



HAL
open science

Alimentation sur mesure et estimation du bien-être des truies gestantes à partir de données hétérogènes

Maëva Durand

► **To cite this version:**

Maëva Durand. Alimentation sur mesure et estimation du bien-être des truies gestantes à partir de données hétérogènes. Sciences agricoles. Agrocampus Ouest, 2023. Français. NNT : 2023NSARC169 . tel-04324739v2

HAL Id: tel-04324739

<https://hal.inrae.fr/tel-04324739v2>

Submitted on 9 Feb 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

COLLEGE

ECOLOGIE

DOCTORAL

GEOSCIENCES

BRETAGNE

AGRONOMIE ALIMENTATION



THESE DE DOCTORAT DE

L'INSTITUT AGRO RENNES ANGERS

ECOLE DOCTORALE N° 600

Ecologie, Géosciences, Agronomie, Alimentation

Spécialité : *Biologie et Physiologie animales*

Par

Maëva DURAND

Alimentation sur mesure et estimation du bien-être des truies gestantes à partir de données hétérogènes

Thèse présentée et soutenue à Rennes, le 23 octobre

Unité de recherche : UMR PEGASE, INRAE, Institut Agro, 35590 Saint Gilles, France

Thèse N° de série : C-169 et N° d'ordre : 2023-17

Rapporteurs avant soutenance :

Philippe Schmidely
Marie-Pierre Létourneau-Montmigny

Professeur, AgroParisTech
Professeur, Université Laval, Québec, Canada

Composition du Jury :

Président : Yannick Le Cozler
Examineurs : Philippe Schmidely
Marie-Pierre Létourneau-Montmigny
Yannick Le Cozler
Sébastien Picault
Christine Duvaux-Ponter
Dir. de thèse : Charlotte Gaillard
Co-dir. de thèse : Christine Largouët

Professeur, Institut Agro
Professeur, AgroParisTech
Professeur, Université Laval, Québec, Canada
Professeur, Institut Agro
Chargé de recherche, INRAE, ONIRIS
Professeur, AgroParisTech
Chargée de recherche, INRAE
Maître de conférences, Institut Agro, IRISA, INRIA

Invité

Jean-Yves Dourmad

Ingénieur de recherche, INRAE

"It always seems impossible until it is done"
Nelson Mandela

Remerciements

Tout d'abord, je tiens à vous remercier, Charlotte, Christine et Jean-Yves, pour votre confiance. Un grand merci à toi, Charlotte, pour m'avoir soutenue, guidée et encouragée en France comme à l'étranger. Le congrès à Davos aura été un bon moment pour apprendre à mieux se connaître. Un grand merci à toi, Christine, pour m'avoir fait découvrir ton domaine, le machine learning, et me l'avoir fait aimer. Je te remercie pour ta patience au cours des trois ans. Un grand merci à toi, Jean-Yves, d'avoir partagé tes connaissances du domaine et de la filière, et pour m'avoir guidée dans la rédaction de mes premiers articles.

Merci à Laetitia Cloutier, Patrick Gagnon, Gabrielle Dumas, Frédéric Guay de m'avoir permis de faire cette mobilité au Québec, en m'aidant dans les démarches de visa, mais aussi, en me faisant découvrir votre travail et la production porcine canadienne.

Merci à Marie-Pierre Létourneau-Montmigny, Philippe Schmidely d'avoir accepté d'être les rapporteurs de cette thèse. Merci également à Yannick Le Cozler, Christine Duvaux-Ponter et Sébastien Picault de faire partie de mon jury de thèse.

Merci aux autres membres de mon CSI, Nicolas Rose et Nathalie Quiniou, pour m'avoir apporté vos conseils et votre regard critique permettant de prendre du recul sur mon travail de thèse.

Merci aux financeurs de la thèse, #DIGITAG et le département PHASE INRAE, d'avoir permis à cette thèse de voir le jour.

Merci à ceux sans qui je n'aurai eu aucunes données pour la thèse. Merci à Daniel Boutin, Yannick Surel, Josselin Delamarre et Mathieu Monvoisin pour votre aide lors des expérimentations entre deux confinements. Merci à Eloïse Talbot-Pouliot, Allison Garand et Nancy Gendron pour votre gentillesse et votre accueil à la maternité de recherche. Merci à Aline Julienne, Clémence Orsini, Justine Abarnou, Marie Couasnon, Clémentine Deroiné, Malinka Misrach, pour vos nombreuses heures à analyser cette montagne de vidéo. Merci à Carole Guérin et Patrick Touanel, pour m'avoir remplacée lors des examens sur les truies.

Merci également à mes collègues de l'équipe Sysporc puis Sysmo, ainsi que les personnes du CDPQ et de l'université de Laval. Un merci plus particulier à Ludovic Brossard pour ton support mental lorsque rien n'allait dans les expérimentations ; à David Renaudeau pour ton aide sur la création du stress thermique et sur la caméra thermique. Merci à Louis Bonneau de Beaufort pour ta grande aide lors des étapes de machine learning et de création de la base de données.

Merci à l'équipe de DILEPIX, Mathieu Simon, Jérémy Foisil, Alban Pobla, Aurélien Yol, mais également à celle du projet SOMOVE, pour nous avoir fait confiance afin de monter ce superbe projet avec nous.

Merci aux doctorants et autres 'précaires' de Pegase pour les bons moments passés en France ou en Congrès. Merci plus particulièrement à Antoine, Chloé et Clément pour m'avoir supportée dans le bureau. Merci à toi, Mathilde, pour ces moments d'échanges et de rire à l'élevage. Merci également aux autres doctorants de #Digitag et d'Agreenium.

Merci à toi, Nadia, pour m'avoir accueillie et fait découvrir ta superbe maison à Lévis et merci aux colocs, Joan et Nadine, pour les bons repas partagés ensemble.

Merci aux copains de la PA Family et à Fabien (presque un PA) pour vos encouragements et vos rires. J'espère que l'on pourra fêter la fin de nos thèses à Sacey bientôt.

Un grand merci à mes deux mousquetaires, Chloé et Cyrielle. Malgré la distance, vous avez toujours pu être là pour me soutenir. J'espère que l'on se retrouvera pour des thés madeleines.

Un immense merci à vous, Maman et Papa. Je ne serais pas arrivée là sans vous, votre soutien sans faille et vos encouragements. Vous m'avez appris à ne pas abandonner et à tout donner pour avoir ce que je veux. Merci à Smallow pour ton petit soutien émotionnel. Merci également au reste de ma famille pour votre intérêt sur mes 'longues' études.

Un immense merci Lucas pour ta patience, ton soutien à mes côtés et pour me rendre meilleure, notamment lors de ces derniers mois de thèse. Merci de m'avoir toujours rappelé les facettes économiques et techniques de mon travail.

Remerciements

A toutes les truies françaises et canadiennes de ma thèse qui m'ont bien fait rire, en direct ou lors des analyses vidéos.

Merci à tous ceux croisés lors des trois ans qui ont embelli mon doctorat et merci à ceux qui liront autre chose que ces lignes.

Sommaire

REMERCIEMENTS	5
SOMMAIRE	8
AVANT-PROPOS	10
VALORISATION AU COURS DE LA THESE	11
LISTE DES FIGURES	15
LISTE DES TABLEAUX	19
LISTE DES ABREVIATIONS	21
INTRODUCTION GENERALE	23
1. ETAT DE L'ART	27
1.1. LE BIEN-ETRE DE LA TRUIE EN GESTATION	27
1.2. L'ALIMENTATION SUR MESURE DE LA TRUIE EN GESTATION	40
1.3. EFFET DU COMPORTEMENT ET DE L'ENVIRONNEMENT SUR LES BESOINS NUTRITIONNELS DE LA TRUIE GESTANTE	49
1.4. APPORT DU MACHINE LEARNING POUR L'ETUDE DU COMPORTEMENT ET L'ALIMENTATION SUR MESURE	59
1.5. REFERENCES BIBLIOGRAPHIQUES	77
2. DÉMARCHE ET QUESTIONNEMENT SCIENTIFIQUE	91
2.1. QUESTIONNEMENT DE LA THESE	91
2.2. DEMARCHE ENTREPRISE DANS LA THESE	93
2.3. REFERENCES BIBLIOGRAPHIQUES	96
3. QUANTIFICATION DE L'EFFET DE L'ENVIRONNEMENT SUR LE COMPORTEMENT DU GROUPE DE TRUIES GESTANTES	97
3.1. CREATION D'UNE BASE DE DONNEES RELATIONNELLE	98
3.2. EXEMPLE DETAILLE D'UNE SITUATION DE COMPETITION ALIMENTAIRE	107
3.3. INFLUENCE DE DIFFERENTS EVENEMENTS SUR LE COMPORTEMENT ET LES BESOINS NUTRITIONNELS DES TRUIES	131
3.4. REFERENCES BIBLIOGRAPHIQUES	141
4. NOUVELLE METHODE DE PREDICTION DES BESOINS NUTRITIONNELS A PARTIR D'AUTOMATES ET DE CAPTEURS	147
4.1. PREDICTION DE L'ACTIVITE D'UN GROUPE DE TRUIES A PARTIR D'ANALYSES D'IMAGES PAR UN RESEAU DE NEURONES	148
4.2. PREDICTION DES BESOINS JOURNALIERS NUTRITIONNELS DES TRUIES GESTANTES A PARTIR DE DONNEES DE CAPTEURS ET D'ALGORITHMES DE MACHINE LEARNING.	155
4.3. REFERENCES BIBLIOGRAPHIQUES	176

5.	ESTIMATION DE L'ETAT DE BIEN-ETRE DES TRUIES A PARTIR DE METHODES DE MACHINE LEARNING	181
5.1.	EXPERIMENTATION FRANÇAISE	182
5.2.	EXPERIMENTATION CANADIENNE	200
5.3.	REFERENCES BIBLIOGRAPHIQUES	208
6.	DISCUSSION GENERALE	213
6.1.	ORIGINALITE DE LA DEMARCHE BASEE SUR LES NOUVELLES TECHNOLOGIES	214
6.2.	VERS LA CONCEPTION D'UN OUTIL D'AIDE A LA DECISION ET D' ACTIONS CORRECTRICES INTEGREES POUR L'ALIMENTATION ET LE BIEN-ETRE.....	221
6.3.	REFERENCES BIBLIOGRAPHIQUES	232
	CONCLUSION GENERALE	235
	ANNEXES.....	236

Avant-propos

La thèse s'est déroulée au sein de l'UMR Pegase de l'INRAE (Physiologie, Environnement et Génétique pour l'Animal et les Systèmes d'Élevage), à Saint Gilles. Le financement de la thèse était issu de l'Etat : l'Agence Nationale de la Recherche au titre du programme d'Investissements d'avenir portant la référence ANR-16-CONV-0004 - #DIGITAG (Institut Convergences Agriculture Numérique) et le département PHASE de INRAE (Physiologie animale et systèmes d'élevage). La thèse s'est également déroulée au sein du parcours doctoral de l'école internationale de recherche d'Agreenium (EIR-A). L'encadrement de la thèse a été réalisé par Charlotte Gaillard et Jean-Yves Dourmad (UMR Pegase, Saint Gilles) et Christine Largouët (UMR IRISA, Rennes).

Au cours de la thèse, une collaboration a eu lieu avec le Centre de développement du Porc du Québec et avec l'Université Laval (département des sciences animales), à Québec, au Canada où une mobilité de 4 mois a eu lieu à la ferme de recherche et de formation de Armagh en 2021. Durant cette période, j'ai été encadrée par Patrick Gagnon, Laetitia Cloutier, Gabrielle Dumas et Frédéric Guay. Cette mobilité a été financée grâce à trois bourses sélectives sur dossier (ED EGAAL, Rennes Métropole et #DIGITAG).



Valorisation au cours de la thèse

Articles scientifiques dans des journaux à comité de lecture

Acceptés et publiés

- (1) Gaillard C., Durand M., Largouët C., Dourmad J.Y., Tallet C., 2021. Effects of the environment and animal behavior on nutrient requirements for gestating sows: Future improvements in precision feeding. *Anim. Feed Sci. Technol.*, 279, 115034.
- (2) Durand M., Dourmad J.Y., Largouët C., Tallet C., Gaillard C., 2021. Alimentation de précision des truies gestantes : prise en compte de la santé, du comportement et de l'environnement. *INRAE Prod. Anim.*, 34, p.293-304.
- (3) Abarnou J., Durand M., Dourmad J.Y., Gaillard C., 2023. Effects of induced thermal conditions on gestating sows' behaviors and energy requirements. *J. Anim. Sci.*, 101, pp.skac413.
- (4) Durand M., Largouët C., Bonneau de Beaufort L., Dourmad J.Y., Gaillard C., 2023. A dataset to study group-housed sows' individual behaviours and production responses to different short-term events. *Animal Open Space*, 2, 100039.
- (5) Durand M., Dourmad J.Y., Julienne A., Couasnon M., Gaillard C., 2023. Effects of a competitive feeding situation on the behaviour and energy requirements of gestating sows. *Appl. Anim. Behav. Sci.*, 261, 105884.
- (6) Gaillard C., Deroiné C., Misrach M., Durand M., 2023. Effects over time of different types of sounds on gestating sows' behaviour. *Appl. Anim. Behav. Sci.*, 266, 106012.
- (7) Durand M., Largouët C., Bonneau de Beaufort L., Dourmad J.Y., Gaillard C. Prediction of the daily nutrient requirements of gestating sows based on sensor data and machine-learning algorithms. *J. Anim. Sci.*, 101, skad337.

Soumis ou en cours de préparation

- (8) Durand M., Largouët C., Bonneau de Beaufort L., Dourmad J.Y., Gaillard C. Prediction of gestating sows' welfare status based on machine learning methods and behavioural data. *En révision à Sci. Rep.*

- (g) Orsini C., Durand M., Gaillard C. Effect of environmental enrichment on the behaviour of pregnant sows. *Soumis à Plos One*.
- (10) Durand M., Largouët C., Dourmad J.Y., Gaillard C. Machine Learning for livestock precision feeding. *En cours de preparation*.

Conférences internationales

Présentations orales

72^{ème} Congrès annuel de l'European Federation of Animal Science (EAAP), Davos, Suisse, 2021 (Annexe A) :

- Durand M., Julienne A., Dourmad J.Y., Gaillard C. Effect of feed competition on activity and social behaviour of gestating sows. *Session 42. Inclusive livestock nutrition: where we have a trad-off between performance, environmental sustainability and animal welfare*.
- Durand M., Renaudeau D., Gaillard C. Use of infrared thermography and rectal thermometer to measure body temperature of gestating sows. *Session 44. PLF methods for measuring health, welfare and caring for individual animals*.
- Gaillard C., Durand M. Effect of sudden noises on gestating sows' behaviour. *Session 58. Animal behaviour : from horses to hens*.

73^{ème} Congrès annuel de l'EAAP, Porto, Portugal, 2022 (Annexe B) :

- Durand M., Abarnou J., Julienne A., Orsini C., Gaillard C. Effect of various short-term events on behaviours of gestating sows. *Session 21. Innovative approaches to pig and poultry production*.
- Durand M., Simon M., Foisil J., Dourmad J.Y., Largouët C., Gaillard C. Evaluation of the physical activity of a group of gestating sows using an artificial neural network. *Session 41. Development and external validation of PLF tools for animal behaviour, health and welfare: pigs, sheep, beef and poultry*.

7^{ème} EAAP International Symposium on Energy and Protein Metabolism and Nutrition (ISEP), Session 5b. *Impact of heat stress and other environmental challenges on energy and protein metabolism*, Grenade, Espagne, 2022 (Annexe C) : Durand M., Abarnou J., Julienne A., Orsini C., Dourmad J.Y., Gaillard C. Effect of short-term

events on the activity of gestating sows and their nutritional requirements. *Animal - science proceedings*, 13, p.445-447.

74^{ème} Congrès annuel de l'EAAP, Lyon, France, 2023 : Gaillard C., Ribas C., Durand M. Precision feeding, recent advances for gestating sows and dairy cow. *Session 81. Precision Feeding.*

Poster

14^{ème} European Symposium of Porcine Health Management (ESPHM), Welfare and Nutrition session, Thessalonique, Grèce, 2023 (Annexe D) : Durand M., Largouët C., Bonneau L., Dourmad J.Y., Gaillard C. Prediction of daily nutritional requirements of gestating sows based on their behaviour and Machine learning methods

Conférences nationales

Présentations orales

54^{ème} Journées de la Recherche Porcine, en ligne, 2022 : Lanthony M., Durand M., Guérin C., Gaillard C., Tallet C. Hiérarchie dans les groupes de truies gestantes : méthodes de calcul, caractéristiques et lien avec les données d'alimentation. *Session Bien-être animal, reproduction porcine et conduite de l'élevage porcin.*

55^{ème} Journées de la Recherche Porcine, Saint Malo, 2023 (Annexe E) : Durand M., Gagnon P., Cloutier L., Dumas G., Guay F., Dourmad J.Y., Gaillard C. Prédiction de la température corporelle de truies gestantes à l'aide d'une caméra thermique. *Session Santé animale.*

Posters

54^{ème} Journées de la Recherche Porcine, en ligne, 2022, *Session Alimentation animale* (Annexe F) :

- Durand M., Gaillard C. Comportements de truies gestantes en situation de compétition alimentaire.
- Orsini C., Durand M., Gaillard C. Effet de l'enrichissement de l'environnement sur le comportement des truies gestantes.

- Abarnou J., Durand M., Gaillard C. Effet de stress thermiques sur le comportement des truies en gestation.

55^{ème} Journées de la Recherche Porcine, Saint Malo, 2023, Session Bien-être animal :

- Durand M., Dourmad J.Y., Gaillard C. Prédiction de l'activité journalière de truies gestantes à partir de créneaux ponctuels d'analyse vidéo manuelle.
- Couasnon M., Gaillard C., Durand M. Comportement de truies gestantes après répétition d'une compétition alimentaire.
- Deroiné C., Misrach M., Durand M., Gaillard C. Effets à court et moyen terme de différents types de sons sur le comportement de truies gestantes.

56^{ème} Journées de la Recherche Porcine, Saint Malo, 2024 : Durand M., Largouët C., Bonneau L., Dourmad J.Y., Gaillard C. Prédiction des besoins nutritionnels de truies gestantes à partir de données de capteurs et d'algorithmes d'apprentissage automatique.

Autres activités de valorisation

- Présentations orales lors des Journées des doctorants de l'unité Pegase, INRAE en 2021, 2022 et 2023.
- Article « Recherche : Prendre la température sans thermomètre. Une caméra pour prédire la température corporelle des truies », Journal Porcmag, n°577, mai-juin 2023, p.37.
- Présentation orale pour le webinaire PigWeb : junior community le 16/01/2023 « New models and parameters for Precision Feeding in pigs ».
- Présentation orale aux Journées scientifiques EGAAL le 30 juin 2022 « Effect of various short term events on behaviours of gestating sows ».
- Intervention à la table Ronde « Le numérique pour mieux produire : des productions animales durable » de la Digitagora, le 25 mai 2022.
- Article « Alimentation des truies gestantes : Comportement et besoins énergétiques », Journal technique Porcmag, n°570, mars-avril 2022, p.55.

Liste des figures

Figure 1-1 : Émotion et état mental de l'animal.....	28
Figure 1-2 : Modèle de motivation alimentaire, de l'influence de régimes alimentaires à haute et faible teneurs en fibres à trois moments (avant et après le repas et entre les repas).....	30
Figure 1-3 : Budget temps des occupations d'une truie en gestation, logée en groupe avec un distributeur automatique d'aliment sur caillebotis béton.	33
Figure 1-4 : Exemple de simulation avec InraPorc de la dynamique de partition des apports quotidiens en énergie digestible et en lysine digestible iléale standardisée pour une truie de rang de parité 2.	41
Figure 1-5 : Influence de la stratégie alimentaire pendant la gestation sur le développement des fœtus.	44
Figure 1-6 : Représentation du modèle nutritionnel des truies en gestation.....	45
Figure 1-7 : Estimation de l'influence d'une alimentation sur mesure (vs. une alimentation conventionnelle) durant la gestation à partir de la proportion de truies recevant des quantités de lysine satisfaisantes, en déficit ou en excès.	47
Figure 1-8 : Apports nutritionnels nécessaire pour couvrir l'activité physique supplémentaire d'une truie gestante au-delà de 4 h passées en position debout.	50
Figure 1-9 : Modifications physiologiques et comportementales de la truie selon la température ambiante.....	54
Figure 1-10 : Schéma du fonctionnement d'une démarche en machine learning.	60
Figure 1-11 : Méthodes et algorithmes de ML utilisé dans la suite de la thèse (Liakos <i>et al.</i> , 2018).....	61
Figure 1-12 : Matrice de confusion et métriques de reconnaissance d'images de chien et de chat entre les prédictions d'un algorithme (étiquettes) et la réalité (images).....	64
Figure 1-13 : Consommation d'eau et ingestion alimentaire totale au sein d'une bande de truies gestantes, en fonction du moment de la journée.	67

Figure 1-14 : Schéma récapitulatif de l'apport du machine learning pour l'alimentation.....	71
Figure 2-1 : Schéma de la démarche scientifique adoptée au cours de la thèse. .	93
Figure 3-1: Schema of the relational database.....	101
Figure 3-2: Summary of the experimental design and data collection on gestating sows.....	106
Figure 3-3: The organization of the gestating sow pen including the automatons and sensors.....	111
Figure 3-4: Effect of the experimental treatment (Control vs. Restricted access to the feeder) and the social ranking (low (LR), intermediate (IR) and high ranking (HR) sows, on the feeding (1.) and drinking (2.) behaviour patterns, as a mean on the five experimental days.	118
Figure 3-5: Effect of the treatment (Control vs. Restricted access to the feeder) on the time stamp of the posture (lying, moving and standing) during the 5 days of the experiment.....	123
Figure 3-6 : Nombre de comportements agressifs en fonction des conditions thermiques et du groupe (les lettres a, b et c montrent une différence significative des tests post-hocs).	136
Figure 3-7 : Effet des différents événements à court terme sur la médiane et les quantiles du besoin en énergie métabolisable (en MJ/d) pour les truies gestantes.	139
Figure 4-1 : Détection de l'activité des truies par le logiciel développé.....	148
Figure 4-2 : Différentes activités détectées par le réseau de neurones.....	149
Figure 4-3 : Schéma de la démarche du travail.....	150
Figure 4-4 : Matrice de confusion avant (A.) et après renforcement (B.).....	151
Figure 4-5 : Capture d'écran d'une vidéo avec une position couchée ambiguë...	152
Figure 4-6 : Activité de la moyenne des deux groupes de truies à la journée (A.) et par heure (B.).	153
Figure 4-7: Creation of scenarios with or without sow and housing characteristics based on various sensors (one only or two combined) used in the study.....	160
Figure 4-8: Evaluation of the algorithm's performance with the nutrition model.	160

Figure 4-9: Evaluation of the 11 scenarios with sow and housing characteristics: R ² scores for SID Lys prediction, according to the 9 algorithms evaluated, with 1 or 2 sensor(s).....	168
Figure 4-10: Evaluation of the 11 scenarios with sow and housing characteristics: R ² scores for ME prediction, according to the 9 algorithms evaluated, with 1 or 2 sensor(s).....	169
Figure 4-11: Ablation study : MAPE values (%) of GTB for standard ileal digestible lysine (SID LYS) and for metabolizable energy (ME) according to the all the features excluded from scenario 1 (feeder data) with sow and housing characteristics.	170
Figure 5-1: General approach of the current study (offline learning part) and practical perspectives (online forecasting). The number (first box, upper left) corresponds to the week of gestation.....	185
Figure 5-2: Evolution of the sows from group A between the three clusters during the six periods followed. One line between periods corresponds to one sow evolution.....	194
Figure 5-3: Proportions of sows in the three clusters (gentle, aggressive, scapegoat) regarding each week (control or events).....	195
Figure 5-4: Decision Tree to predict clusters with the feeder (individual data) and automatic video analysis data (group data).....	196
Figure 5-5 : Représentation schématique des zones où la température cutanée a été relevée par caméra thermique infrarouge (ir) : 1 : ir_oeil, 2 : ir_oreille, 3 : ir_dos, 4 : ir_vulve et 5 : ir_mamelle.....	201
Figure 5-6 : Evolution au cours du temps des catégories de bien-être (sur les truies suivies en continu soit 660 observations).....	204
Figure 5-7 : Répartition des truies selon les catégories en fonction de la stratégie alimentaire.....	205
Figure 5-8 : Arbre de décision pour prédire le niveau de bien-être à l'aide de l'automate d'alimentation et la caméra thermique.....	206
Figure 6-1 : Schéma d'un retour sur investissement de la démarche de la thèse pour un élevage type.....	217
Figure 6-2 : MAPE de prédiction du Phosphore digestible par les différentes techniques de ML selon les capteurs (avec les données sur les caractéristiques des truies).....	222

Figure 6-3 : Calculs a posteriori du temps debout (A.) et des besoins alimentaires (B.) avec la distinction du mouvement.	224
Figure 6-4 : Evolution entre les semaines observées des truies entre les trois clusters de bien-être, selon les quatre bandes.....	226
Figure 6-5 : Schéma de l'outil imaginé en aide à la décision, avec des alertes et des actions correctrices.....	227

Liste des tableaux

Tableau 1-1 : Protocole du Welfare Quality® (2009) pour les truies gestantes.....	35
Tableau 1-2 : Exemple de capteurs et de leurs applications pour la mesure de modifications comportementales et physiologiques des porcs (Cornou et Kristensen, 2013 ; Matthews <i>et al.</i> , 2016 ; Benjamin et Yik, 2019).....	38
Tableau 1-3 : Niveaux alimentaires recommandés pour les truies gestantes à différentes parités et performances ¹ inspiré de Trottier <i>et al.</i> , (2015).....	42
Table 3-1: Description of the 18 tables of the relational database: primary and foreign keys, number of columns and rows.....	102
Table 3-2: Composition of the two diets (low and high nutrient content) used for feed allowance, expressed in g per kg of feed.....	112
Table 3-3: Description of the sows' behaviours recorded manually from videos.	114
Table 3-4: Effect of the experimental treatment ^a , period ^b , group ^c and hierarchical status of sows ^d , on the feeding and drinking behaviour (number and duration of visits, and the amount of feed and water consumed), on the social behaviour (number of positive and negative interactions) and on the occupation.	117
Table 3-5: Effect of the experimental treatment ^a , period ^b , batch ^c and hierarchical status of sows ^d , on the body condition (body weight and backfat thickness gain), on the skin lesions (scratch and wound index), on the posture and on the nutritional requirements.....	122
Tableau 3-6 : Effets des évènements sur le comportement des truies, par rapport à leur semaine contrôle respective (en rose si augmentation et en bleu si diminution significative).	133
Tableau 4-1 : Performances de l'algorithme avant et après renforcement.	151
Tableau 4-2 : Comparaison des pourcentages d'activités détectées sur les vidéos par un observateur humain et l'algorithme.	152
Table 4-3: Description of the daily variables predicted and used in the nutritional model as well as sow and housing characteristics.....	161
Table 4-4: Description of the variables studied per scenario, as a daily mean value by parity (primiparous and multiparous sows).	162

Table 4-5: Hyper-parameters tested on the selected supervised learning algorithms.....164

Table 4-6: Prediction performances (RMSE, MAPE, R2) of standard ileal digestible lysine (SID Lys) and metabolizable energy (ME) with sensor-based scenarios (one or two) only (as a mean value \pm SD of the 9 algorithms).....165

Table 4-7: Prediction performances (RMSE, MAPE, R2) of metabolizable energy (ME) and standard ileal digestible lysine (SID Lys) per algorithm (as a mean value \pm SD of the 22 scenarios with or without sow and housing characteristics).....166

Table 4-8: Prediction performances (RMSE, MAPE, R2) of standard ileal digestible lysine (SID Lys) and metabolizable energy (ME) with sensor-based scenarios (one or two) including sow and housing characteristics (as a mean value \pm SD of the 9 algorithms).....167

Table 5-1: Ethogram and description of the features used on the study (NV = nutritive visit; NNV = nonnutritive visit; cat = categories; Avg = average; Nb = number).
.....189

Table 5-2: Differences of features between the three clusters. The letters a, b, and c show a significant difference for post hoc tests (NV = nutritive visit; NNV = nonnutritive visit; cat = categories; Avg = average; Nb = number).....193

Table 5-3: Performances metrics (precision, recall, F1-score) depending of the clusters and the data used on the decision tree.196

Tableau 5-4 : Métriques de performances (precision, recall, f1-score) selon les catégories de bien-être et les données utilisées pour l'arbre de décision.....207

Liste des abréviations

DAC (ESF en anglais) = Distributeur automatique aliment

DL = Apprentissage profond (Deep Learning)

ELD = Epaisseur de Lard Dorsal

EM (ME en anglais) = Energie métabolique

EN = Energie nette

GTB = Arbre à Gradient Boosté (Gradient Tree Boosting)

KNN = k-plus-proches voisins (K-nearest-neighbors)

LASSO = Régression linéaire avec optimisation LASSO

LR = Régression linéaire

MAPE = Erreur moyenne absolue en pourcentage

ML = Apprentissage automatique (Machine Learning)

MLP = Perceptron à couches multiples (Multiple layer perceptron)

NV = Visite nutritive

NNV = Visite non-nutritive

PR = Régression Polynomiale

RF = Forêt aléatoire

RFID = Identification par Radio fréquence

RIDGE = Régression Linéaire avec optimisation RIDGE

RMSE = Erreur Quadratique moyenne

SID = Digestible iléal standardisé

STTD = Digestible total dans le tractus standardisé

SVR = Machine à Vecteur de support (Support Vector Machine)

TC_i = Température critique inférieure

TC_e = Température critique d'évaporation

THI = Index Température Humidité

Introduction générale

Depuis plusieurs années, la production porcine française doit faire face à de profondes mutations liées, d'une part à un changement générationnel des éleveurs, et d'autre part à une évolution des pratiques. En effet, depuis 2010, le nombre d'exploitations agricoles avec un atelier porcin a été réduit de plus de 20 %, en lien avec une augmentation de la taille de celui-ci. De plus, l'attractivité du métier d'éleveur porcin nécessite d'être renforcée pour répondre aux besoins croissants de main d'œuvre. La numérisation et l'automatisation des élevages se développent également dans cet objectif (Roguet, 2023). Différents enjeux se profilent aussi pour la filière notamment, la gestion du coût de l'alimentation des animaux et les attentes sociétales grandissantes concernant le bien-être animal (Buchet *et al.*, 2023). Le coût alimentaire est très volatil, avec une évolution à la hausse, depuis quelques années, sous l'influence du changement climatique et de conflits géopolitiques. Il devient nécessaire de le réduire afin de maximiser le revenu des éleveurs. L'amélioration des conditions de vie des animaux fait l'objet de nombreuses réglementations et recommandations aux niveaux français et européen. L'objectif est de favoriser le bien-être des animaux, dans un contexte d'augmentation des tailles de cheptel. Ces deux enjeux peuvent être soutenus par l'élevage de précision et les nouvelles technologies en élevage.

Numérisation et automatisation des élevages porcins. Le développement d'automates et d'objets connectés s'est fait grâce aux progrès technologiques qui permettent de disposer de plus en plus de données. Ainsi, il est possible de mettre en place des solutions numériques et automatiques dans tous les domaines (industrie, médical, *etc.*) mais également en production animale. Ce nouveau domaine appelé élevage de précision offre des perspectives à explorer pour répondre aux enjeux de la production porcine, en support des yeux et des oreilles de l'éleveur (Oczak *et al.*, 2021). Par exemple, les automates permettent, d'automatiser l'alimentation, mais aussi de suivre les animaux d'élevage grâce à des systèmes de reconnaissance de radio fréquence et des caméras. Parmi les opportunités offertes par ce nouveau domaine, il est intéressant de noter la réduction des coûts d'alimentation et l'amélioration du bien-être (Neethirajan et

Kemp, 2021). En effet, avec l'augmentation des tailles de cheptel, le temps accordé pour chaque animal par l'éleveur est réduit. Les outils d'élevage de précision permettent d'agir le plus précocement possible sur des problèmes de bien-être ou de santé. Cependant, il est nécessaire de développer des méthodes d'analyse des données hétérogènes issues de ces outils.

Réduire les coûts d'alimentation au cours de la gestation. Afin de réduire les coûts d'alimentation, qui représentent plus de 75 % du coût de production, et de maximiser l'efficacité alimentaire, plusieurs stratégies ont été proposées et étudiées. L'efficacité alimentaire peut être définie comme le ratio entre les performances de production de l'animal et sa consommation d'aliment sur une période (Gaillard *et al.*, 2020). L'alimentation sur mesure (appelée auparavant de précision) se développe avec pour objectif de maximiser l'efficacité alimentaire en limitant les excès de consommation d'aliment. Cette stratégie vise à apporter à l'animal les justes quantités journalières de nourriture permettant de couvrir ses besoins individuels. L'utilisation du terme d'alimentation « sur mesure » à la place de « précision » permet de mettre en évidence qu'elle vise à proposer des stratégies individualisées mais qui peuvent encore gagner en précision pour la prédiction des besoins et la distribution des apports (Faverdin *et al.*, 2021). L'alimentation sur mesure permet notamment de réduire le coût alimentaire et les rejets environnementaux (tel que le phosphore et l'azote), un autre défi de la production porcine (Pomar et Remus, 2021). Il est ainsi nécessaire de continuer à développer des outils de prédiction des besoins, en s'appuyant sur des modèles ou des algorithmes.

Améliorer le bien-être des truies gestantes. Avec la mise en groupe des truies gestantes en 2013, l'amélioration de leur bien-être est une préoccupation de la filière porcine. La recherche d'indicateurs de bien-être fiables et faciles à utiliser en élevage représente également un autre challenge pour répondre aux attentes sociétales. Il convient pour ce faire de définir le bien-être et ses implications sur la physiologie et le comportement des animaux, avant de l'évaluer. De nombreux projets de recherche s'intéressent ainsi à l'impact du stress, de la santé et du bien-être à l'aide de biomarqueurs dans le sang, les soies, la salive, *etc.* Le développement des nouvelles technologies est une voie possible pour l'étude du

comportement. La plupart des technologies disponibles aujourd'hui se concentrent sur la détection précoce de problèmes de santé liée à des modifications comportementales (Veissier *et al.*, 2019). Il est ainsi nécessaire de développer des méthodes d'estimation du bien-être en s'appuyant sur les nouvelles technologies.

Dans ce contexte, cette thèse vise à répondre à la problématique suivante :
Comment les données comportementales et environnementales peuvent améliorer l'estimation des besoins nutritionnels et du bien-être des truies en gestation ?

Ce manuscrit se compose de six chapitres. Dans le premier chapitre, un état de l'art est réalisé afin de replacer le sujet de la thèse dans son contexte. Une première partie est consacrée aux notions autour du bien-être et aux indicateurs utilisés pour la truie gestante. Une deuxième partie s'intéresse à la variabilité et au calcul des besoins nutritionnels, ainsi qu'aux avantages et inconvénients de l'alimentation sur mesure. Une troisième partie se concentre sur l'impact du comportement de la truie et de son environnement sur les besoins nutritionnels. La dernière partie de l'état de l'art présente l'utilisation d'algorithmes de machine learning, synthétise leurs contributions pour la mesure du comportement et pour l'alimentation sur mesure. Le chapitre 2 décline les questions de recherche et présente la démarche scientifique adoptée au cours de la thèse. Les chapitres 3, 4 et 5 regroupent les principaux résultats de la thèse. Une discussion générale est développée dans le chapitre 6 afin de rassembler les résultats marquants du projet, les points d'amélioration et les perspectives mais aussi de répondre aux objectifs de la thèse. Une conclusion générale clôture ce manuscrit.

Références bibliographiques :

Buchet A., Botric M., Ballay M., Domain C., Sialelli J.N., David J.C., 2023. Étude de la perception sociale d'un modèle d'élevage de porcs conventionnel par le biais de la réalité virtuelle. In : JRP (Ed.), Proceedings of 55ème Journées Rech. Porcine, Saint-Malo, France, p.13-18.

Faverdin P., Allain C., Guatteo R., Hostiou N., Veissier I., 2021. Élevage de précision : De nouvelles informations utiles pour la décision ? *INRAE Prod. Anim.*, 33, p.223-234.

Gaillard C., Brossard L., Dourmad J.Y., 2020. Improvement of feed and nutrient efficiency in pig production through precision feeding. *Anim. Feed Sci. Technol.*, 268, 114611.

Neethirajan S., Kemp B., 2021. Digital Livestock Farming, *Sens. Bio-Sens. Res.*, 32, 100408.

Oczak M., Maschat K., Baumgartner J., 2021. Advances in technologies for monitoring pig welfare. In : S. Edwards (Ed.), Understanding the behaviour and improving the welfare of pigs, Burleigh Dodds Science Publishing Series in Agricultural science, number 96, Dublin, Irlande. p.525-561.

Pomar C., Remus A., 2021. Precision pig feeding: a breakthrough towards sustainability. In : ESPHM (Ed.), Proceedings of 12th European symposium of porcine health management, Session Nutrition, Bern, Suisse, p.28-39.

Roguet C., 2023. Evolution, diversité et typologie des exploitations porcines en France : enseignements du recensement agricole de 2020, comparaison aux recensements de 2010 et 2000. In : JRP (Ed.), Proceedings of 55ème Journées Rech. Porcine, Saint-Malo, France, p.1-6.

Veissier I., Kling-Eveillard F., Mialon M.M., Silberberg M., De Boyer Des Roches A., Terlouw C., Ledoux D., Meunier B., Hostiou N., 2019. Élevage de précision et bien-être en élevage : la révolution numérique de l'agriculture permettra-t-elle de prendre en compte les besoins des animaux et des éleveurs ? *INRA Prod. Anim.*, 32, p.281-290

1. Etat de l'art

Cet état de l'art résume notamment plusieurs publications soumises ou publiées : (1), (2) et (10).

1.1. Le bien-être de la truie en gestation

1.1.1. Définitions et notions autour du bien-être animal

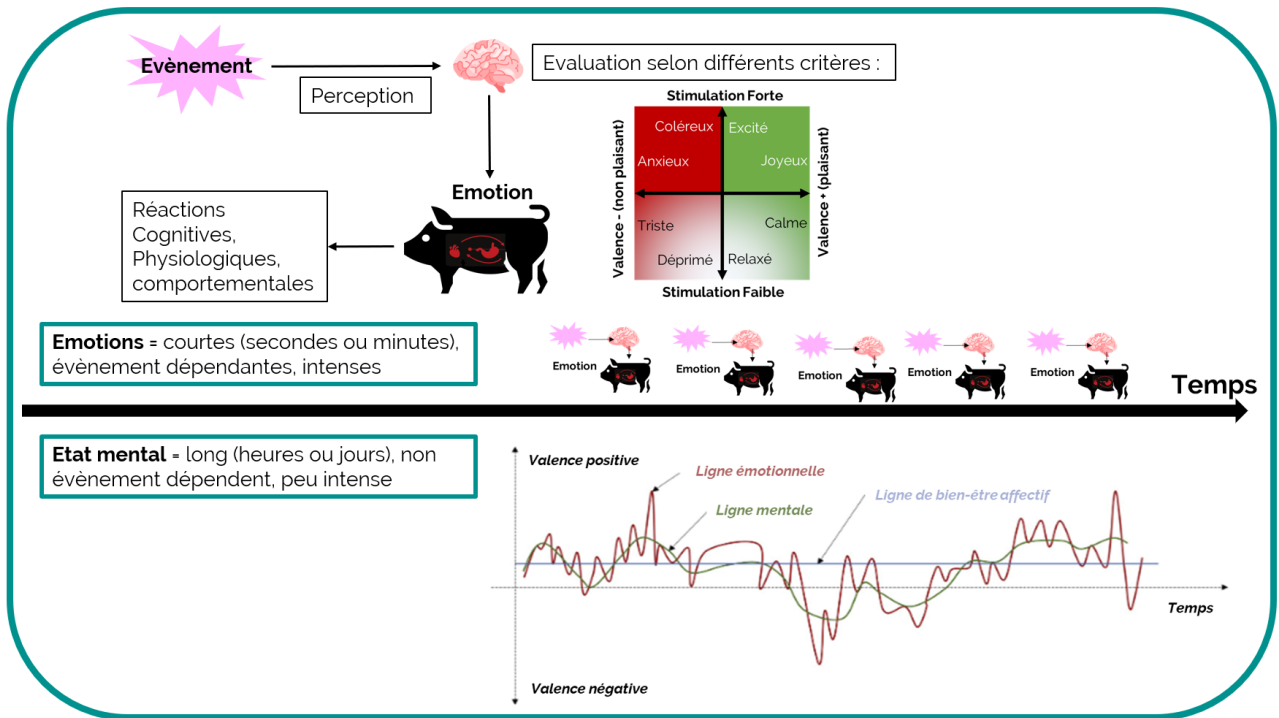
Depuis plus de 50 ans, la définition du bien-être animal fait l'objet de débats et de désaccords (Mormède *et al.*, 2018). Le bien-être est souvent défini par les 5 libertés individuelles, présentées en 1979 par le Farm Animal Welfare Council (FAWC) et reprises par la suite par l'Organisation Mondiale de la santé animale (OIE, 2018). Il s'agit de :

- *L'absence de faim, de soif et de malnutrition* : l'animal doit avoir accès à une alimentation de qualité et en quantité correspondant aux besoins de son espèce. Il doit également avoir accès à l'eau.
- *L'absence de peur et de détresse* : les conditions de vie ne doivent pas induire de souffrances psychiques à l'animal.
- *L'absence de stress physique et/ou thermique* : l'animal doit être logé dans des conditions de confort physique et thermique.
- *L'absence de douleur, de lésions et de maladie* : l'animal ne doit pas subir de traitements risquant de lui faire mal ou de le blesser. Il doit être également soigné en cas de maladie.
- *La liberté d'expression d'un comportement normal de son espèce* : l'animal doit être logé dans ces conditions adaptées à son espèce et à ses besoins.

Cette définition n'est pas suffisante pour la notion de bien-être animal car il s'agit de bientraitance de l'animal par l'homme. C'est-à-dire que l'animal vit dans un environnement conforme à ses besoins. La définition du bien-être de l'ANSES de

2018 va plus loin avec la question du ressenti et des émotions de l'animal. Elle est désormais adoptée par de nombreux experts du domaine.

« Le bien-être d'un animal est l'état mental et physique positif lié à la satisfaction de ses besoins physiologiques et comportementaux, ainsi que de ses attentes. Cet état varie en fonction de la perception de la situation par l'animal » (ANSES, 2018).



Inspiré de Kremer *et al.*, 2020 et Mendl *et al.*, 2010

Figure 1-1 : Émotion et état mental de l'animal.

Une émotion est une réaction affective, intense et fugace, en réponse à un évènement. En effet, lorsqu'un animal perçoit un évènement, il évalue celui-ci selon différents critères: la soudaineté, la familiarité, la prévisibilité ou la prédictibilité, la valence positive ou négative, l'adéquation avec les attentes, la contrôlabilité et les normes sociales. Selon cette évaluation et son expérience, l'animal provoquera ou non des réponses comportementales et/ou des réponses physiologiques. L'ensemble de ces émotions au cours du temps constitue l'état mental de l'animal (Boissy *et al.*, 2007 ; Veissier *et al.*, 2009 ; Figure 1-1). Le comportement est ainsi un mécanisme adaptatif en réponse à l'environnement et qui rassemble toutes activités observables neuronales, motrices ou sensorielles telles que le mouvement, les interactions sociales, l'exploration, la cognition ou

l'apprentissage (Breed et Moore, 2012 ; Dugatkin, 2019). Ces trois premières composantes seront utilisées dans la suite de ce travail.



Pour résumer, le bien-être animal est une notion complexe à définir car elle intègre l'état mental de l'animal et son ressenti face à un évènement. Il est lié aux émotions qui peuvent déclencher des réponses comportementales et physiologiques. Au cours de sa gestation, la truie peut être confrontée à des évènements altérant son bien-être.

1.1.2. Principaux risques de mal-être pour la truie en gestation

Ces risques de mal-être sont liés aux combats avec les congénères, aux problèmes de santé, et au rationnement alimentaire. Les combats et agressions entre truies sont naturels afin de construire les relations de dominance lors de la mise en place de la hiérarchie mais constituent un premier risque de mal-être. En effet, les agressions sont inévitables lorsque des truies non familières sont regroupées. Ces relations agonistiques peuvent provoquer des blessures plus ou moins sévères : des griffures et plaies, des fractures, des boiteries, voire des atteintes de la moelle épinière liées à des glissades, des coups, des morsures, *etc.* (Anil *et al.*, 2005 ; Hemsworth, 2021). Les relations de dominance se mettent en place environ à partir du 9^{ème} jour de regroupement. Une fois celles-ci établies, le niveau d'agressions et de combats diminue (Gonyou, 2001) pour laisser place à des agressions plus courtes pour gagner ou défendre l'accès aux ressources (nourriture ou espace de couchage ; Verdon et Rault, 2018 ; Hemsworth, 2021). Ces agressions peuvent être renforcées par des conditions de logement non optimales (espace disponible par truie, taille du groupe, type de système d'alimentation, enrichissement et type de sol), des principes de gestion (moment de mise en groupe, groupe statique ou dynamique) et des caractéristiques individuelles des truies (génétique, âge ; Hemsworth, 2021).

Parmi les problèmes de santé, les boiteries sont des problèmes récurrents qui peuvent être liés, aux conditions de logement ou à des carences

nutritionnelles, ainsi qu'aux agressions citées précédemment. Les truies sont généralement immunisées contre la plupart des maladies endémiques de leur élevage. Cependant, l'introduction de nouveaux pathogènes (tel que le parvovirus ou le virus de l'influenza porcine) peuvent créer des épidémies provoquant des pertes économiques pour l'éleveur. Ces épidémies peuvent induire avortement ou diminution du nombre de fœtus, voire une mortalité de la truie. D'autres causes de mortalité brutales peuvent être dues à des hémorragies, des ulcères gastriques ou des torsions gastrointestinales, à des stress thermiques, à des poly néphrites ou à des insuffisances cardiaques (Friendship et Sullivan, 2015).

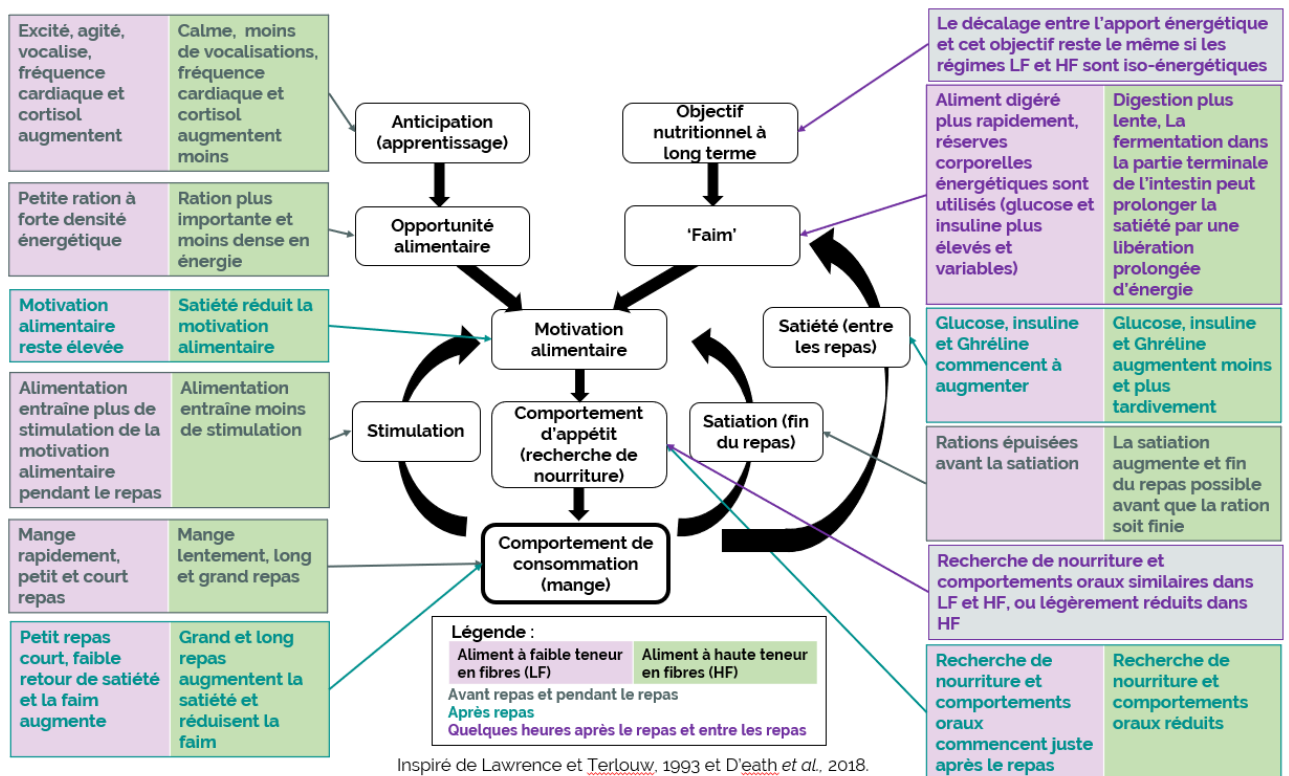


Figure 1-2 : Modèle de motivation alimentaire, de l'influence de régimes alimentaires à haute et faible teneurs en fibres à trois moments (avant et après le repas et entre les repas).

Le rationnement alimentaire est également un risque de mal-être chez la truie en gestation. Afin de limiter les problèmes d'aplomb et les problèmes à la mise-bas, l'alimentation des truies gestantes n'est pas *ad libitum*. Elle est rationnée en conformité avec les besoins nutritionnels du groupe (pas nécessairement individuel). C'est-à-dire à environ 60 à 70 % d'*ad libitum* (D'eath et al., 2018). Les aliments conventionnels de « gestation » sont souvent hautement concentrés et pauvres en fibres, afin de réduire la quantité ingérée d'aliment. De plus, leur mode

de distribution induit une rapide consommation de nourriture. Le porc est un animal qui fouisse pour chercher sa nourriture dans son environnement de vie avec son groin. C'est pourquoi naturellement la consommation est lente et par petites quantités (Lawrence et Terlouw, 1993 ; D'eath *et al.*, 2018). Ainsi, ces aliments et leur distribution ne reproduisent pas le mode d'alimentation naturel et peuvent entraîner des stéréotypies orales (léchage, morsures de barres métalliques, mâchouillements dans le vide, *etc...*) (Bergeron *et al.*, 2006). L'incorporation de fibres dans la ration (tout en maintenant une restriction sur l'énergie ingérée) permet de réduire ses stéréotypies (D'eath *et al.*, 2018, Figure 1-2). Afin de combler les besoins de recherche de nourriture, des substrats ou des objets pouvant être fouillés et mâchouillés, comme de la paille en litière, peuvent être utilisés (Hemsworth, 2021).



Ainsi, la truie gestante peut être soumise à des combats entre congénères, au rationnement alimentaire et à des problèmes de santé qui dégradent son bien-être. Ces principaux risques peuvent être atténués via le mode de logement ou des pratiques d'élevage. Afin d'évaluer le bien-être, des indicateurs et des notations en élevage existent.

1.1.3. Les indicateurs et l'évaluation du bien-être de la truie

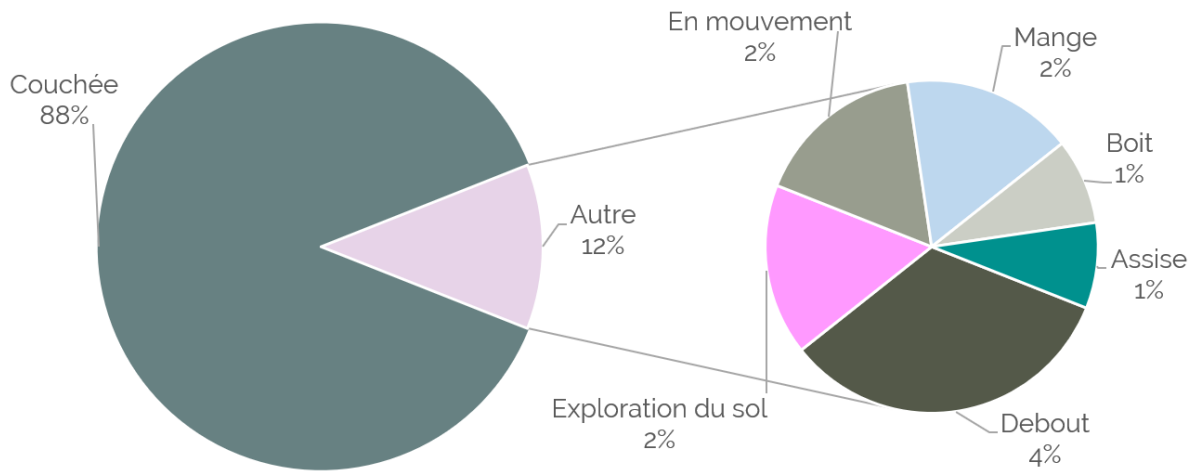
L'évaluation du bien-être, et plus particulièrement de l'état mental d'un animal est une tâche ardue en biologie (Dawkins, 2006). En effet, un comportement ou une émotion est fugace et sa perception est subjective pour l'humain. L'un des principaux risques d'incompréhension des réponses animales est l'anthropomorphisme. Par exemple, la majorité des personnes verront un porc se roulant dans la boue comme heureux, alors qu'en réalité, le porc souffre de stress thermique (Veissier *et al.*, 2009). Une émotion peut être évaluée indirectement à l'aide de ses trois composantes : cognitive, comportementale et physiologique.

Les composantes cognitive et physiologique sont principalement utilisées dans les protocoles de recherche et non d'évaluation du bien-être sur le terrain. La composante cognitive permet d'évaluer l'état affectif en testant les biais cognitifs (tels que ceux de jugement ou d'attention) de l'animal (Paul *et al.*, 2005 ; Murphy *et*

al., 2021). L'utilisation de la physiologie est reliée à la notion de stress dans de nombreuses études. Les termes émotion et stress ont de nombreuses similitudes et sont utilisés en synonyme dans la littérature (McMillan et Yeates, 2008). Le terme de « stress » peut être défini comme une réponse adaptative en fonction d'une appréciation subjective par l'animal des challenges environnementaux (Murphy *et al.*, 2021). La majorité des études du stress est axée sur des biomarqueurs des systèmes nerveux (Mormède *et al.*, 2007) et immunitaire (Guevara *et al.*, 2022).

i. Indicateurs comportementaux du bien-être

L'analyse comportementale peut être réalisée en regardant, directement ou indirectement (*via* des vidéos), en totalité ou en partie l'animal : postures spécifiques et activité physique, exploration de l'environnement, comportements sociaux. Les postures peuvent être observées afin de distinguer des signes de problème de bien-être. Les porcs passent plus de 75 % de leur temps en position couchée (Figure 1-3) et ce comportement est très important pour leur thermorégulation. En effet, l'agitation des animaux peut être un signe de manque de confort thermique ou émotionnel (Geers, 2007). L'observation et l'analyse du temps en position couchée doit être nuancée au regard d'interactions avec des facteurs endogènes (génétique du porc, âge, parité), exogènes (moment de la journée, alimentation riche en fibres, type de logement) et sociaux (incluant l'humain). Si le comportement postural donne des informations à l'échelle individuelle, la localisation du couchage en donne à l'échelle du groupe (comme des problèmes de ventilation). De plus, l'étude du temps passé dans chaque posture et de la fréquence des changements posturaux (*c.a.d.* le nombre de changement entre deux postures) peuvent être des informations précises et intéressantes pour évaluer le bien-être (Hörning, 2007). Certaines parties du corps peuvent être regardées plus en détail comme la position et les mouvements de la queue pouvant indiquer une situation stimulante, notamment chez les jeunes porcs (Reimert *et al.*, 2013).



Inspiré de Weng *et al.*, 2009.

Figure 1-3 : Budget temps des occupations d'une truie en gestation, logée en groupe avec un distributeur automatique d'aliment sur caillebotis béton.

L'exploration de l'environnement est un caractère important lié au bien-être qui est souvent relié à l'enrichissement du milieu de vie et à la recherche de nourriture (Partie 1.1.2.). Cependant, les comportements de « jeux » avec les éléments de l'environnement ne sont pas des indicateurs précis d'émotions car ils sont peu nombreux chez les adultes contrairement aux jeunes (Murphy *et al.*, 2021).

Les comportements sociaux agonistiques (relatifs à la menace, l'attaque ou la défense mais aussi la fuite ou la passivité face à une agression) sont utiles à l'évaluation des émotions lors des relations sociales. Ils sont cependant naturels dans un groupe de truies mais leur nombre et la durée des agressions peuvent être comparés entre différentes situations comme le type de logement (Velarde, 2007). Une interaction sociale entre deux truies peut être qualifiée d'agressive à la suite de ces observations : des pressions avec l'épaule, des coups avec le groin ou la tête, des morsures ou des retraites d'une des deux truies (Gonyou, 2001). Il existe également des interactions sociales dites positives, qui permettent notamment de maintenir la cohésion du groupe mais aussi une hygiène de groupe via le toilettage par un congénère (Boissy *et al.*, 2007).

D'autres indicateurs comportementaux peuvent être également explorés pour l'étude des émotions tels que les vocalisations et les expressions faciales. Les porcs sont capables d'émettre une large gamme de vocalisations face à différentes situations de stress (Marchant *et al.*, 2001 ; Manteuffel *et al.*, 2004 ; Held

et al., 2009 ; Chan *et al.*, 2011). Leur étude acoustique permet de discriminer les émotions (Villain *et al.*, 2020 ; Murphy *et al.*, 2021). Afin d'évaluer les émotions liées à la douleur, les expressions faciales peuvent être utilisées en se basant sur des « échelles de grimaces » : en regardant la position du groin, des yeux et des oreilles (di Giminiani *et al.*, 2016 ; Camerlink *et al.*, 2018).

ii. Evaluation du bien-être en élevage grâce au protocole Welfare Quality

De nombreux travaux de recherche se sont intéressés aux méthodes d'évaluations du bien-être des animaux d'élevage, à l'aide de notes ou de catégories (Murphy *et al.*, 2021). Un projet européen, Welfare Quality® (2009), avait pour objectif de produire des évaluations applicables en élevage en se basant sur les 5 domaines définis par Mellor (2017) en reclassant les 5 libertés individuelles : Nutrition, Environnement, Santé, Comportement et Etat Mental (Tableau 1-1). L'état mental est considéré comme la conséquence des autres domaines et amène à des émotions positives ou négatives. Certains des paramètres mesurés concernent des mesures de facteurs externes, comme les ressources du milieu d'élevage (en bleu dans le Tableau 1-1), pouvant modifier le bien-être des animaux et des mesures directement sur les animaux (Tableau 1-1). Les mesures sur les facteurs externes sont souvent retrouvées dans la législation ou dans certains cahiers des charges (Hemsworth, 2018 ; Forkman, 2021).

Ces évaluations peuvent être faites par des évaluateurs entraînés et généralement effectuées sur des temps d'observation courts (par exemple, une journée d'audit lors du Welfare Quality). Ce qui ne représente pas la réalité de l'état de bien-être des animaux en continu. L'éleveur est le plus à même de connaître le bien-être de chacun de ses animaux. Cependant, l'augmentation des cheptels et, ainsi, la réduction du temps disponible pour l'observation par animal nécessite des outils de suivi des animaux. C'est ici que l'élevage de précision a un rôle à jouer dans l'automatisation de l'évaluation du bien-être. De plus, la possibilité de suivre les animaux en continu (24h/24 et 7j/7) et en temps réel est un véritable avantage

pour l'éleveur pour intervenir le plus tôt possible afin d'améliorer le bien-être des animaux.

Tableau 1-1 : Protocole du Welfare Quality® (2009) pour les truies gestantes.

Domaine	Critères de bien-être	Paramètres mesurables
Alimentation	Absence de faim prolongée	Score d'état corporel
	Absence de soif prolongée	Apport en eau (abreuvoir propre et fonctionnel)
Environnement	Confort de couchage	Score de bursites Score de blessures aux épaules Pourcentage de salissure sur le corps Score d'halètement et de blottissement
	Confort thermique	Espace disponible par truie
Santé	Facilité de mouvement	Boiteries ou démarche compliquée, Plaies sur le corps, Lésions vulvaires, Mortalité, Troubles respiratoires : toux, éternuements, respiration difficile, Troubles gastro-intestinaux : prolapsus rectal, diarrhée, constipation, Troubles reproductifs : métrite, mammite, prolapsus utérin, Autres troubles : état de la peau, hernies, infections locales
	Absence de blessures	Anneau nasal et caudectomie
Comportement	Absence de douleurs induites par des procédures de gestion	Comportement social (positif et négatif)
	Expression de comportements sociaux	Stéréotypies, Comportement exploratoire
	Expression d'autres comportements propres à l'espèce	Peur de l'humain (distance d'évitement)
	Bonne relation homme-animal	Evaluation qualitative de l'état émotionnel (Actif, Apprécient, Vif, Détendu, Frustré, Indifférent, Craintif, Sociable, Irritable, Agité, Ennuyé, Sans but, Calme, Enjoué, Heureux, Content, Détendu, Angoissé, Tendu, Apathique)
	Etat émotionnel positif	

iii. Evaluation du bien-être grâce à des capteurs et des automates

Les capteurs et les objets connectés peuvent surveiller les animaux et collecter des données à différents niveaux : l'animal et l'exploitation (température ambiante, composition de l'air, *etc.*). Les capteurs non invasifs, sur ou autour de l'animal, peuvent être des microphones, des capteurs de pesée, des caméras ou des capteurs de vision. Ils sont principalement développés et utilisés pour collecter des données de mouvement, de vocalisation, de production, d'activité ou physiologiques (Neethirajan, 2020). L'identification et la traçabilité des productions animales étant demandées, chaque animal est identifié à la ferme à l'aide d'une boucle d'identification. Cette boucle peut fonctionner par radiofréquence (RFID) et être reconnue par des automates (d'alimentation ou d'abreuvement). Les données enregistrées sont ainsi attribuées à chaque animal. Les capteurs et les automates ont de faibles coûts d'acquisition et ainsi ils enregistrent rapidement une quantité importante de données de nature différente. Il peut être nécessaire de stocker ces données avec un coût parfois conséquent. Ces données sont définies par le terme "Big Data" pour le volume, la vitesse et la variabilité de celles-ci (Neethirajan, 2020).

Des informations essentielles pour l'estimation du bien-être évoquées précédemment (telles que l'activité physique) peuvent être mesurées et calculées par différents types de capteurs : automates d'alimentation, balances, accéléromètres, caméras, microphones, *etc.*

Les automates d'alimentation et d'abreuvement, associés à une identification de la truie, permettent d'enregistrer la consommation individuelle en aliment et en eau ainsi que le nombre de visites à l'automate (Kashiha *et al.*, 2013 ; Alameer *et al.*, 2020). De plus, le développement d'automates d'alimentation, avec une identification de l'animal, permet de s'assurer que chaque truie consomme bien sa ration attribuée et de limiter les « vols de ration » au sein du groupe de truies. Le rang hiérarchique au sein du groupe de truie peut être connu précisément à partir de ces données d'alimentation (Lanthony *et al.*, 2022). En outre, des études chez le veau ont montré un lien entre personnalité et comportement alimentaire (Carlake *et al.*, 2022). Le comportement alimentaire est défini comme

le nombre de visites nutritives (avec ingestion d'aliments) et le nombre de visites non nutritives (dues à la faim ou à l'ennui). Il comprend également la durée de ces visites (Matthews *et al.*, 2016).

Des balances intégrées dans les automates d'alimentation ou d'abreuvement, ou des méthodes d'analyse d'images et de vidéos (Pezzuolo *et al.*, 2018) permettent de peser ou d'estimer le poids de l'animal sans intervention humaine. La mesure de l'épaisseur de lard dorsal (ELD) via un échographe est très chronophage et difficilement automatisable. De plus, cette mesure manque de précision en raison de des biais d'observateur, de technologie, mais aussi de la latence de dépôt de graisse à cet endroit (Schinckel et Lange, 1996). La mesure de l'état corporel pourrait sûrement aussi être automatisée chez la truie via l'analyse d'images en trois dimensions, comme c'est déjà le cas chez la vache laitière (Le Cozler *et al.*, 2019).

L'enregistrement du niveau d'activité physique est rendu possible grâce à des accéléromètres ou des caméras 2D/3D. Les accéléromètres sont cependant coûteux, invasifs (boucle d'oreille assez lourde et risque d'infection possible, Hayer *et al.*, 2022) et fragiles. Cependant, leurs données sont facilement analysables en fonction de seuils, liés à une activité de mouvement rapide ou lent, par exemple (Chapa *et al.*, 2020). Contrairement aux accéléromètres, les enregistrements vidéo sont peu coûteux et non-invasifs. Néanmoins, la détection des activités réalisées manuellement est une tâche fastidieuse et chronophage, et le biais liés à l'observateur peut être important (Volkman *et al.*, 2021). L'automatisation de la détection des activités physiques des animaux à partir des vidéos est une piste prometteuse et en développement grâce à l'intelligence artificielle. Des travaux novateurs comme ceux de Labrecque *et al.* (2020) émergent, déterminant l'activité de chaque truie automatiquement. Cependant, cette approche ne peut pas être opérationnelle actuellement dans les élevages commerciaux. Les positions « couchée » et « debout » étaient les seules détectées avec une précision acceptable (respectivement de 95,6 et 91,7 %).

L'état de santé d'un animal (une des composantes du bien-être) peut être suivi à partir de différents capteurs : caméra thermique, microphone, capteurs de position, *etc...* La quantité ingérée d'aliments et le comportement alimentaire

peuvent constituer des variables d'intérêt pour évaluer l'état de santé d'un porc (Kavlak *et al.*, 2023). La température corporelle, est l'un des principaux indicateurs de troubles de santé et de stress thermique en élevage. La température cutanée peut être mesurée automatiquement et en continu grâce à des caméras thermiques placées dans la salle ou grâce à des capteurs auriculaires sur la truie (Benjamin et Yik, 2019). Les troubles respiratoires peuvent être détectés grâce à des analyses sonores distinguant les vocalisations, des toux pathologiques et non pathologiques sur des sons mesurés par des microphones dans la salle (Yin *et al.*, 2020). Les boiteries représentent un problème fréquent chez les truies gestantes, qui affectent leur démarche, leur posture et leur activité physique. Elles peuvent être identifiées grâce à des capteurs de position et des accéléromètres, des analyses vidéo, ou des capteurs d'appui de chaque membre sur le sol (Pluym *et al.*, 2013 ; Marcon *et al.*, 2020 ; Tableau 1-2).

Tableau 1-2 : Exemple de capteurs et de leurs applications pour la mesure de modifications comportementales et physiologiques des porcs (Cornou et Kristensen, 2013 ; Matthews *et al.*, 2016 ; Benjamin et Yik, 2019).

Capteurs	Catégorie	Applications
Caméra 2D/3D	Comportement et physiologie	Estimation du poids vif Détection des comportements agressifs, de la modification de la posture et de la démarche Observation du comportement social et maternel
Microphones	Sons	Détection de pic de stress, de maladies respiratoires
Imagerie thermique	Physiologie	Détection de désordres physiologiques (maladie, stress thermique, stress) et d'inflammations locales (mammites, boiteries)
Accéléromètres	Activité physique	Détection de modifications de démarche Observation du comportement social et maternel

La température et l'humidité ambiante peuvent être mesurées par des sondes d'humidité et des thermomètres disposés dans la salle de gestation. La localisation des animaux dans l'espace et leur proximité entre eux peuvent également constituer une mesure indirecte des effets de la température. Par exemple, il peut s'agir de comportements de blotissement en période froide ou d'évitement de courants d'air froid (Jackson *et al.*, 2020). La localisation des animaux, à l'échelle du groupe, est étudiée chez le porc en croissance via l'analyse d'images issues de vidéo rapportant le taux d'occupation horaire des différentes

aires de la salle (Nilsson *et al.*, 2015). La détection automatique à un niveau individuel se développe mais reste imparfaite actuellement (Alameer *et al.*, 2020b). Pour le moment, ces approches ne sont pas automatisées chez les truies en gestation. Ces avantages de l'élevage de précision pour l'évaluation du bien-être laissent envisager des perspectives de développement de nouveaux capteurs et produits sur le marché (Oczak *et al.*, 2021).



Les observations comportementales permettent d'évaluer le bien-être et peuvent être intégrées dans des évaluations globales à l'échelle d'un élevage. Les outils connectés de l'élevage de précision permettent grâce à leur diversité d'enregistrer une importante partie du registre comportemental. L'alimentation sur mesure permet de répondre à l'enjeu de nourrir au plus près de leurs besoins individuels les animaux d'élevage et dans ce sens participe à l'amélioration du bien-être animal.

1.2. L'alimentation sur mesure de la truie en gestation

1.2.1. Besoins nutritionnels au cours de la gestation

La période de gestation représente les deux tiers du cycle reproductif d'une truie. Elle constitue une période importante : pour la croissance et le développement des fœtus, pour la préparation de la mise-bas, pour la reprise d'état corporel et la reconstitution des réserves corporelles à la suite de la lactation précédente (pour les multipares), et également pour la fin de la croissance (pour les primipares).

i. Importance de l'alimentation sur le développement des embryons et de la glande mammaire

Le début de la gestation est une période critique pour la réussite de celle-ci. Le taux d'avortement autour du 15^{ème} jour de gestation est de 5 à 40 % en conditions commerciales (Langendijk, 2015). La nutrition a peu d'impacts directs sur la croissance embryonnaire avant 3 semaines. Elle a cependant une influence indirecte sur la qualité des sites d'implantation des embryons (Town *et al.*, 2004 ; Langendijk, 2015). En effet, lors des stades embryonnaires précoces et intermédiaires, elle peut modifier la concentration en progestérone, impactant les fonctions lutéales et l'environnement utérin (Athorn *et al.*, 2012 ; Gerritsen *et al.*, 2008 ; Langendijk, 2015). Par exemple, un haut niveau d'ingestion (en passant de 2 à 4 kg/jour) durant les 27^{ers} jours suivant l'implantation des fœtus réduit la progestérone systémique et impacte négativement les conditions utérines et par conséquent la survie embryonnaire (Quesnel *et al.*, 2010 ; Langendijk, 2015). Au-delà des premiers jours de gestation, il n'existe pas de consensus scientifique sur un lien entre un haut niveau d'ingestion et les niveaux d'hormones lutéales et de progestérone utérine (Langendijk and Peltoniemi, 2013 ; Virolainen *et al.*, 2005). Des études ont montré également l'importance de certains nutriments spécifiques. La leucine et la glutamine favorisent le développement des embryons au stade de blastocytes (Bazer *et al.*, 2013). L'arginine, quant à elle, favorise l'implantation et la

vascularisation du placenta (Hazeleger *et al.*, 2007 ; Novak *et al.*, 2011), ce qui a un effet sur la survie des fœtus et la taille de la portée à terme.

La glande mammaire se développe plus fortement durant le dernier tiers de gestation : développement et croissance histologiques, changement de composition et différenciation cellulaire, augmentation de l'activité métabolique (Farmer et Hurley, 2015). L'augmentation de la teneur énergétique de l'aliment (de 5,76 à 10,50 Mcal/ME) à partir du 75^{ème} au dernier jour de gestation diminue le poids du parenchyme mammaire et le nombre de cellules mammaires, ce qui implique une diminution des capacités laitières de la truie en lactation (Weldon *et al.*, 1991). Tandis qu'une augmentation des protéines ingérées (330 vs. 216 g de protéines brutes) ou de lysine (4 ou 8 ou 16 g/ jour, du 25^{ème} au 105^{ème} jour) n'a aucun impact sur la mammogénèse (Weldon *et al.*, 1991 ; Kusina *et al.*, 1999). Il est alors nécessaire de limiter les apports énergétiques en fin de gestation (pour ne pas limiter les capacités d'allaitement) mais favoriser la croissance des fœtus.




Figure 1-4 : Exemple de simulation avec InraPorc de la dynamique de partition des apports quotidiens en énergie digestible et en lysine digestible iléale standardisée pour une truie de rang de parité 2.

ii. Besoins nutritionnels et apports au cours de la gestation

Au cours de la gestation, les besoins alimentaires, et ainsi les apports alimentaires, augmentent en lien avec le gain de poids des truies et le développement de la portée et de la glande mammaire (Figure 1-4).

Tableau 1-3 : Niveaux alimentaires recommandés pour les truies gestantes à différentes parités et performances¹ inspiré de Trottier *et al.*, (2015).

Rang de parité	1		2		3		4 et plus					
Poids vifs (en kg)	140		165		185		205		205		230	
Taille de portée estimée	12,5		13,5		13,5		13,5		15,5		13,5	
Gain de poids vifs estimé (kg)	65		60		52,5		40		45		40	
Jours de gestation	<90	>90	<90	>90	<90	>90	<90	>90	<90	>90	<90	>90
Ingéré estimé ⁵ (kg/jour)	2,13	2,53	2,21	2,61	2,21	2,61	2,05	2,45	2,08	2,48	2,21	2,61
EM effective (kcal/kg) ²	3,30	3,30	3,30	3,30	3,30	3,30	3,30	3,30	3,30	3,30	3,30	3,30
EN (kcal/kg) ²	2,52	2,52	2,52	2,52	2,52	2,52	2,52	2,52	2,52	2,52	2,52	2,52
SID Lysine (%) ³	0,57	0,76	0,48	0,67	0,41	0,58	0,35	0,53	0,36	0,55	0,34	0,50
Total calcium (%)	0,67	0,91	0,59	0,86	0,54	0,79	0,51	0,78	0,51	0,82	0,50	0,75
STTD phosphore (%) ⁴	0,30	0,40	0,26	0,37	0,23	0,34	0,22	0,34	0,22	0,36	0,21	0,33

¹Valeurs calculées pour 90 % de teneur en matières sèches pour l'aliment et issues de NRC (2012) mais avec une marge de sécurité de 10 % pour les acides aminés, le calcium et le phosphore pour tenir compte d'imprécision dans la préparation de l'aliment et dans l'estimation des niveaux de performances des truies.

²Teneur en énergie dans l'aliment se rapporte aux rations à base de maïs et de soja. Les teneurs en énergie métabolisable (EM) effective sont calculées à partir des teneurs en énergie nette (EN) en utilisant les valeurs de conversion pour les truies. Pour les rations à base de maïs et de soja les teneurs en EM effective sont similaires aux teneurs actuelles en EM. Les teneurs optimales en énergie de l'aliment varient en fonction de la disponibilité et du coût d'ingrédients locaux.

³SID = Digestible idéal standardisé.

⁴STTD = Digestible dans le total tractus standardisé.

⁵Ingéré estimé avec une marge de sécurité de 5 % d'aliment gaspillé.

Les besoins alimentaires évoluent aussi selon le rang de portée, avec des apports recommandés entre 2,5 et 3,0 kg d'aliment par jour, en moyenne, pour respectivement, les truies primipares et multipares. Cependant, il existe une grande variabilité des quantités distribuées par l'éleveur. Certaines stratégies alimentaires sont ajustées en fonction de l'état corporel et du poids au début de la

gestation ou des objectifs de mise bas (Gaillard *et al.*, 2020b ; Marcon *et al.*, 2020 Tableau 1-3). L'ingestion estimée est d'environ 2,18 kg en début et milieu de gestation et 2,55 kg lors du dernier tiers de gestation, avec des variations en fonction de la parité et de l'état corporel (Tableau 1-3). L'aliment de gestation doit être ainsi composé des acides aminés essentiels (en proportion de la protéine idéale), de minéraux (tels que le calcium ou le phosphore) et avoir un taux d'énergie métabolique autour de 3,30 MJ/kg, afin de répondre à ces besoins (Tableau 1-3).

Assurer les besoins hydriques est aussi important que les apports nutritionnels au cours de la gestation mais ils sont difficiles à estimer. En effet, la consommation hydrique tient compte des variables suivantes : la quantité d'eau bue pour couvrir les besoins, la consommation d'eau supplémentaire (liée par exemple à de la potomanie) et la quantité d'eau associée à un gaspillage (visant à rafraîchir la truie ou à jouer dans le cas des plus jeunes), cette dernière étant également influencée par le débit et la forme de l'abreuvoir (Renaudeau *et al.*, 2001 ; Chen *et al.*, 2020a). Chez le porc, la consommation d'eau varie en fonction du niveau d'alimentation, de la température ambiante, du type de logement et de l'individu lui-même (Massabie *et al.*, 2014). En moyenne, dans l'étude de Marcon *et al.* (2020) les truies gestantes consomment environ $7,7 \pm 2,9$ L par jour dans le cas d'une distribution alimentaire à l'aide d'un automate et disposant d'un abreuvoir à volonté. Cette valeur est inférieure à celle mesurée par Madec (1985) chez des truies bloquées ($17,0 \pm 6,9$ L par jour). Dans les deux cas il est intéressant de noter la très forte variabilité entre les truies, avec des coefficients de variation de respectivement 39 et 41 %. D'après Kruse *et al.* (2010), la consommation d'eau et la quantité ingérée d'aliment sont corrélées positivement jusqu'à 60 jours de gestation, avec un ratio moyen de 5,8 L d'eau bue par kg d'aliment, pour une consommation totale journalière de 16,7 L.



Les besoins nutritionnels et hydriques de la truie au cours de sa gestation augmentent en lien avec la croissance des fœtus et le développement de la glande mammaire. Différentes stratégies d'apports alimentaires peuvent être mises en place pour ajuster au mieux les rations.

1.2.2. Stratégie d'alimentation de la truie gestante

Différentes stratégies d'apports alimentaires pendant la gestation existent. La plus simple est de nourrir le groupe de manière identique et pendant toute la gestation. Les truies peuvent être également allotées selon le groupe ou la catégorie à laquelle elles appartiennent : primipares/multipares, état corporel maigre/grosse. D'autres stratégies alimentaires visent à moduler l'apport au cours de la gestation, comme le principe du 'HBH' (pour Haut-Bas-Haut). Il divise la gestation en trois phases : une première avec des apports élevés pour reconstituer les réserves corporelles (suite à la précédente lactation), une seconde avec des apports plus faibles liés au développement de la glande mammaire et une troisième avec des apports élevés en lien avec la production laitière et la croissance rapide des fœtus (Silva *et al.*, 2023). Ces différentes stratégies ne sont cependant pas parfaites et amènent à des situations de sous ou sur-nutrition chez certaines truies ou à des baisses de performances (Figure 1-5 ; Domingos *et al.*, 2022 ; Silva *et al.*, 2023).

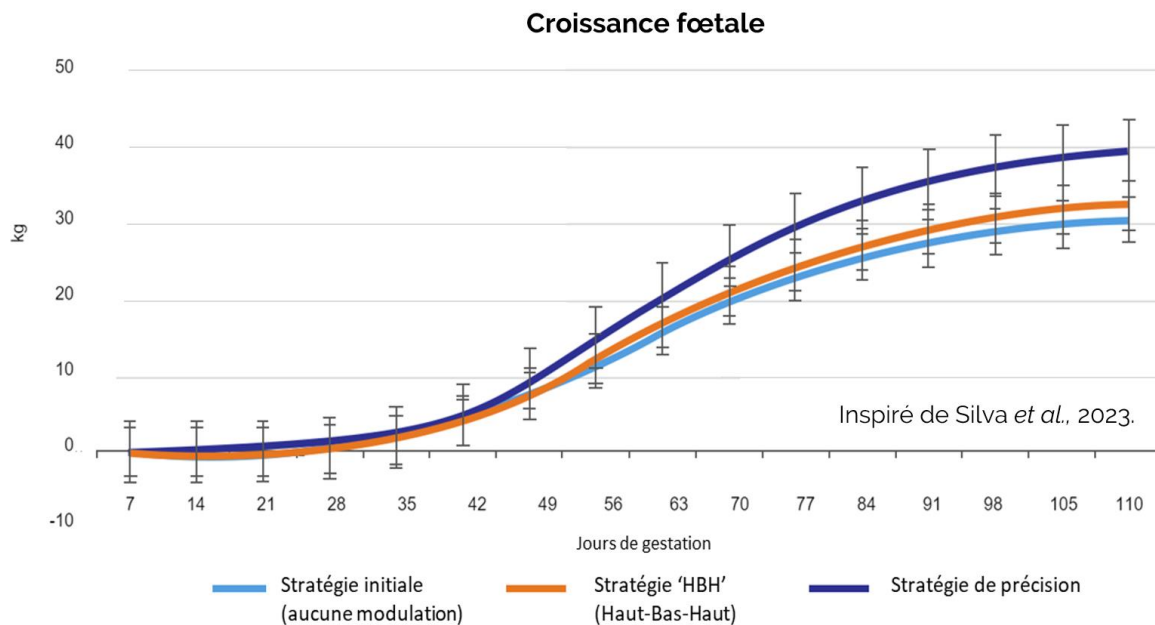



Figure 1-5 : Influence de la stratégie alimentaire pendant la gestation sur le développement des fœtus.

C'est pourquoi l'alimentation sur mesure en élevage s'est développée afin de mieux prendre en compte les besoins nutritionnels des animaux à l'échelle individuelle. L'objectif est de fournir à l'animal l'apport idéal d'aliment, en quantité et en composition chaque jour. Cette approche est particulièrement intéressante

chez la truie en gestation élevée en groupe, aujourd'hui basée sur un ajustement journalier en énergie, en lysine et en minéraux (comme le phosphore et le calcium, Gaillard *et al.*, 2020a). Au sein d'un groupe de truies, il existe une variabilité des besoins nutritionnels liée principalement au rang de portée, à l'état corporel lors de l'insémination et au stade de gestation. Le développement d'automates rend possible une distribution individualisée d'aliments, et ainsi, une réduction des situations de déficit ou d'excès des apports en nutriments et en énergie lors de la gestation des truies (Gaillard *et al.*, 2019). En effet, il a été montré que les truies nourries avec une alimentation sur mesure avaient une production laitière supérieure de 1,4 kg/jour, en lien avec une moindre mobilisation des réserves corporelles, comparé à des stratégies alimentaires de type 'HBH' (Domingos *et al.*, 2022). Il est donc important de pouvoir prédire au mieux les besoins nutritionnels individuels.

Un modèle pour les truies gestantes dérivé d'InraPorc (Gaillard *et al.*, 2019) prédit les besoins journaliers individuels en énergie, en acides aminés et en minéraux. Dans ce modèle, les besoins de la truie sont calculés selon une approche factorielle comme la somme de différentes dépenses : entretien, réserves corporelles, développement des fœtus, activité physique et thermorégulation (Figure 1-6).



ELD : Epaisseur de lard dorsal ; IA : Insémination artificielle ; MB : Mise-bas ; PV : Poids vif

Inspiré de Gaillard *et al.*, 2019

Figure 1-6 : Représentation du modèle nutritionnel des truies en gestation.

En pratique, l'estimation des besoins nutritionnels est réalisée principalement selon l'âge, le poids vif et l'ELD de la truie, mesurés lors de l'insémination ainsi que selon les objectifs à la mise bas. Le modèle intègre également une prédiction de la taille et du poids de la portée à la mise bas, fondée sur des données historiques de l'élevage et sur l'âge de la truie. Il peut aussi tenir compte de quelques autres critères, lorsque ces derniers sont disponibles, comme l'activité physique ou les conditions de logement (ex. température ambiante, mode de logement). Mais généralement, l'activité est fixée par défaut à 4 h debout pour toutes les truies, et la température ambiante est supposée rester au-dessus de la température critique basse (qui est définie à 20°C pour les truies en groupe). Ce qui n'influence donc pas le calcul des besoins (pas de besoin de thermorégulation). Une fois les besoins individuels estimés par le modèle, les apports peuvent être calculés et de nouvelles stratégies d'alimentation peuvent se mettre en place.

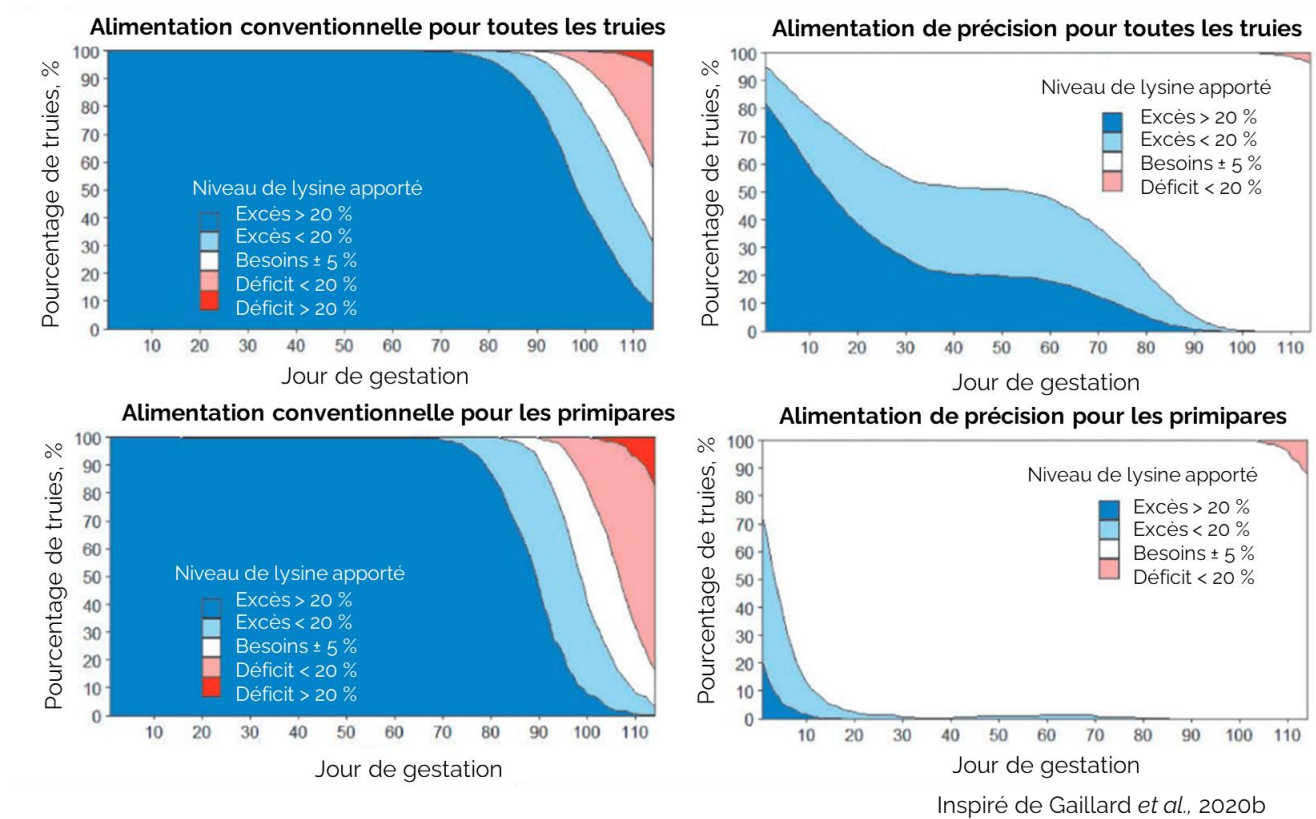


Il existe aujourd'hui différentes stratégies qui permettent de réduire le nombre de truies sur- ou sous-alimentées pendant une partie ou toute la gestation. L'alimentation sur mesure est l'une de ces stratégies, qui se base sur le stade de gestation, la parité et l'état corporel de la truie et propose un ajustement individuel, et à un pas de temps régulier, de la ration (en quantité et en composition).

1.2.3. Avantages et inconvénients de l'alimentation sur mesure

L'alimentation sur mesure est en plein essor dans le domaine de la nutrition animale car elle permet de s'engager dans la voie de la durabilité, avec un haut niveau de bien-être animal et avec un impact environnemental faible. De plus couplée avec l'automatisation, elle favorise un suivi en temps réel et une gestion intelligente de l'alimentation et des animaux afin d'améliorer l'efficacité économique. Elle contribue également à réduire le temps de travail pour l'éleveur sur certaines tâches (potentiellement remplacées par la gestion des automates) et

d'identifier précocement des stress environnementaux ou des problèmes de santé pour le porc (Pomar et Remus, 2021).



Inspiré de Gaillard *et al.*, 2020b

Figure 1-7 : Estimation de l'influence d'une alimentation sur mesure (vs. une alimentation conventionnelle) durant la gestation à partir de la proportion de truies recevant des quantités de lysine satisfaisantes, en déficit ou en excès.

Une étude de Gaillard et Dourmad (2022) montre une diminution de 25,0 % de l'ingestion de lysine et de 18,5 % de l'excrétion d'azote avec l'alimentation sur mesure comparé à une alimentation conventionnelle (nourrissant les truies en moyenne par parité et stade de gestation). L'ingestion et l'excrétion de phosphore sont également réduites respectivement de 8 et 9 %, sans dégrader les performances de reproduction (*i.e.* taille et poids de la portée). De plus, le coût alimentaire est réduit de 3,4 € par gestation, soit 8,0 € par tonne d'aliment. L'utilisation de l'alimentation sur mesure permet également de réduire l'empreinte écologique, par exemple, en diminuant l'émission de gaz à effet de serre de 6 % chez le porc en croissance (Andretta *et al.*, 2018 ; Pomar et Remus, 2021). En outre, l'alimentation sur mesure permet de répondre aux enjeux du bien-être animal en limitant la sur- ou sous-nutrition, et en optimisant la reconstitution des réserves. L'alimentation sur mesure permet de réduire les situations de déficit et d'excès

d'apport en lysine, et de manière particulièrement importante chez les primipares, comparé à une alimentation conventionnelle (Figure 1-7 ; Gaillard *et al.*, 2020b). Une étude de Cloutier *et al.* (2019) a montré qu'une alimentation sur mesure ajustée sur la lysine (réduisant les situations de déficit) pendant la gestation améliore la survie des porcelets chez les primipares à la mise-bas. En réduisant également les situations d'excès en lysine, les pertes en azote dans les urines sont alors réduites (Pomar et Remus, 2019).

Cependant, l'alimentation sur mesure doit être améliorée pour la truie gestante afin de mieux prendre en compte les minéraux. Par exemple, le calcium permet la croissance osseuse des fœtus et évite des problèmes locomoteurs chez la truie en fin de carrière. De plus, l'application de l'alimentation sur mesure à une échelle individuelle requiert : une collecte automatique des données de la ferme, et un traitement des données conforme à la stratégie de gestion établie (Aerts *et al.*, 2003; Banhazi *et al.*, 2012).

L'inconvénient majeur de l'alimentation sur mesure est son coût et la complexité de mise en œuvre dans un élevage. Une étude de Seddon *et al.*, (2013) montre une augmentation de 11 €/place de truie en lactation par an avec l'utilisation d'un automate d'alimentation, soit 12 % de plus qu'une place avec un nourrissage manuel. De plus, l'installation d'automates d'alimentation nécessite de repenser la conception du logement et d'installer de nouveaux sols, tubulaires, *etc...* ce qui implique également un surcoût économique pour l'éleveur (Schwartz, 2011). Sa mise en place requiert également du temps de travail supplémentaire afin d'habituer les truies à se nourrir avec un automate.



Une alimentation individualisée des truies gestantes est possible grâce à l'alimentation sur mesure. Elle permet de limiter le coût alimentaire et les pertes environnementales. Elle nécessite cependant d'estimer avec précision et fréquemment (ex. chaque jour, pour chaque truie) les besoins nutritionnels et leurs variations dépendantes de certains facteurs (ex. comportementaux et environnementaux).

1.3. Effet du comportement et de l'environnement sur les besoins nutritionnels de la truie gestante

Le comportement de l'animal mais aussi l'environnement sont des facteurs qui peuvent influencer les besoins en nutriments et en énergie au cours du temps et entre les animaux.

1.3.1. Comportement et état de santé, des facteurs de variation à considérer pour le calcul des besoins nutritionnels

Le comportement (ex. niveau d'activité physique, comportement social) est propre à chaque animal et peut être consommateur d'énergie ou de certains nutriments, ce qui influence *in fine* les besoins de l'animal. L'état de santé est également un facteur de variation des besoins alimentaires.

i. Niveau d'activité physique, une variabilité individuelle élevée

L'activité physique est dépendante de la parité, du stade de gestation de la truie, du type de logement et du mode d'élevage (Cornou et Lundbye-Christensen, 2008). Si le temps passé debout pour une truie en groupe a été établi à 4 h/j en moyenne (Bertin et Ramonet, 2015), il existe une variabilité entre les individus. Une heure d'activité journalière supplémentaire se traduit par une augmentation du besoin en énergie de 0,30 kJ d'EM par kg de poids métabolique ($PV^{0.75}$) et par minute (Noblet *et al.*, 1993a), soit environ 75 g/j (pour un aliment à 12,8 MJ d'EM/kg et une truie de 200 kg, Figure 1-8).

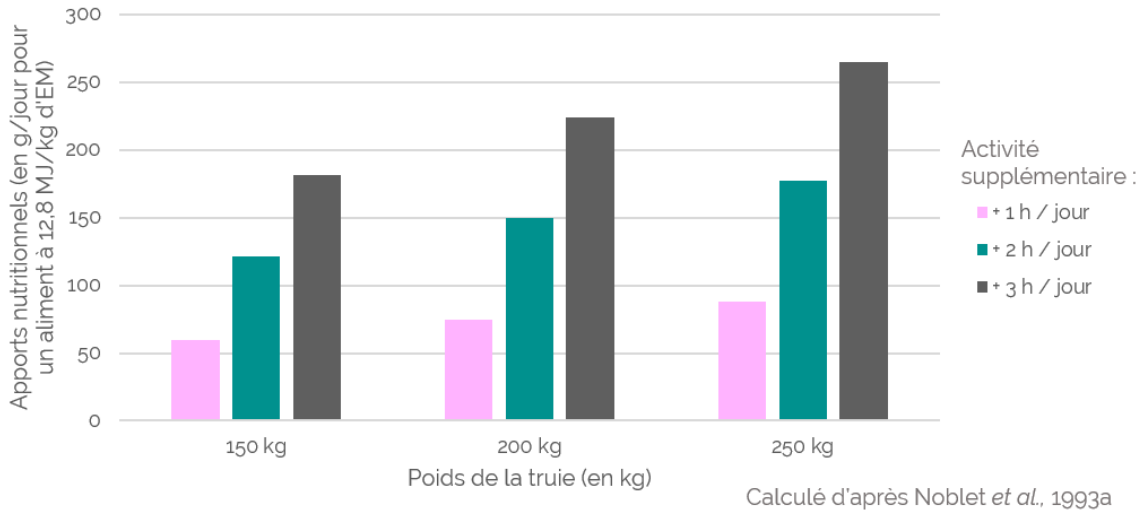


Figure 1-8 : Apports nutritionnels nécessaire pour couvrir l'activité physique supplémentaire d'une truie gestante au-delà de 4 h passées en position debout.

L'intégration de l'activité physique individuelle dans le calcul des besoins nutritionnels permet donc de gagner en précision (Dourmad *et al.*, 2008 ; Marcon *et al.*, 2020). De plus, le type d'activité doit être détaillé (debout statique, court et marche) au-delà de la simple identification de la durée passée debout. En effet, les besoins en énergie sont doublés entre la position couchée et la position debout (statique) chez la truie en gestation (Noblet *et al.*, 1993a) et doublés à nouveau entre la position debout statique et la position debout en mouvement (Marcon *et al.*, 2020). En outre, la prise en compte du nombre de changements de position pourrait également contribuer à préciser le calcul des besoins nutritionnels. Dans les conditions d'élevage de leur étude, Bertin et Ramonet (2015) observent que les truies changent en moyenne 29 fois de position sur une journée, avec une forte variabilité s'étalant de 8 à 76 fois selon les truies. Il faudrait pouvoir quantifier ce que ces changements de position représentent en termes de besoin énergétique.

ii. Comportement social et la hiérarchie

Si les porcs passent 80 % de leur temps inactifs et 10 % à manger, les autres comportements (exploration et social) représentent 10 % de leur budget temps. Cependant, cette répartition évolue au cours de la gestation, avec un peu plus de comportement social (notamment d'agression) au début de la mise en groupe (Meese et Ewbank, 1973 ; O'Malley *et al.*, 2021). Or, le comportement social peut

influencer les besoins nutritionnels des truies gestantes, principalement à cause de son effet sur l'activité physique. Une augmentation des tensions sociales, et plus particulièrement des comportements agressifs entre congénères, induit une consommation d'énergie plus importante. Plusieurs solutions, notamment alimentaires, peuvent diminuer les agressions. Par exemple, l'incorporation de parois végétales dans la ration à hauteur de 344 g de fibres par kg d'aliment (vs 176 g/kg) réduit le temps excessif d'exploration de l'environnement tout en diminuant le nombre de comportements agonistiques entre les truies (Danielsen et Vestergaard, 2001).

Le comportement social est lié au comportement alimentaire et à l'ordre hiérarchique qui régule l'accès à l'alimentation, via l'ordre d'accès au système d'alimentation (Spolder et Vermeer, 2015). Les truies dominantes bénéficient d'un accès prioritaire à l'automate d'alimentation comparé aux autres truies (Boisy, 2012 ; Lanthony *et al.*, 2022). La hiérarchie au sein d'un groupe d'animaux peut être mesurée par les relations de dominance par dyade (paire d'animaux) dans des conditions de compétition pour une ressource ou au moment des repas. Le nombre d'interactions agonistiques ou l'observation du membre de la dyade qui acquiert la ressource permet de déterminer les relations de dominance (Meese et Ewbank, 1973 ; Parent *et al.*, 2012). Ainsi, la réduction de l'accès à l'alimentation, par exemple, lorsque l'on accroît le nombre de truies par stalle d'alimentation, peut augmenter les tensions sociales (avec une restructuration de la hiérarchie) et donc modifier les besoins nutritionnels au sein du groupe de truies. C'est d'ailleurs dans la zone d'alimentation qu'ont lieu 69 % des agressions (Norrington *et al.*, 2019). La hiérarchie reste un facteur important à prendre en compte, car elle a un impact sur l'ordre de passage à l'automate d'alimentation (Lanthony *et al.*, 2022) et probablement sur l'activité physique (via les tensions sociales).

iii. Etat de santé et comportement alimentaire

L'état de santé d'un animal influence ses besoins nutritionnels tout en étant également impacté par les apports nutritionnels. Une truie malade ou en situation de mal-être diminue son ingestion ainsi que son niveau d'activité, via des modifications physiologiques et métaboliques. En effet, une baisse de la quantité

d'aliment ingéré d'environ 10 à 20 % est souvent le signe précoce d'un problème de santé ou une maladie déjà déclarée (Kyriazakis et Doeschl-Wilson, 2009). De plus, en cas de maladie, la répartition des besoins nutritionnels est modifiée, souvent en faveur du système immunitaire et en défaveur des fonctions de production (Johnson, 1997 ; Le Floc'h, 2000). Une augmentation du métabolisme basal, et par conséquent de la température corporelle, entraîne un accroissement des besoins énergétiques et une modification des voies métaboliques de synthèse des protéines (Johnson, 1997 ; Le Floc'h *et al.*, 2004). Même si les résultats divergent selon les études, les apports de protéines et d'acides aminés dans la ration pourraient jouer un rôle dans l'atténuation de ces symptômes en participant à la synthèse des protéines immunitaires (Le Floc'h, 2000), sans nécessiter la mobilisation des réserves. En effets, certains acides aminés comme le tryptophane et la thréonine jouent un rôle important dans la régulation de la réponse du système immunitaire pendant une infection, une inflammation ou en fin de gestation, ce qui peut conduire à un accroissement des besoins en acides aminés (Le Floc'h *et al.*, 2011). Toutefois ces résultats obtenus pour la plupart chez le porcelet restent à approfondir chez la truie en gestation.

Le comportement alimentaire peut varier sous la dépendance de différentes régulations physiologiques, telles que la capacité d'ingestion de l'animal, son stade physiologique et ses performances de reproduction (Friend, 1971). C'est aussi un élément informatif de l'état de santé de l'animal. Des études chez le veau ont montré que le nombre de visites non alimentaires (sans consommation d'aliment) au distributeur de lait peut constituer un indicateur de maladies, notamment digestives. Les veaux malades réduisent leurs visites à l'automate d'environ 25 % (Weary *et al.*, 2009). Une modification du nombre de visites à l'automate d'alimentation pour une truie donnée pourrait permettre d'identifier des troubles de santé (Cornou et Kristensen, 2013). En pratique, les truies en gestation sont rationnées, pour éviter un état d'engraissement excessif qui peut être délétère lors de la parturition et pendant la lactation (Dourmad *et al.*, 2021). Elles consomment généralement leur ration en une seule visite « alimentaire » par jour, de courte durée. Ce faible temps et cette faible fréquence de repas peuvent se traduire par de la faim et de la frustration et par des problèmes de bien-être identifiés notamment par le développement de stéréotypies, signes de mal-

être courants chez les truies gestantes (Dourmad *et al.*, 2021). Les visites « non alimentaires » quant à elles peuvent varier entre les truies ou lors d'épisodes sanitaires. Dans l'étude de Gaillard *et al.* (2021), les primipares ont réalisé, en moyenne, seulement 3,8 visites non alimentaires contre 4,5 pour les multipares dans les 85 premiers jours de gestation. Ainsi, l'enregistrement individuel des visites non-alimentaires est intéressant pour détecter des problèmes de santé ou de mal-être (pouvant influencer les besoins nutritionnels), à condition que ce nombre soit stable au cours de la gestation pour chaque truie.



Pour résumer, les besoins nutritionnels et le comportement alimentaire peuvent varier en fonction du niveau d'activité physique, des interactions sociales ou de l'état de santé de la truie. Cependant, l'environnement peut affecter ces facteurs mais aussi directement les besoins énergétiques.

1.3.2. Facteurs environnementaux affectant le comportement et les besoins en énergie

i. Température et humidité, influençant le confort thermique

La zone de confort thermique se définit comme une plage de températures dans laquelle la dépense énergétique pour la thermorégulation reste stable et minimale indépendamment de la température ambiante, de même que les besoins nutritionnels et les performances associées (Wegner *et al.*, 2016). Elle est incluse dans la zone de thermoneutralité, délimitée par la Température Critique inférieure (TCi) et la Température Critique d'évaporation (TCe). Pour des truies élevées en groupe, la zone de thermoneutralité se situe entre 16 et 20 °C (Verstegen et Curtis, 1988). Elle est plus élevée en case individuelle avec une TCe entre 20-23 °C (Noblet *et al.*, 1988). La TCi diminue lorsque les truies sont logées sur une litière de paille (Verstegen et Curtis, 1988). Des températures situées en dehors de cette zone de thermoneutralité peuvent entraîner diverses modifications physiologiques et comportementales, comme un risque

d'hypothermie ou d'hyperthermie, voire conduire à la mort de l'animal (Figure 1-9). Grâce au logement en groupe, pour lutter contre le froid, les truies peuvent aussi se blottir les unes contre les autres (comportement de blottissement) et ainsi limiter la déperdition de chaleur (Dourmad *et al.*, 2008) réduisant le besoin énergétique de thermorégulation.




Figure 1-9 : Modifications physiologiques et comportementales de la truie selon la température ambiante.

La TCi varie entre les truies en fonction de leur poids et de leur ELD : elle diminue lorsque le poids et l'ELD augmentent. Le niveau alimentaire influence également la production de chaleur interne et donc la TCi. Holmes et Close (1977) ont ainsi estimé qu'une truie maigre de 140 kg devrait consommer 59 g/j d'aliment supplémentaire (à 12,1 MJ d'EM par kg d'aliment) pour compenser 1 °C de froid contre seulement 34 g/j pour une truie de même poids vif mais avec un état corporel plus gras. Pour des truies de même poids, l'ingestion joue également un rôle dans la variabilité de la TCi. Un bas niveau d'ingestion conduit à une moindre production d'extra chaleur, entraînant une TCi plus élevée et ainsi une plus grande

sensibilité au froid (Holmes et Close, 1977). Pour compenser la perte de chaleur, les apports énergétiques journaliers peuvent être augmentés. Il n'y a pas d'études montrant que la composition des rations en acides aminés ou en minéraux des truies gestantes peut influencer la TCi.

Dans la zone de stress thermique chaud, la température corporelle et la fréquence respiratoire augmentent (Schild, 2018). Dans la littérature, très peu de données sont disponibles pour la truie en gestation, qui se trouve très rarement dans cette situation, du fait du rationnement alimentaire qui accroît la TCe, tandis que c'est fréquemment le cas chez la truie en lactation nourrie à volonté (Renaudeau *et al.*, 2001). Il est observé que les truies ont tendance à baisser leur niveau d'activité en cas de stress thermique chaud.

L'humidité relative peut modifier l'effet de la température et doit donc être considérée conjointement à celle-ci. Lorsque l'humidité augmente, la température ressentie s'accroît également en situation de température élevée (Holmes et Close, 1977). Pour les températures basses, il est fréquent d'observer des phénomènes de condensation entraînant des parois et des sols humides défavorables au confort thermique des animaux. L'Index Température-Humidité (THI) peut être utilisé pour évaluer le niveau de stress thermique d'un animal, notamment chez la truie (Wegner *et al.*, 2016). Ainsi, au-delà d'une valeur de THI de 74, Wegner *et al.* (2014 ; 2016) observent des effets défavorables sur le taux de fécondation des truies et sur la survie des porcelets à la naissance.

ii. Qualité du logement : sol et air

Les effets du logement sur les besoins nutritionnels et la santé ont surtout été évalués chez le porc en croissance (logé en groupe), mais on peut supposer que ces résultats peuvent également concerner les truies gestantes.

La nature du sol, et plus particulièrement, le type de litière impacte le bien-être et l'activité physique des porcs. Il influence également la déperdition de chaleur des animaux et la TCi, modifiant les besoins énergétiques. Le logement sur paille augmente le comportement de fouille et d'exploration, ce qui accroît les besoins nutritionnels, du fait de l'élévation du niveau d'activité physique (Meunier-

Salaün *et al.*, 2001). Mais ce type de logement diminue la dépense d'énergie liée aux comportements anormaux comme les stéréotypies, réduites en présence de paille. Ainsi, l'efficacité alimentaire peut être améliorée, tout comme le bien-être des animaux (Le Floc'h *et al.*, 2021). En effet, la dépense énergétique liée à l'activité supplémentaire peut s'équilibrer avec la dépense réduite liée aux potentielles stéréotypies. L'apport supplémentaire d'énergie issu de l'ingestion de paille est considéré comme nul (Noblet *et al.*, 1993b). Cet équilibre a cependant une forte variabilité due au type de litière (profonde ou superficielle) et au niveau d'activité de l'individu (Croney et Millman, 2007).

L'espace au sol disponible par animal est un facteur primordial pour les performances, la santé et le bien-être des truies. En Europe, la surface minimale au cours de la gestation est de 2,25 m² par truie, avec une adaptation selon le nombre d'animaux logés ensemble. Salak-Johnson *et al.* (2007) ont montré que les truies disposant d'un espace de 1,4 m² par animal présentaient un score de lésion plus élevé par rapport à celles disposant d'un espace de 2,3 ou 3,3 m² (au sein d'un groupe de 5 truies). L'augmentation de l'espace disponible par truie (3,3 vs. 1,4 m²) peut également avoir un effet positif sur leur poids vif, leur ELD, et la taille de leur portée (Salak-Johnson *et al.*, 2012). Il est aussi intéressant de noter qu'une augmentation de l'espace par truie entraîne :

- une diminution des agressions et des blessures associées (liées à des zones de fuite plus importantes),
- une modification des réponses comportementales (ex. interactions sociales positives, mastication dans l'air),
- une augmentation de l'activité physique (ex. temps passé debout ou à boire) et du statut immunitaire (ex. ratio de cellules immunitaires, Salak-Johnson *et al.*, 2012).

Cependant, il est nécessaire de mettre ce facteur en relation avec le nombre de truies par groupe, qui peut également faire varier la fréquence et le nombre d'agressions pour une même densité au m² (Spoolder et Vermeer, 2015), les possibilités de fuite étant plus élevées dans les grands groupes.

Les taux d'ammoniac et de dioxyde de carbone dans l'air impactent fortement la santé et les performances des animaux (Choi *et al.*, 2011). Chez le porc à l'engraissement, l'exposition à des niveaux élevés de ces gaz diminue l'appétit et en conséquence, le gain moyen quotidien. En été comme en hiver, une vitesse d'air de 0,5 m/s est recommandée pour les truies gestantes (IFIP, 2019). L'augmentation du renouvellement de l'air et d'évacuation de l'air vicié favorise la consommation d'aliment et la croissance des animaux. Il faut cependant tenir compte de la configuration du bâtiment et le nombre d'animaux. Une ventilation trop élevée accroît la déperdition de chaleur et les risques de courant d'air. En l'absence de chauffage, en période hivernale, elle s'accompagne d'un accroissement des besoins énergétiques de thermorégulation conduisant à une dégradation de l'efficacité alimentaire (Massabie *et al.*, 1997). De même une mauvaise conception des entrées d'air peut être problématique en cas de coulées d'air froid tombant sur les animaux, en situation de sous-ventilation hivernale. Le niveau de ventilation affecte aussi le comportement, l'activité, et la santé respiratoire des animaux. Ces résultats laissent donc penser que les besoins nutritionnels pourraient être modifiés chez la truie en gestation selon la qualité de l'air et les modalités de ventilation. La prise en compte de l'activité physique des truies, de la température et de l'humidité de l'air constituerait une première approche pour intégrer les effets du logement dans les modèles nutritionnels.

iii. Influence de la lumière et du bruit

Peu d'études se sont intéressées à l'influence de la durée d'éclairage sur les besoins nutritionnels des truies gestantes. Chez la truie en lactation, Stevenson *et al.* (1983) ont montré qu'une augmentation du temps de luminosité se traduit par un poids de portée plus élevé au sevrage et un retour en chaleur plus rapide après sevrage. Cependant, aucun effet n'a pu être montré sur le poids vif ou sur l'ingestion chez la truie dans cette étude. Une étude a été réalisée chez le porc à l'engraissement par Baldwin et Start (1985) sur la motivation à l'obtention de lumière supplémentaire. Elle a mis en évidence que des porcs, soumis à l'obscurité et entraînés à allumer et éteindre la lumière, actionnaient un interrupteur pour obtenir entre 1,5 et 2,0 h de lumière supplémentaires par jour. À l'inverse, les porcs

exposés à une lumière continue n'actionnaient pas l'interrupteur pour obtenir des périodes d'obscurité. En outre, une étude chez le porc en croissance démontre que le passage de 8 à 14 h d'éclairage artificiel réduit le nombre de stéréotypies ou le temps passé à une exploration excessive du sol (Martelli *et al.*, 2005). L'effet de la lumière sur l'activité physique et les besoins nutritionnels mériterait donc d'être évalué chez la truie en gestation.

Le niveau sonore impacte le comportement et la physiologie des animaux, via une action sur les hormones du stress (Turner *et al.*, 2005). Le système d'élevage a un effet direct sur le niveau sonore dépendant, du système d'alimentation (type d'entrée ex. à bascule, présence et nombre d'automates) ou de logement (ventilation, type de sol, Wegner *et al.*, 2019). Chez le porc, une exposition au-delà de 100-135 dB entraîne une diminution de l'ingestion, du gain de poids mais aussi des performances de reproduction (Manci *et al.*, 1988). La législation européenne impose un seuil maximal de 85 dB pour le niveau sonore dans les bâtiments d'élevage. Le niveau sonore modifie également à court terme l'activité et le comportement social des porcs, impactant leurs besoins nutritionnels (Talling *et al.*, 1996 ; Otten *et al.*, 2004). Cependant, sur le long terme, il semble y avoir un effet d'habituation des porcs à un niveau sonore constant, continu et identique sur une période donnée (Kittawornrat et Zimmerman, 2011). C'est pourquoi lorsque l'on étudie l'effet sonore, il convient de distinguer le type de son : continu ou soudain, habituel ou imprévu, la fréquence et l'intensité de celui-ci (Talling *et al.*, 1996).



Tout comme les facteurs comportementaux, les conditions d'élevage (ex. température et humidité de la salle, niveau sonore) doivent être prises en compte pour prédire les besoins nutritionnels chez la truie en gestation. Leur influence doit être quantifiée plus précisément afin de les inclure dans les modèles nutritionnels existants.

1.4. Apport du machine learning pour l'étude du comportement et l'alimentation sur mesure

Au-delà de l'alimentation sur mesure, l'élevage de précision, d'une manière générale, s'est développé depuis plusieurs années. L'utilisation des nouvelles technologies et de l'intelligence artificielle a rapidement progressé, avec des perspectives d'application en élevage porcin. Des capteurs innovants mesurent des variables relatives au comportement (ex. alimentaire, abreuvement, activité) de l'animal, et à l'environnement d'élevage (ex. température ambiante, qualité de l'air). Les données générées par ces capteurs peuvent ensuite être traitées par des méthodes d'apprentissage automatique comme par exemple, des réseaux de neurones pouvant détecter automatiquement l'activité des animaux à partir d'enregistrements vidéo (Benjamin et Yik, 2019). L'estimation de cette activité physique permet d'enrichir les informations disponibles pour le calcul des besoins énergétiques.

1.4.1. Les algorithmes de machine learning et leurs performances

i. Différents types d'algorithmes pour différents objectifs

L'apprentissage automatique (ou machine learning - ML) devient de plus en plus employé pour l'étude du comportement animal et de son environnement de vie. Les algorithmes de ML sont généralement considérés comme des "approximateurs universels" qui simulent le comportement sous-jacent d'un système. Le but du ML est ainsi d'extraire de la connaissance à partir de données, afin de reproduire une tâche, à l'aide d'un modèle représentant la réalité. Ces modèles permettent ensuite de reproduire la tâche ou de prendre des décisions sur de nouvelles données.

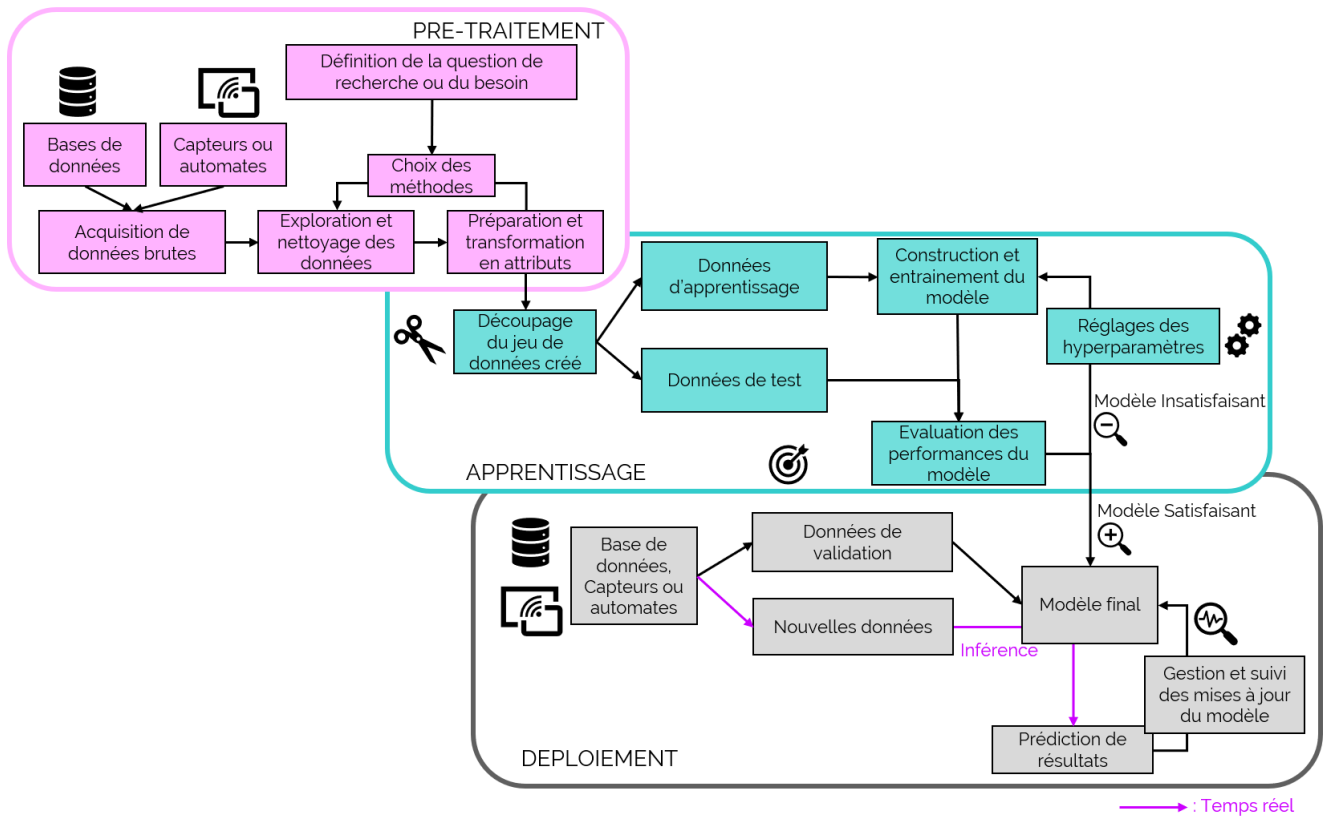


Figure 1-10 : Schéma du fonctionnement d'une démarche en machine learning.

Une approche classique en ML peut être découpée en trois phases : Pré-traitement, Apprentissage et Déploiement (Figure 1-10). La première étape concerne le pré-traitement de données brutes et représente les trois quarts du temps d'un projet de ML. Cette phase d'exploration et de nettoyage des données est l'une des plus importantes. Il s'agit d'éliminer des anomalies, comme des valeurs manquantes, dupliquées ou erronées, afin d'obtenir des données appropriées pour l'entraînement des modèles de ML. Des données mal préparées peuvent, en effet, conduire à des modèles inefficaces ou biaisés. Un pré-traitement adéquat peut grandement influencer les performances et la fiabilité des modèles appris. Le choix des méthodes de machine learning à utiliser par la suite est dépendant du besoin, de la tâche à réaliser, mais surtout du type de données. La dernière étape du pré-traitement est de préparer le jeu de données en créant ou transformant les données brutes en attributs avec des étapes telles que la normalisation, l'agrégation temporelle, la gestion des données déséquilibrées si besoin est. Les attributs correspondent aux variables (ou « features » en anglais) qui seront utilisées par la suite, dans l'étape l'apprentissage, et leur pré-traitement peut se faire de manière itérative afin de sélectionner des données de qualité

permettant d'améliorer les performances des algorithmes. Leur création et leur choix dépendent de l'expertise dans le domaine mais aussi du besoin recherché.

Le processus d'apprentissage, qui est au cœur des algorithmes ML, est basé sur un ensemble de données appelé "jeu de données d'apprentissage". La performance et l'efficacité du modèle sont ensuite évaluées sur un autre jeu de données : "jeu de données de test". Ces deux jeux de données sont souvent basés sur la répartition des données expérimentales : environ 70 % pour l'ensemble d'apprentissage et 30 % pour l'ensemble de test. Une autre méthode de découpage de données, la validation croisée, est utile pour les jeux de données de petite taille. Elle utilise les jeux de données d'entraînement et de test pour l'évaluation des performances et vise à réduire le sur-apprentissage. Selon les pratiques, il peut y avoir une troisième partition appelée "jeu de données de déploiement" ou "de validation". Ce jeu de données est utilisé pour ajuster les hyperparamètres lors de la mise en place opérationnelle du modèle déjà appris et évalué sur données d'apprentissage et de test.

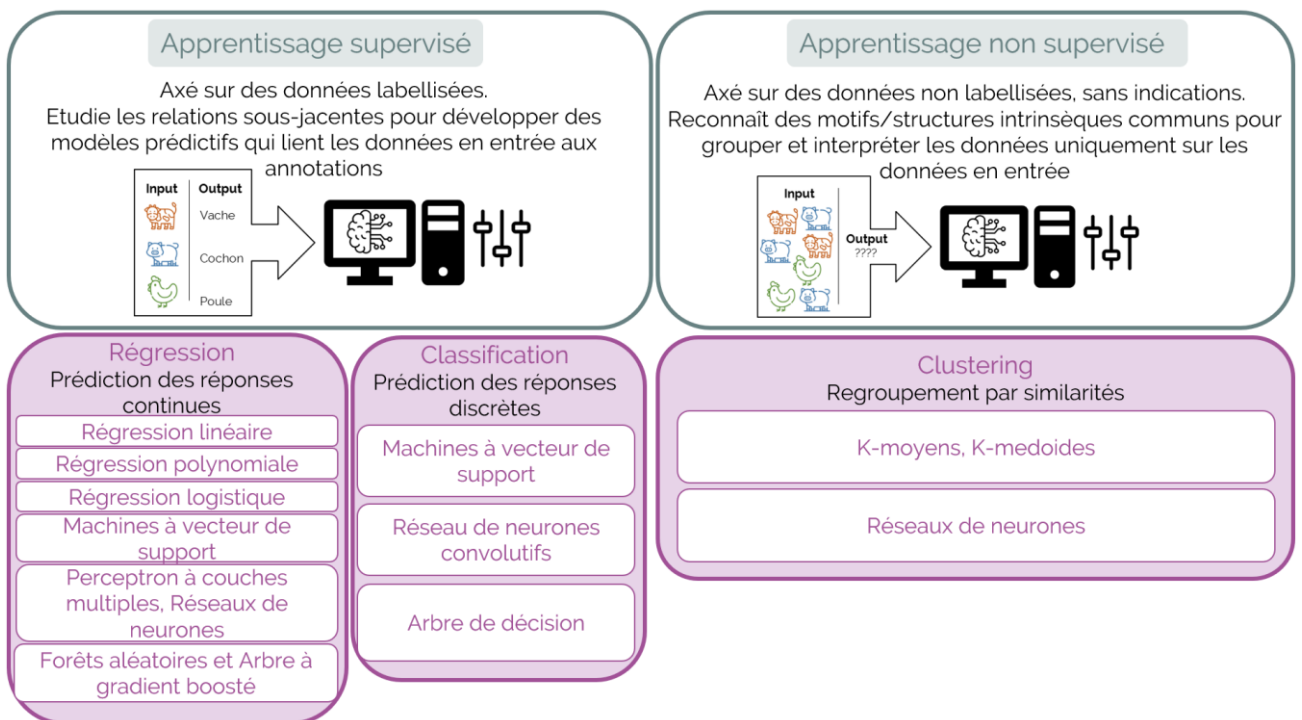


Figure 1-11 : Méthodes et algorithmes de ML utilisés dans la suite de la thèse (Liakos et al., 2018).

Le ML comprend une grande variété d'algorithmes qui peuvent être classés en catégories : supervisé et non supervisé (Figure 1-11), ainsi que d'autres méthodes

moins courantes dans le domaine de l'agro-écologie (apprentissage semi-supervisé, apprentissage par renforcement, *etc.*). La principale différence de principe entre les techniques supervisées et non supervisées, réside dans l'utilisation de données étiquetées pour l'apprentissage dans le cas de l'apprentissage supervisé. Dans ce cadre, l'algorithme est guidé par les informations connues, ce qui facilite l'apprentissage.

Il existe deux grandes catégories de méthodes supervisées : la régression permettant de répondre à des tâches de prédiction, et la classification qui regroupe des individus partageant des caractéristiques similaires (Figure 1-11). La principale caractéristique des méthodes supervisées est qu'elles nécessitent des étiquettes sur des données numériques pour l'entraînement des algorithmes. Ce sont aujourd'hui ces méthodes qui produisent les meilleures performances. L'annotation des données permet d'informer, pour le jeu de données d'entraînement, la valeur « cible », c'est-à-dire la « bonne réponse » pour un expert humain, celle que l'on souhaite que l'algorithme de ML apprenne. Ces annotations, dans le domaine de l'alimentation sur mesure et du comportement (ex, à partir d'enregistrement vidéo), sont réalisées manuellement par des experts du domaine et nécessitent par conséquent des moyens importants en temps et en compétences.

L'apprentissage profond (ou Deep Learning - DL) est un sous-domaine du ML. Il est basé sur de réseaux neuronaux artificiels à couches multiples qui construisent des modèles inspirés à l'origine de la structure du cerveau humain. Jusqu'à présent, la grande majorité des algorithmes de DL appliqués fonctionnent de manière supervisée. Il a été démontré que ces algorithmes ont des performances exceptionnelles dans divers domaines car ils peuvent traiter des tâches extrêmement complexes (notamment dans la reconnaissance d'images). Cependant, ils nécessitent un grand ensemble de données d'apprentissage mais aussi de données étiquetées, ce qui est généralement coûteux en temps pour l'étape d'annotation et ces méthodes requièrent de fortes puissances de calcul pour l'apprentissage.

Si les performances sont satisfaisantes avec les jeux de données de validation, la dernière étape d'un processus de ML est le déploiement en

conditions opérationnelles. Les hyperparamètres sont ajustés à l'aide du jeu de données de déploiement. Une fois le modèle validé, il peut être utilisé dans un cadre opérationnel. L'inférence consiste donc, à partir de données réelles à réaliser la tâche (prédiction, classification, clustering, *etc.*), pour laquelle l'apprentissage a été effectué, c'est-à-dire en s'appuyant sur le modèle appris. Afin de pérenniser et d'adapter le modèle à des légers changements possible au cours du temps, une phase de gestion et de suivi du modèle est nécessaire. Il s'agit de mettre à jour le modèle avec des nouvelles données (afin de renforcer les performances), de vérifier que les systèmes informatiques fonctionnent toujours malgré les mises à jour ou les évolutions de ceux-ci.

Une des approches de référence pour l'utilisation du machine learning pour l'élevage de précision est celle de Alameer *et al.* (2020) pour la détection de problèmes de santé chez le porc en croissance, à une échelle individuelle. Il s'agit d'un système automatisé d'analyse d'images, à partir de nombreuses observations reportées manuellement (113 379 images annotées), et d'un algorithme de ML (un réseau de neurones convolutifs) recensant des changements dans les comportements d'activités (debout, couché et assis) et d'abreuvement du porc avec de très bons résultats.

Lorsque des données étiquetées ne sont pas disponibles (trop coûteuses ou manque d'expertise), des méthodes de ML non supervisées sont appliquées. L'objectif du « clustering » est un exemple de méthode non supervisée qui permet de partitionner les données en groupes cohérents dans lesquels les éléments d'un groupe partagent des caractéristiques similaires et dont les groupes se distinguent le plus possible les uns des autres. Une illustration en élevage peut être de regrouper des animaux partageant des schémas comportementaux semblables. Par exemple, Gauthier *et al.* (2021) ont utilisé une méthode de clustering sur des séries temporelles d'ingestion alimentaire de truies en lactation. Cela a permis de regrouper des truies qui partagent le même type de comportement alimentaire, et d'inférer des prototypes de courbes d'ingestion. Ces prototypes sont ensuite utilisés, en temps réel, dans le but de prédire la ration et la composition de l'aliment à distribuer. Aujourd'hui malgré les difficultés rencontrées pour collecter suffisamment de données étiquetées nécessaires à l'utilisation de méthodes

supervisées, seules quelques études ont utilisé des méthodes non supervisées (Lokhorst *et al.*, 2019).

ii. Analyse des performances des algorithmes

Concernant l'évaluation des méthodes de ML, les performances des algorithmes doivent être testées lors de la phase d'apprentissage et de déploiement. L'obtention du meilleur modèle se fait par l'évaluation et la comparaison des modèles avec différents paramètres, différents algorithmes, selon une variété de pré-traitements et de découpages du jeu de données, *etc.* L'évaluation nécessite également d'être réalisée dans des conditions proches de celles d'usage, comme en fermes commerciales porcines pour notre domaine. En effet, pour un algorithme reposant sur de l'analyse d'images, les problèmes suivants peuvent affecter ses performances : les regroupements d'animaux au sein desquels il est plus difficile d'identifier les individus, les variations de luminosité, *etc.* Tandis que pour un algorithme analysant les émissions sonores, il faudra faire face à des bruits parasites liés au fonctionnement de l'élevage (bruit d'automate d'alimentation, de tracteur, *etc.*).




Figure 1-12 : Matrice de confusion et métriques de reconnaissance d'images de chien et de chat entre les prédictions d'un algorithme (étiquettes) et la réalité (images).

Les performances et la précision de prédiction des méthodes ML peuvent être évaluées à l'aide de différentes métriques utilisant des méthodes statistiques. En ce qui concerne les méthodes supervisées, la matrice de confusion (Figure 1-12), est l'une des représentations les plus couramment utilisées, car aisée à lire et à comprendre, puisque reposant sur des données de test étiquetées. Elle a pour objectif de mesurer l' « accuracy » d'un algorithme de classification qui représente le pourcentage de valeurs bien prédites (équation dans la Figure 1-12, exprimée en % ou entre 0-1). La précision et le rappel (équations dans la Figure 1-12) sont d'autres métriques utilisées pour évaluer les performances du modèle appris. Le choix entre celles-ci est un compromis qui dépend du type de problème à résoudre. La précision est utile pour estimer le taux de prédiction des vraies valeurs positives (la proportion d'éléments positifs correctement prédits positifs) alors que le rappel s'intéresse aux faux négatifs (éléments positifs non prédits comme tels). Le rappel (aussi appelé sensibilité) est particulièrement important, par exemple, pour la détection des maladies (afin de ne pas écarter des animaux réellement malades). La spécificité est aussi intéressante à évaluer, car il s'agit de la proportion de vrais négatifs prédits. L'évaluation de modèles de ML prédisant des valeurs numériques comme le modèle de régression repose sur le calcul de l'erreur (la distance entre la valeur prédite et la valeur réelle). Pour toutes ces métriques, plus la valeur est élevée, plus l'erreur du modèle de régression est importante.

Aujourd'hui parmi toutes les méthodes envisageables, seules les méthodes supervisées proposent des résultats suffisamment fiables permettant une exploitation en conditions opérationnelles. Cependant certaines solutions non-supervisées, sur un certain type de données (séries temporelles), émergent peu à peu (Gauthier *et al.*, 2021). Pour chaque environnement, exploitation et type d'animaux, il est nécessaire de disposer de données étiquetées afin que l'apprentissage du modèle soit adapté aux conditions d'utilisation. Ce prérequis est une limitation forte puisqu'il est difficilement envisageable de demander aux éleveurs d'annoter de nombreuses données, en particulier les images.




Les techniques de machine learning permettent aux ordinateurs d'apprendre à partir des données afin de répondre à une tâche précise puis d'utiliser ces modèles pour deviner des cas qui n'ont pas encore été décrits. Ces techniques par leur diversité permettent de réaliser un certain nombre de tâches telles que la régression, la prédiction, ou la classification. L'une de leurs applications peut être l'analyse du comportement des porcs.

1.4.2. Exemples de l'utilisation du machine learning : évaluation du comportement, du bien-être et de l'état de santé

Les études sur l'élevage de précision ont introduit l'utilisation possible de capteurs pour la détection des problèmes de bien-être, tels que les boiteries ou les infections respiratoires. Sur la base des données de capteurs, il a été démontré que l'utilisation de méthodes statistiques classiques est limitée en raison de l'hétérogénéité des données (sons, images, *etc.*). Les méthodes de ML pourraient donc aider à mieux identifier des indicateurs de comportement et de bien-être pour ensuite les intégrer dans des modèles d'estimation des besoins (Dawkins, 2006).

Avant d'analyser le comportement alimentaire ou d'abreuvement d'un animal, il faut tout d'abord identifier et tenir compte d'un schéma comportemental, variant selon le cycle circadien (Figure 1-13). En effet, des variations de comportements ont lieu au cours de la journée avec des phases d'alimentation, de repos, *etc.* De plus, en ce qui concerne les truies, il est également important de prendre en considération certains critères individuels, comme le rang de portée et le rang hiérarchique. Les truies multipares ont généralement accès aux automates d'alimentation et aux abreuvoirs avant les primipares ou plus généralement avant les truies de rang hiérarchique bas au sein du groupe.



Inspiré de Kruse *et al.*, 2011

Figure 1-13 : Consommation d'eau et ingestion alimentaire totale au sein d'une bande de truies gestantes, en fonction du moment de la journée.

La principale difficulté dans l'analyse du comportement d'un animal consiste donc à définir un niveau basal spécifique à chaque truie de façon à pouvoir par la suite identifier des variations indicatrices de situations particulières. Dans les exemples décrits ci-dessous, le ML est utilisé afin de détecter l'inconfort thermique et prédire la température corporelle des porcs pour améliorer leur bien-être.

i. Localisation des porcs pour détecter des problèmes de confort du logement

Dans une salle, en raison de perturbations potentielles du chauffage et de la ventilation, des zones d'inconfort thermique peuvent apparaître. L'éleveur peut détecter ces zones en observant le regroupement et la localisation des animaux dans des zones spécifiques (Pedersen, 2018) : identification d'espaces vides, de porcs couchés dans la zone d'urine/de fèces. Cowton *et al.* (2019) utilisent des méthodes de DL pour suivre et localiser chaque porc dans l'enclos, en temps réel, à l'aide d'une simple caméra. Le système développé est initialement composé d'un

algorithme de détection des porcs sur chaque image (un réseau de neurones convolutifs), puis d'un algorithme de suivi capable de suivre chaque porc entre les images (un autre réseau de neurones convolutifs). Le système de suivi utilise une métrique d'association apprise afin de détecter si un porc apparaît ou non sur deux images différentes (tâche de ré-identification).

Dans la phase d'apprentissage de cette étude, un transfert de modèle a été utilisé, afin de maximiser les performances. Le transfert de modèle (transfer learning) est une technique de machine learning qui consiste à utiliser un modèle déjà pré-entraîné sur une tâche et à s'en servir comme point de départ pour une tâche similaire. Ainsi, un réseau de neurones déjà pré-entraîné sur une base de nombreuses images généralistes a été spécialisé avec des images de porcs. Ce nouveau jeu de données a été annoté manuellement. Puis, il a été divisé en trois parties : une pour la détection des porcs (1 646 images), une autre pour le suivi des cochons dans l'espace et le temps (une seule vidéo de 7,8 min, 4 images par seconde) et une dernière pour ré-identifier les porcs (5 653 images avec 25 identités de porcs). Ce dernier jeu de données contenait des images prises dans des bonnes et mauvaises conditions environnementales (par exemple, des groupes denses de porcs dans de petits espaces, un mauvais éclairage dans un environnement poussiéreux, des similitudes de forme entre les porcs) pour renforcer les performances du système.

La précision moyenne des performances de détection était comprise entre 85 % (pour les conditions de faible éclairage) et 91 % (pour des porcs densément logés et une lumière surexposée). La précision de détection des porcs était de 92 %, avec une précision moyenne de 86 % pour la tâche de ré-identification. Cette étude offre de nouvelles perspectives pour la détection, le suivi et la localisation de porcs logés en groupe dans des fermes commerciales, à l'aide de caméras à faible coût. De plus, le système ne nécessite pas de matériel supplémentaire (comme des étiquettes d'identification) ou d'aides visuelles pour identifier les porcs (comme des marques d'identification sur le dos des porcs). En effet, la problématique de cette étude est à l'échelle du groupe et non individuelle.

ii. Prédiction de la température corporelle de porcelets

La température corporelle est souvent utilisée comme indicateur de maladies, notamment d'infections, ou de troubles physiologiques tels que le stress thermique. Dans l'étude de Gorczyca *et al.* (2018), l'objectif était de prédire la température corporelle (rectale, de surface de la peau et du pelage) de porcelets à partir des variables environnementales de la maternité (intensité de la chaleur d'appoint, température de l'air, *etc.*). Les performances de prédiction de quatre algorithmes de ML (modèle linéaire généralisé, gradient boost machine, forêts aléatoires, réseaux neuronaux profonds) ont été comparés. Le gradient boost machine et les forêts aléatoires sont des méthodes d'apprentissage qui combinent des petits modèles tels que les arbres de décision pour construire de manière itérative le système de prédiction.

Les ensembles de données ont été composés de 173 observations en combinant les variables environnementales prédictives et les trois températures des porcelets à prédire. La température rectale a été mesurée avec une sonde de température dans le rectum. La température de la surface de la peau a été mesurée sur la partie supérieure de la patte de l'animal avec une sonde de température de la peau. La température du pelage a été mesurée sur la même zone avec un thermomètre infrarouge.

Les résultats de la prédiction étaient fiables avec les variables environnementales, sauf pour le modèle linéaire généralisé. Les réseaux neuronaux profonds ont été capables de prédire très précisément la température rectale avec un pourcentage moyen d'erreur absolue (MAPE) de 0,36 %. Le gradient boost machine a été capable de prédire la température de la peau avec un MAPE de 0,62 %. La méthode des forêts aléatoires a permis de prédire la température du pelage avec un MAPE de 1,35 %. L'ajout d'autres variables environnementales (taux de ventilation, densité de porcs, *etc.*) pourrait permettre d'améliorer ces résultats intéressants. L'approche ML pourrait ainsi prédire la température corporelle exacte de l'animal et déterminer si l'animal est malade ou s'il subit un stress thermique à l'échelle individuelle (Soerensen et Pedersen, 2015).



Améliorer le bien-être des animaux en intégrant des informations ou des connaissances extraites des données fournies par les capteurs, présents sur les exploitations, est une solution en plein essor. Aujourd'hui, les techniques de ML sont les plus efficaces pour extraire ces connaissances des données de capteurs et proposent des solutions prometteuses pour le bien-être. Ces méthodes peuvent également s'appliquer à d'autres domaines comme la nutrition.

1.4.3. Apport du machine learning pour l'alimentation sur mesure

Ces innovations en termes d'algorithmes et de données collectées permettent d'envisager une évolution des modèles nutritionnels actuels en intégrant ces nouvelles variables dans le calcul des besoins en temps réel (Figure 1-14). L'intégration de données en temps réel à l'échelle de la journée, comme le poids ou le niveau d'ingestion des animaux, améliorerait également la précision des calculs du modèle. Le ML pourrait également être utilisé pour remplacer un modèle mécaniste traditionnel et prédire les besoins nutritionnels. Quelle que soit la méthode de prédiction des besoins, les apports alimentaires pourraient être ajustés aux besoins réels de l'animal en temps réel, grâce à des systèmes d'aide à la décision. La diversité des capteurs utilisés a montré la capacité des méthodes de ML à s'adapter à des données de physiologie et d'élevage des animaux.

① Prédiction d'une entrée du modèle nutritionnel : exemple du poids vifs

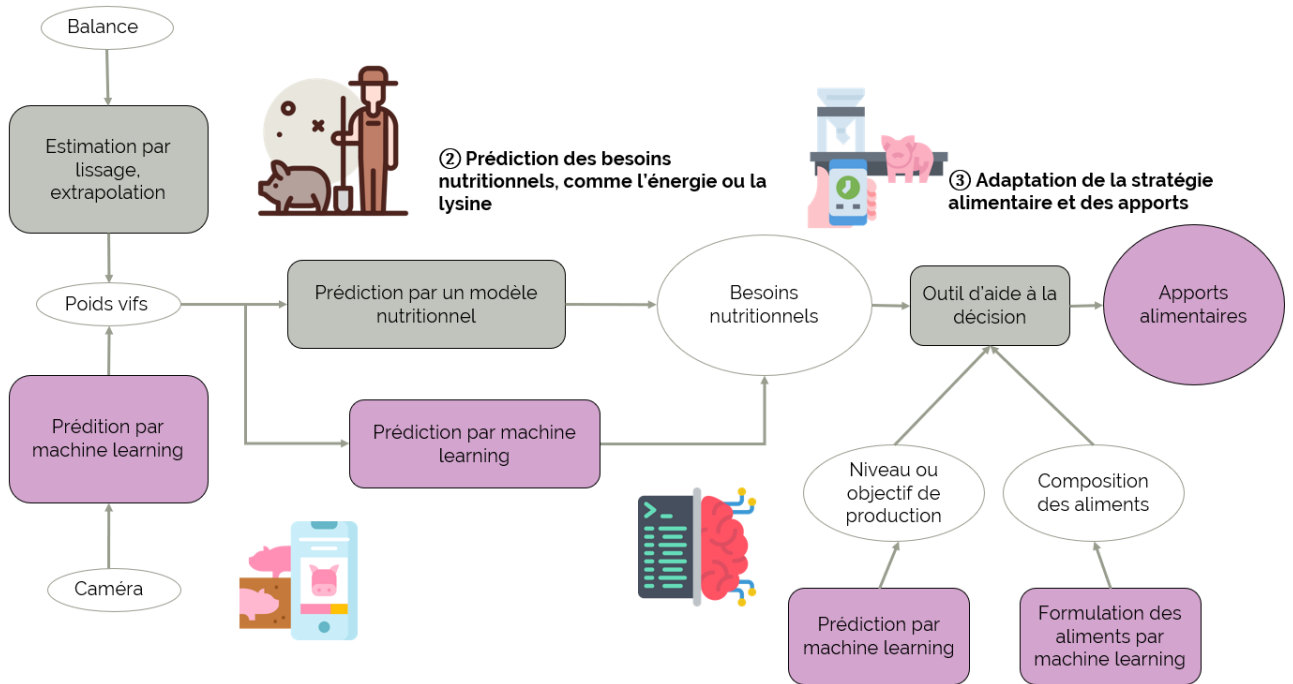


Figure 1-14 : Schéma récapitulatif de l'apport du machine learning pour l'alimentation.

i. Machine Learning pour prédire les entrées de modèle nutritionnel

Les modèles nutritionnels s'appuient sur des paramètres d'entrée tels que le poids vif de l'animal (Figure 1-14) et son ingestion d'aliment. Le poids vif est un paramètre important utilisé pour estimer la croissance d'un animal et les besoins nutritionnels (Halachmi et Guarino, 2016). Le poids vif individuel peut être facilement enregistré avec des balances. Néanmoins, le processus de pesée peut être coûteux (si achat d'une balance automatique installée dans la salle), consommateur de temps pour les animaliers, long et stressant pour les animaux. En particulier, c'est le cas lorsque les animaux doivent être déplacés, et potentiellement maintenus, sur les balances manuelles (Wang *et al.*, 2021). Pour les animaux en croissance, le processus de pesée quotidienne est le niveau minimal pour suivre le poids vif. Cependant, la variabilité peut être élevée au cours d'une journée, selon que l'animal a mangé et bu (poids du contenu digestif). Pour les femelles reproductrices (comme les truies en gestation), l'évolution du poids entre deux journées est limitée, et des données hebdomadaires sont donc suffisantes.

Les méthodes de ML basées sur des images extraites de vidéos pour prédire le poids des animaux attirent l'attention et font donc leur apparition dans les fermes expérimentales.

Si le poids vif est un paramètre clé pour prédire les besoins nutritionnels des animaux, la consommation alimentaire est également un paramètre pertinent à prédire quotidiennement. La consommation d'aliments n'est pas toujours enregistrée individuellement, même si des distributeurs automatiques d'aliment se développent pour plusieurs espèces (bovins laitiers, porcs). Ils restent coûteux et nécessitent généralement une restructuration de l'élevage. En l'absence d'automates d'alimentation connectés, les enregistrements peuvent être effectués manuellement au niveau de l'individu ou du groupe, ce qui, dans les deux cas, prend beaucoup de temps. Une estimation précise de la consommation d'aliments peut réduire les pertes d'aliments grâce à une meilleure estimation de la capacité d'ingestion de l'animal. Elle permet également de rééquilibrer les apports de nutriments dans la période suivante d'alimentation. Parfois, lorsqu'il est impossible de recueillir des données sur la consommation d'aliments, la consommation d'aliments peut être estimée à partir du comportement alimentaire. Une grande partie des nouvelles études utilisant des techniques de ML s'est intéressée à l'étude du comportement, et notamment du comportement alimentaire (Nashirahmadi *et al.*, 2017). Ces études ont porté sur l'exploitation de données issues de différents capteurs : accéléromètres (comme chez les volailles ou les bovins) et caméras vidéo (pour les porcs majoritairement), principalement en raison du système de logement (intérieur ou extérieur).

En dehors des capteurs précédemment cités, le traitement des images et des vidéos est un domaine très prometteur pour estimer le poids corporel et le comportement alimentaire des animaux. Différents types de caméras et de capteurs électro-optiques sans contact peuvent être utilisés : 2D (Wang *et al.*, 2008 ; Shi *et al.*, 2016 ; Jun *et al.*, 2018, Cowton *et al.*, 2019), 3D (Pezzuolo *et al.*, 2018 ; Cang *et al.*, 2019 ; Chen *et al.*, 2020b ; Zhang *et al.*, 2021.), caméra infrarouge (Benjamin et Yik, 2019), ou caméra avec profondeur (Buayai *et al.*, 2019 ; Alameer *et al.*, 2020b ; Yu *et al.*, 2021). Le choix de la caméra, selon la qualité de l'image

produite, et les conditions de luminosité ou d'application (posture, reconnaissance de l'animal) sont également importants à prendre en compte pour améliorer la performance de la prédiction. Les ombres, les changements d'éclairage ou la poussière peuvent diminuer la qualité de la segmentation des images et de la reconnaissance des animaux (Dohmen *et al.*, 2021). Pezzuolo *et al.* (2018) ont mis au point un système conçu pour des enclos intérieurs pour porcs afin d'éviter les variations du rayonnement solaire, permettant d'obtenir de faibles erreurs de poids prédits.

L'utilisation de la vision par ordinateur permet un mouvement libre de l'animal pendant la mesure, donc un animal moins stressé. Si l'animal est seul dans l'enclos, il est plus facile de faire le lien entre la mesure prédite par vision par ordinateur et l'animal (comme Cang *et al.*, 2019). Jun *et al.* (2018) ont été capables de mesurer le poids des porcs indépendamment de la posture de l'animal (en tenant compte de la totalité du corps et de la position de celui-ci), avec une précision de 80 %. Cependant, l'identification et le suivi de chaque animal doivent être développés, comme cela a été fait dans l'étude de Cowton *et al.*, (2019) pour les porcelets. Dans le cas d'un hébergement en groupe, une étape d'identification de chaque animal au préalable est nécessaire.

La plupart des études utilisent des réseaux de neurones à convolutions pour analyser les images issues de camera (Yang *et al.*, 2018 ; Alameer *et al.*, 2020b, Chen *et al.*, 2020b ; Li *et al.*, 2020), pour leur performance élevée dans la reconnaissance d'images (précision supérieure à 90 %). Cependant, la nature supervisée de ces algorithmes de ML nécessite un nombre important de données étiquetées pour la tâche d'apprentissage, souvent obtenues à l'aide d'un processus de réapprentissage basé sur les données déjà utilisées pour un autre système d'élevage.

Les méthodes de ML appliquées aux données issues de différents capteurs (notamment des caméras) peuvent contribuer à prédire de manière dynamique, au niveau individuel et quotidiennement, différentes caractéristiques des animaux (poids corporel, consommation d'aliments) afin de permettre une meilleure prédiction des besoins nutritionnels individuels.

ii. Machine learning pour calculer les besoins nutritionnels

Les modèles nutritionnels existants sont des modèles mathématiques pouvant combiner différents types de formalismes : mécanistes et empiriques, statiques et dynamiques, déterministes et stochastiques. Il s'agit alors de modèles hybrides (Jacobs *et al.*, 2022), qui peuvent également intégrer des systèmes d'intelligence artificielle (*i.e.* modèle mécaniste intelligent hybride ; Tedeschi, 2022). Les algorithmes de ML présentent l'avantage d'intégrer beaucoup de données (pas seulement des données historiques), de nouveaux types de données (comme des images ou des fichiers audios, de la génomique, Tedeschi *et al.*, 2017) et de modéliser une relation non linéaire entre les variables (modèle axé sur les données). De plus, le ML peut compléter ou remplacer les modèles nutritionnels de différentes manières. En effet, il peut prédire une variable d'entrée du modèle nutritionnel mécaniste (par exemple, le poids vif ou la consommation d'aliments comme vu précédemment, Figure 1-14) ou prédire la sortie d'un modèle nutritionnel (à la place de celui-ci, Tedeschi, 2022).

Cependant, une étape importante est de veiller à la qualité des données collectées par les automates et les capteurs. Les étapes de prétraitement des données, *i.e.* d'extraction et de nettoyage, indispensables à tout traitement par ML sont d'autant plus incontournable lorsqu'il s'agit de qualifier des informations portant sur des animaux difficiles à identifier (Friggens et Robert, 2016). En effet, la collecte d'un grand nombre de données de capteurs s'accompagne généralement d'informations partiellement manquantes ou de données erronées (comme par exemple une mauvaise identification de l'animal). Un système automatique permettant d'éliminer ou de corriger ces données erronées de manière efficace serait nécessaire notamment pour une utilisation en temps réel et non *a posteriori*.

iii. Machine learning pour adapter la stratégie alimentaire et les apports alimentaires

Au-delà de la prédiction des besoins, le ML pourrait être utilisé de différentes manières pour gérer les apports alimentaires et la stratégie alimentaire (Figure 1-14). En effet, des algorithmes peuvent formuler un régime alimentaire pour le porc avec une relation non linéaire entre les données afin d'optimiser le prix et la composition en nutriments (Saxena et Parasher, 2019). Le ML peut également servir à détecter la suffisance de l'approvisionnement en aliments (comme par exemple la disponibilité de l'herbe au pâturage pour les vaches laitières, Shafiullah *et al.*, 2019) ; ou pour surveiller et adapter le régime alimentaire, en fonction du niveau de production, avec un système intégré d'aide à la décision (comme chez la vache laitière, Fuentes *et al.*, 2020 ; Da Rosa Righi *et al.*, 2020 ; Kuan *et al.*, 2019).

Un système d'aide à la décision pour l'alimentation du porc imaginé à l'échelle individuelle pourrait délivrer en sortie des informations agrégées et compréhensibles pour l'éleveur ainsi que des recommandations ou actions. Les actions correctrices pourraient être, par exemple, l'ajustement automatique à la hausse de la ration en cas de période froide ou d'une suractivité des truies. Cependant, il convient de faire coïncider la précision du modèle nutritionnel avec celle du matériel de distribution, mais également du matériel d'acquisition des données. La finesse de l'apport calculé d'un aliment donné doit correspondre à la possibilité de distribution de l'automate (Gaillard *et al.*, 2020a).

En cas de situations détectées comme anormales, comme une altération des comportements alimentaires, le système d'aide à la décision pourrait, au-delà de l'adaptation des apports alimentaires, générer des alertes. Certains systèmes existent déjà pour la détection et la prévention de problèmes de santé, y compris chez les truies gestantes. Il peut s'agir des boiteries et des maladies digestives (Madsen et Kristensen, 2005 ; Cornou et Kristensen, 2013 ; Kashiha *et al.*, 2013) mais aussi des combats et d'autres comportements délétères chez le porc (Prunier *et al.*, 2019). Alameer *et al.* (2020a) ont développé chez le porc en croissance un système de reconnaissance de posture et d'étude de l'abreuvement afin d'évaluer l'état de santé et de bien-être des animaux. Les réseaux neuronaux créés ont permis la détection de ces postures avec une précision supérieure à 95 %, tant au

niveau du groupe qu'au niveau individuel. Ainsi, la multiplicité des capteurs et le développement de méthodes de ML permettent d'imaginer des systèmes d'aide à la décision. Cependant, il convient, avant de travailler sur l'intégration de ces nouvelles variables comportementales dans les modèles nutritionnels, de répondre aux interrogations suivantes : comment les intégrer ? quelles sont les catégories à définir ? comment passer de l'échelle du groupe à celle de l'individu ? *etc.*



L'enjeu des prochains modèles nutritionnels est de caractériser plus précisément les besoins des truies en gestation, en tenant compte de la forte variabilité entre individus liée au comportement, à la santé ou aux conditions d'élevage. L'élevage de précision peut y répondre grâce à la collecte continue et en temps réel de données par des capteurs et l'analyse de ces données grâce à des méthodes de machine learning.

1.5. Références bibliographiques

- Aerts J.M., Wathes C.M., Berckmans D., 2003. Dynamic Data-based Modelling of Heat Production and Growth of Broiler Chickens: Development of an Integrated Management System. *Biosys. Eng.*, 84, p.257-266.
- Alameer A., Kyriazakis I., Bacardit J., 2020a. Automated recognition of postures and drinking behaviour for the detection of compromised health in pigs. *Sci. Rep.*, 10, 13665.
- Alameer A., Kyriazakis I., Dalton H.A., Miller A.L., Bacardit J., 2020b. Automatic recognition of feeding and foraging behaviour in pigs using deep learning. *Biosys. Eng.*, 197, p.91-104.
- Andretta I., Hauschild L., Kipper M., Pires P.G.S., Pomar C., 2018. Environmental impacts of precision feeding programs applied in pig production. *Animal*, 12, p.1990-1998.
- Anil S., Anil L., Deen J., Baidoo S., Walker R., 2005. Characterization of claw lesions in gestating sows. In : Proceedings Allen D. Lemman Swine Conference, Minneapolis, Etats-Unis, p.193-199.
- Anses, 2018. Avis de l'Anses relatif au « Bien-être animal : contexte, définition et évaluation ». <https://www.anses.fr/fr/system/files/SABA2016SA0288.pdf> (consulté le 28/12/2022).
- Athorn R.Z., Stoot P., Bouwman E.G., Edwards A.C., Blackberry M.A., Martin G.B., Langendijk P. 2012. Feeding level and dietary energy source have no effect on embryo survival in gilts, despite changes in systemic progesterone levels. *Anim. Prod. Sci.*, 53, p.30-37.
- Baldwin B.A., Start I.B., 1985. Illumination preferences of pigs. *Appl. Anim. Behav. Sci.*, 14, p.233-243.
- Banhazi T.M., Lehr H., Black J.L., Crabtree H., Schofield P., Tschärke M., Berckmans D., 2012. Precision Livestock Farming: An international review of scientific and commercial aspects. *Int. J. Agric. Biol. Eng.*, 5, p.1-9.
- Bazer F.W., Kim J., Song G., Ka H., Wu G., Johnson G.A., Vallet J.L., 2013. Roles of selected nutrients in development of the porcine conceptus during pregnancy. In : H. Rodriguez-Martinez, N.M. Soede & W.L. Flowers (Eds.), Control of pig reproduction IX. Context Products, Packington, Royaume-Uni, p.159-174.
- Benjamin M., Yik S., 2019. Precision livestock farming in swine welfare: A review for swine practitioners. *Animals*, 9, 133.
- Bergeron R., Badnell-Waters A.J., Lambton S., Mason G., 2006. Stereotypic oral behaviour in captive ungulates: foraging, diet and gastrointestinal function. In : G. Mason G. & J. Rushen (Eds), Stereotypic Animal Behaviour: Fundamentals and Applications to Welfare, CABI Publishing, Wallingfor, Royaume-Uni, p.19-27.

- Bertin C., Ramonet Y., 2015. Utilisation d'accéléromètres pour mesurer l'activité physique des truies logées en groupes. Développement de la méthode et utilisation dans six élevages. In : JRP (Ed.), Proceedings Journées Rech. Porcine, 47, p.229-234.
- Boissy A., Manteuffel G., Jensen M.B., Moe R.O., Spruijt B., Keeling L.J., Winckler C., Forkman B., Dimitrov I., Langbein J., Bakken M., Veissier I., Aubert A., 2007. Assessment of positive emotions in animals to improve their welfare. *Physiol. Behav.*, 92, p.375-397.
- Boissy A., 2012. Recherche en éthologie appliquée aux animaux de ferme : Concilier bien-être animal et production. *Bull. Acad. Vet. Fr.*, 165, p.137-148.
- Breed M.D., Moore J., 2022. Of Cockroaches and Wolves: Framing Animal Behavior. In : M.D. Breed & J. Moore (Eds), *Animal Behavior*, Academic Press, Cambridge, Etats-Unis, p.1-24.
- Buayai P., Piewthongngam K., Leung C.K., Saikaew K.R., 2019. Semi-automatic pig weight estimation using digital image analysis. *ASABE - Applied Engineering in Agriculture*, 35, p.521-534.
- Camerlink I., Coulange E., Farish M., Baxter E.M., Turner S.P., 2018. Facial expression as a potential measure of both intent and emotion. *Sci. Rep.*, 8, 17602.
- Cang Y., He H., Qiao Y., 2019. An Intelligent Pig Weights Estimate Method Based on Deep Learning in Sow Stall Environments. *IEEE Access*, 7, p.164867-164875.
- Carlslake C., Occhiuto F., Vazquez-Diosdado J.A., Kaler J., 2022. Indication of a personality trait in dairy calves and its link to weight gain through automatically collected feeding behaviours. *Sci. Rep.*, 12, 19425.
- Chan W.Y., Cloutier S., Newberry R.C., 2011. Barking pigs: differences in acoustic morphology predict juvenile responses to alarm calls. *Anim. Behav.*, 82, p.767-774.
- Chapa J.M., Maschat K., Iwersen M., Baumgartner J., Drillich M., 2020. Accelerometer systems as tools for health and welfare assessment in cattle and pigs – A review. *Behav. Proc.*, 181, 104262.
- Chen C., Zhu W., Steibel J., Siegford J., Han J., Norton T., 2020a. Classification of drinking and drinker-playing in pigs by a video-based deep learning method. *Biosyst. Eng.*, 196, p.1-14.
- Chen C., Zhu W., Steibel J., Siegford J., Han J., Norton T., 2020b. Recognition of feeding behaviour of pigs and determining of feeding time of each pig by a video-based deep learning method. *Comput. Electron. Agric.*, 176, 105642.
- Choi H.L., Han S.H., Albright L.D., Chang W.K., 2011. The correlation between thermal and noxious gas environments, pig productivity and behavioral responses of growing pigs. *Int. J. Environ. Res. Public Health*, 8, p.3514-3527.
- Cloutier L., Dourmad JY., Pomar C., Morin-Doré L., Gagnon P., 2019. Effet d'une alimentation de précision sur les performances, la productivité et le coût d'alimentation pendant la gestation dans

un contexte commercial de gestion des truies en groupe. In : JRP (Ed.), Proceedings Journées Rech. Porcine, 51, p.129-134

Cornou C., Lundbye-Christensen S., 2008. Classifying sows' activity types from acceleration patterns. *Appl. Anim. Behav. Sci.*, 111, p.262-273.

Cornou C., Kristensen A.R., 2013. Use of information from monitoring and decision support systems in pig production: Collection, applications and expected benefits. *Livest. Sci.*, 157, p.552-567.

Cowton J., Kyriazakis I., Bacardit J., 2019. Automated Individual Pig Localisation, Tracking and Behaviour Metric Extraction Using Deep Learning. *IEEE Access*, 7, p.108049-108060.

Croney C.C., Millman S.T., 2007. Board-Invited Review: The ethical and behavioral bases for farm animal welfare legislation. *J. Anim. Sci.*, 85, p.556-565.

Da Rosa R.R., Goldschmidt G., Kunst R., Deon C., da Costa C.A., 2020. Towards combining data prediction and internet of things to manage milk production on dairy cows. *Comput. Electron. Agric.*, 169, 105156.

Dawkins M.S., 2006. Through animal eyes: What behaviour tells us. *Appl. Anim. Behav. Sci.*, 100, p.4-10.

Danielsen V., Vestergaard E.M., 2001. Dietary fiber for pregnant sows: effect on performance and behaviour. *Anim. Feed Sci. Technol.*, 90, p.71-80.

D'eath R.B., Jarvis S., Baxter E.M., Houdijk J., 2018. Mitigating hunger in pregnant sows. In : M. Spinka (Ed.), *Advances in Pig Welfare*, Woodhead Publishing Series in Food Science, Technology and Nutrition, Duxford, Royaume-Uni, p.199-234

di Giminiani P., Brierley V.L.M.H., Scollo A., Gottardo F., Malcolm E.M., Edwards S.A., Leach M.C., 2016. The assessment of facial expressions in piglets undergoing tail docking and castration: toward the development of the Piglet Grimace Scale. *Front. vet. sci.*, 3, 100.

Dohmen R., Catal C., Liu Q., 2021. Computer vision-based weight estimation of livestock: a systematic literature review. *New Zealand J. Agric. Res.*, 65, p.227-247.

Domingos R., Rueda F., Abreu M., Luna A., Htoo J., González-Veja C., Luspa M., Brand H., Rebordões F., Silva B., 2022. Development and validation of a precision feeding program using automated intelligent precision feeders (AIPF) on performance of high-prolific gestating sows. *Animal - Science Proceedings*, 13, 169.

Dourmad J.Y., Etienne M., Valancogne A., Dubois S., van Milgen J., Noblet J., 2008. InraPorc: A model and decision support tool for the nutrition of sows. *Anim. Feed Sci. Technol.*, 143, p.372-386.

Dourmad J.Y., 2019. Evolution of the feeding approach in sows during the last decades. In : A.P. Yagüe (Ed), *Nutrition of hyperprolific sows*, NOVUS, Etats-Unis, p.107-132.

- Dourmad J.Y., Gauthier R., Gaillard C., 2021. Evolution des concepts nutritionnels et des méthodes d'alimentation des truies reproductrices : historiques et perspectives. In : JRP (Ed.), Journées Rech. Porcine, 53, p.133-144.
- Dugatkin L.A., 2019. Principles of Animal Behavior. In : L.A. Dugatkin (Ed.), Principles of Animal Behavior, Fourth Edition, The university of Chicago Press, Etats-Unis, p.1-20.
- Farmer C., Hurley W.L., 2015. Mammary development. In : C. Farmer (Ed.), The gestating and lactating sows, Wageningen Academic Publishers, Wageningen, Pays-Bas, p.73-94.
- FAWC, 1979. Farm Animal Welfare Council. Press statement. <http://www.fawc.org.uk/pdf/fivefreedoms1979.pdf> (consulté le 28/12/2022).
- Forkman B., 2021. Welfare assessment of pigs. In : S. Edwards (Ed.), Understanding the behaviour and improving the welfare of pigs, Burleigh Dodds Science Publishing Series in Agricultural science number 96, Dublin, Irlande, p.497-524.
- Friend D.W., 1971. Self-selection of feed and water by swine during pregnancy and lactation. *J. Anim. Sci.*, 32, p.658-663.
- Friendship R.M., O'Sullivan T.L., 2015. Sow health. In : C. Farmer (Ed.), The gestating and lactating sows, Wageningen Academic Publishers, Wageningen, Pays-Bas, p.409-421.
- Friggens N., Robert P.E., 2016. Faire émerger les informations clés des données de l'élevage de précision. In : S. Chastant-Maillard & M. Saint Dizier (Eds.), Élevage de précision, Éditions France Agricole, Paris, FR, 270p.
- Fuentes S., Viejo C.G., Cullen B., Tongson E., Chauhan S.S., Dunshea F.R., 2020. Artificial Intelligence Applied to a Robotic Dairy Farm to Model Milk Productivity and Quality based on Cow Data and Daily Environmental Parameters. *Sensors*, 20, 2975.
- Gaillard C., Gauthier R., Cloutier L., Dourmad J.Y., 2019. Exploration of individual variability to better predict the nutrient requirements of gestating sows. *J. Anim. Sci.*, 97, p.4934-4945.
- Gaillard C., Brossard L., Dourmad J.Y., 2020a. Improvement of feed and nutrient efficiency in pig production through precision feeding. *Anim. Feed Sci. Technol.*, 268, 114611.
- Gaillard C., Quiniou N., Gauthier R., Cloutier L., Dourmad J.Y., 2020b. Evaluation of a decision support system for a precision feeding of gestating sows. *J. Anim. Sci.*, 98, p.1-12.
- Gaillard C., Julienne A., Dourmad J.Y., 2021. Comportement alimentaire des truies en gestation recevant une alimentation de précision. In : JRP (Ed.), Journées Rech. Porcine, 53, p.201-202.
- Gaillard C., Dourmad J.Y., 2022. Application of a precision feeding strategy for gestating sows. *Anim. Feed Sci. Technol.*, 287, 115280.

- Gauthier R., Largouët C., Rozé L., Dourmad J.Y., 2021. Online forecasting of daily feed intake in lactating sows supported by offline time-series clustering, for precision livestock farming. *Comput. Electron. Agric.*, 188, 106329.
- Geers R., 2007. Lying behaviour (location, posture and duration). In : A. Velarde & R. Geers (Eds.), On farm monitoring of pig welfare, Wageningen Academic Publishers, Wageningen, Pays-Bas, p.19-24.
- Gerritsen R., Soede N.M., Langendijk P., Dieleman S.J., Hazeleger W., Laurensen B.F.A., Kemp B., 2008. Feeding level does not affect progesterone levels in intermittently suckled sows with lactational ovulation. *Animal Reproduction Science*, 103, p.379-384.
- Gjergji M., Weber V.M., Silva L.O.C., Gomes R.C., Araujo T.L.A.C., Pistori H., Alvarez M., 2020. Deep learning techniques for beef cattle body weight prediction. In : Proceedings International Joint Conference on Neural Networks (IJCNN), p.1-8.
- Gonyou H.W., 2001. The social behaviour of pigs. In : L.J. Keeling & H.W. Gonyou (Eds.), Social Behaviour in Farm Animals, CAB International, Wallingford, Royaume-Uni, p.147-168.
- Gorczyca M.T., Milan H.F.M., Maia A.S.C., Gebremedhin K.G., 2018. Machine learning algorithms to predict core, skin, and hair-coat temperatures of piglets. *Comput. Electron. Agric.*, 151, p.286-294.
- Guevara R.D., Pastor J.J., Manteca X., Tedo G., Llonch P., 2022. Systematic review of animal-based indicators to measure thermal, social, and immune-related stress in pigs. *PLoS ONE*, 17, e0266524.
- Halachmi I., Guarino M., 2016. Editorial: Precision livestock farming: a 'per animal' approach using advanced monitoring technologies. *Animal*, 10, p.1482-1483.
- Hayer J.J., Nysar D., Schmitz A., Leubner C.D., Heinemann C., Steinhoff-Wagner J., 2022. Wound lesions caused by ear tagging in unweaned calves: assessing the prevalence of wound lesions and identifying risk factors. *Animal*, 16, 100454.
- Hazeleger W., Smits C., Kemp B., 2007. Influence of nutritional factors on placenta growth and piglet imprinting. In : J. Wiseman, B. Kemp & M. Varley (Eds.), Paradigm in pig science, University of Nottingham Press, Nottingham, Royaume-Uni, p.309-327.
- Held S.D.E., Cooper J.J., Mendl M.T., 2009. Advances in the study of cognition, behavioural priorities and emotions. In : J.N. Marchant-Forde (Ed.), The Welfare of Pigs, Springer, Heidelberg, Allemagne, p.47-94.
- Hemsworth P.H., 2018. Key determinants of pig welfare: implications of animal management and housing design on livestock welfare. *Anim. Prod. Sci.*, 58, 1375.
- Hemsworth P.H., 2021. Optimising pig welfare in breeding and gestation. In : S. Edwards (Ed.), Understanding the behaviour and improving the welfare of pigs, Burleigh Dodds Science Publishing Series in Agricultural science, Dublin, Irlande, p.87-120.

- Holmes C.W., Close W.H., 1977. The influence of climatic variables on energy metabolism and associated aspects of productivity in pigs. In : W. Haresign, H. Swan & D. Lewis (Eds.), *Nutrition and the Climatic Environment*, Londres, Royaume-Uni, p.51-74.
- Hörning B., 2007. Lying down and standing behaviour. In : A. Velarde & R. Geers (Eds.), *On farm monitoring of pig welfare*, Wageningen Academic Publishers, Wageningen, The Netherlands, p.25-34.
- Jackson P., Nasirahmadi A., Guy J.H., Bull S., Avery P.J., Edwards S.A., Sturm B., 2020. Using CFD modelling to relate pig lying locations to environmental variability in finishing pens. *Sustainability*, 12, p.19-28.
- IFIP, 2019. Bâtisanté : Ambiance : ventilation et chauffage. Fiche n°7 Fondamentaux sur l'ambiance. Disponible à : <https://biosecurite.ifip.asso.fr/documents/fiches/porcibat/fiche-7.pdf>.
- Jacobs M., Remus A., Gaillard C., Menendez H.M., Tedeschi L.O., Neethirajan S., Ellis J.L., 2022. ASAS-NANP SYMPOSIUM - Mathematical modeling in animal nutrition: Limitations and potential next steps for modeling and modelers in the Animal Sciences. *J. Anim. Sci.*, 100, p.1-15.
- Johnson R.W., 1997. Inhibition of growth by pro-inflammatory cytokines: an integrated view. *J. Anim. Sci.*, 75, p.1244-1255.
- Jun K., Kim S.J., Ji H.W. 2018. Estimating pig weights from images without constraint on posture and illumination. *Comput. Electron. Agric.*, 153, p.169-176.
- Kavlak A.T., Pastell M., Uimari P., 2023. Disease detection in pigs based on feeding behaviour traits using machine learning. *Biosys. Eng.*, 226, p.132-143.
- Kashiha M., Bahr C., Haredasht S.A., Ott S., Moons C.P.H., Niewold T.A., Odeberg F.O., Berckmans D., 2013. The automatic monitoring of pigs water use by cameras. *Comput. Electron. Agric.*, 90, p.164-169.
- Kittawornrat A., Zimmerman J.J., 2011. Toward a better understanding of pig behavior and pig welfare. *Anim. Health Res. Rev.*, 12, p.25-32.
- Kremer L., Klein H.S.E.J., Reimert I., Bolhuis J.E., Webb L.E., 2020. The nuts and bolts of animal emotion. *Neurosci. Biobehav. Rev.*, 113, p.273-286.
- Kruse S., Stamer E., Traulsen I., Krieter J., 2010. Relationship between feed, water intake, and body weight in gestating sows. *Livest. Sci.*, 137, p.37-41.
- Kruse S., Stamer E., Traulsen I., Krieter J., 2011. Temporal pattern of feeding and drinking behaviour of gestating sows. *Arch. Anim. Breed.*, 54, p.490-503.
- Kuan C.Y., Tsai Y.C., Hsu J.T., Ding S.T., Lin T.T., 2019 An Imaging System Based on Deep Learning for Monitoring the Feeding Behavior of Dairy Cows. *ASABE Annual International Meeting*, Boston, Etats-Unis, 1901469.

- Kusina J., Pettigrew J.E., Sower A.F., Hathaway M.R., White M.E., Crooker B.A., 1999. Effect of protein intake during gestation on mammary development of primiparous sows. *J. Anim. Sci.*, 77, p.925-930.
- Kyriazakis I., Doeschl-Wilson A., 2009. Anorexia during infection in mammals: variation and its sources. In : D. Torrallardona & E. Roura (Eds.), *Voluntary feed intake in pigs*, Wageningen Academic Publishers, Wageningen, Pays-Bas, p.307-321.
- Labrecque J., Gouineau F., Rivest J., Germain G., 2020. Suivi individuel des porcs et collecte de métriques comportementales en temps réel avec des caméras de sécurité. In : JRP (Ed.), *Proceedings Journées Rech. Porcine*, 52, p.379-384.
- Langendijk P., Peltoniemi O., 2013. How does nutrition influence luteal function and early embryo survival. In : H. Rodriguez-Martinez, N.M. Soede & W.L. Flowers (Eds.), *Control of pig reproduction IX*. Context Products, Packington, Royaume-Uni, p.145-158.
- Langendijk P., 2015. Early gestation feeding and management for optimal reproductive performance. In : C. Farmer (Ed.), *The gestating and lactating sows*, Wageningen Academic Publishers, Wageningen, Pays-Bas, p.27-45.
- Lanthony M., Danglot M., Spinka M., Tallet C., 2022. Dominance hierarchy in groups of pregnant sows: Characteristics and identification of related indicators. *Appl. Anim. Behav. Sci.*, 254, 105683.
- Lawrence A.B., Terlouw E.M.C., 1993. A review of the behavioural factors involved in the development and continued performance of stereotypic behaviors in pigs. *J. Anim. Sci.*, 71, p.2815-2825.
- Le Cozler Y., Allain C., Caillot A., Delouard J.M., Delattre L., Luginbuhl T., Faverdin P., 2019. High precision scanning system for complete 3D cow body shape imaging and analysis of morphological traits. *Comput. Electron. Agric.*, 157, p.447-453.
- Le Floc'h N., 2000. Conséquences d'un état inflammatoire ou infectieux sur le métabolisme et le besoin en acides aminés chez le porc. *INRA Prod. Anim.*, 13, p.3-10.
- Le Floc'h N., Melchior D., Obled C., 2004. Modifications of protein and amino acid metabolism during inflammation and immune system activation. *Livest. Prod. Sci.*, 87, p.37-45.
- Le Floc'h N., Otten W., Merlot E., 2011. Tryptophan metabolism, from nutrition to potential therapeutic applications. *Amino Acids*, 41, p.1195-1205.
- Le Floc'h N., Boudon A., Montagne L., Gilbert H., Gondret F., Lebret B., Lefaucheur L., Louveau I., Merlot E., Père M.C., Meunier-Salaün M.C., Prunier A., Quesnel H., 2021. Santé et bien-être de la truie gestante et du porc en croissance. *INRAE Prod. Anim.*, 34, p.48-79.
- Liakos K., Busato P., Moshou D., Pearson S., Bochtis D., 2018. Machine Learning in Agriculture: A Review. *Sensors*, 18, 2674.

- Li D., Zhang K., Li Z., Chen Y., 2020. A Spatiotemporal Convolutional Network for Multi-Behavior Recognition of Pigs. *Sensors*, 20, 2381.
- Lokhorst C., de Mol R.M., Kamphuis C., 2019. Invited review: Big Data in precision dairy farming. *Animal*, 13, p.1519-1528.
- Madec F., 1985. La consommation d'eau chez la truie gestante en élevage intensif. In : JRP (Ed.), Proceedings Journées Rech. Porcine, 17, p.223-236.
- Madsen T.N., Kristensen A.R., 2005. A model for monitoring the condition of young pigs by their drinking behaviour. *Comput. Electron. Agric.*, 48, p.138-154.
- Manci K.M., Gladwin D.N., Vilella R., Cavendish M.G., 1988. Effects of aircraft noise and sonic booms on domestic animals and wildlife: a literature synthesis. In : U.S. Fish and wildlife service national ecology research center, Ft. Collins, Technical Report, PB-89-115026/XAB; NERC-88/29, 86p.
- Manteuffel G., Puppe B., Schön P.C., 2004. Vocalization of farm animals as a measure of welfare. *Appl. Anim. Behav. Sci.*, 88, p.163-182.
- Marchant J.N., Whittaker X., Broom D.M., 2001. Vocalisations of the adult female domestic pig during a standard human approach test and their relationships with behavioural and heart rate measures. *Appl. Anim. Behav. Sci.*, 72, p.23-39.
- Marcon M., Quiniou N., Courboulay V., Rousselière Y., Melot G., Meunier-Salaün M.C., Labussière E., Ramonet Y., Cherel P., Le Mer M., 2020. Améliorer les performances et le bien être des truies gravides par la mobilisation de nouvelles technologies pour une alimentation de précision et la détection de signaux comportementaux. *Innov. Agron., INRAE*, 79, p.245-256.
- Martelli G., Scalabrin M., Scipioni R., Sardi L., 2005. The effects of the duration of the artificial photoperiod on the growth parameters and the behaviour of heavy pigs. *Vet. Res. Commun.*, 29, p.367-369.
- Massabie P., Granier R., Le Dividich J., 1997. Effects of environmental conditions on the performance of growing-finishing pigs. In : Proceedings 5th ILES, Bloomington, Etats-Unis, p.1010-1016.
- Massabie P., Roy H., Boulestreau-Boulay A.L., Dubois A., 2014. La consommation d'eau en élevage de porcs. Des leviers pour réduire la consommation d'eau en élevage de porcs. Rapport de IFIP, CRAB, CRPAL, 16p.
- Matthews S.G., Miller A.L., Clapp J., Plötz T., Kyriazakis I., 2016. Early detection of health and welfare compromises through automated detection of behavioural changes in pigs. *Vet. J.*, 217, p.43-51.
- McMillan F.D., Yeates J.W., 2008. The problem with well-being terminology. In : F.D. McMillan (Ed.), Mental Health and Well-Being in Animals, CABI, 2nd Edition, p.8-20.
- Meese B.Y.G.B., Ewbank R., 1973. The establishment and nature of the dominance hierarchy in the domesticated pig. *Anim. Behav.*, p.326-334.

- Mellor D.J., 2017. Operational Details of the Five Domains Model and Its Key Applications to the Assessment and Management of Animal Welfare. *Animals*, 7, 60.
- Mendl M., Burman O.H.P., Paul E.S., 2010. An integrative and functional framework for the study of animal emotion and mood. *Proc. Royal Soc. B.*, 277, p.2895-2904.
- Meunier-Salaün M.C., Edwards S.A., Robert S., 2001. Effect of dietary fibre on the behaviour and health of the restricted fed sow. *Anim. Feed Sci. Technol.*, 90, p.53-69.
- Mormède P., Andanson S., Aupérin B., Beerda B., Guémené D., Malmkvist J., Manteca X., Manteuffel G., Prunet P., van Reenen C.G., Richard S., Veissier I., 2007. Exploration of the hypothalamic-pituitary-adrenal function as a tool to evaluate animal welfare. *Physiol. Behav.*, 92, p.317-339.
- Mormède P., Boisseau-Sowinski L., Chiron J., Diederich C., Eddison J., Guichet J.L., Le Neindre P., Meunier-Salaün M.C., 2018. Bien-être animal : contexte, définition, évaluation. *INRA Prod. Anim.*, 31, p.145-162.
- Murphy E., Melotti L., Mendl M., 2021. Assessing emotions in pigs: determining negative and positive mental states. In : S. Edwards (Ed.), *Understanding the behaviour and improving the welfare of pigs*, Burleigh Dodds Series Science Publishing in Agricultural science, Dublin, Irlande, p.455-496.
- Nasirahmadi A., Edwards S.A., Sturm B., 2017. Implementation of machine vision for detecting behaviour of cattle and pigs. *Livest. Sci.*, 202, p.25-38.
- Neethirajan S., 2020. Transforming the Adaptation Physiology of Farm Animals through Sensors. *Animals*, 10, 1512.
- Nilsson M., Herlin A.H., Ardo H., Guzhva O., Astrom K., Bergsten C., 2015. Development of automatic surveillance of animal behaviour and welfare using image analysis and machine learned segmentation technique. *Animal*, 9, p.1859-1865.
- Noblet J., Etienne M., Dourmad J.Y., 1988. Besoins énergétiques de la truie allaitante : détermination par la méthode factorielle. *INRA Prod. Anim.*, 1, p.355-358.
- Noblet J., Shi X.S., Dubois S., 1993a. Energy cost of standing activity in sows. *Livest. Prod. Sci.*, 34, p.127-136.
- Noblet J., Shi X.S., Karege C., Dubois S., 1993b. Effets du type sexuel, du niveau d'alimentation, du poids vif et du stade physiologique sur l'utilisation digestive de l'énergie et des nutriments chez le porc : interactions avec la composition du régime. In : JRP (Ed.), *Proceedings Journées Rech. Porcine*, 25, p.165-180.
- Norring M., Valros A., Bergman P., Marchant-Forde J.N., Heinonen M., 2019. Body condition, live weight and success in agonistic encounters in mixed parity groups of sows during gestation. *Animal*, 13, p.392-398.

Novak S., Paradis F., Patterson J.L., Pasternak J.A., Oxtoby K., Moore H.S., Hahn M., Dyck M.K., Dixon W.T., Foxcroft G.R., 2011. Temporal candidate gene expression in the sow placenta and embryo during early gestation and effect of maternal Progenos supplementation on embryonic and placental development. *Reprod. Fertil. Dev.*, 24, p.550-558.

OIE, 2018. Code sanitaire pour les animaux terrestres, Bien-être animal, Introduction sur les recommandations relatives au bien-être animal, article 7.1.1, http://www.oie.int/index.php?id=169&L=1&htmfile=titre_1.7.htm

O'Malley C.I., Steibel J.P., Bates R.O., Ernst C.W., Siegord J.M., 2021. Time budgets of group-housed pigs in relation to social aggression and production. *J. Anim. Sci.*, 99, p.1-8.

Otten W., Konitz E., Puppe B., Tuchscherer M., Brussow K.P., Nurnberg G., Stabenow B., 2004. Acute and longterm effects of chronic intermittent noise stress on hypothalamic-pituitary-adrenocortical and sympatho- adrenomedullary axis in pigs. *Anim. Sci.*, 78, p.271-283.

Parent J.P., Meunier-Salaün M.C., Vasseur E., Bergeron R., 2012. Stability of social hierarchy in growing female pigs and pregnant sows. *Appl. Anim. Behav. Sci.*, 142, p.1-10.

Paul E.S., Harding E.J., Mendl M., 2005. Measuring emotional processes in animals: the utility of a cognitive approach. *Neurosci. Biobehav. Rev.*, 29, p.469-491.

Pedersen L.J., 2018. Overview of commercial pig production systems and their main welfare challenges. In : M. Spinka (Ed.), *Advances in Pig Welfare*, Woodhead Publishing Series in Food Science, Technology and Nutrition, Duxford, Royaume-Uni, p.3-25.

Pezzuolo A., Guarino M., Sartori L., González L.A., Marinello F., 2018. On-barn pig weight estimation based on body measurements by a Kinect v1 depth camera. *Comput. Electron. Agric.*, 148, p.29-36.

Pluym L.M., Maes D., Vangeyte J., Mertens K., Baert J., Van Weyenberg S., Millet S., Van Nuffel A., 2013. Development of a system for automatic measurements of force and visual stance variables for objective lameness detection in sows: SowSIS. *Biosyst. Eng.*, 116, p.64-74.

Prunier A., Tallet C., Lagarrigues G., Sakri O., Vidal A., Coulon L.F., Brulais S., Godin C., Labyt E., 2019. Vers une détection automatisée des comportements délétères des porcs en élevage. In : JRP (Ed.), *Journées Rech. Porcine*, 51, p.25-30.

Quesnel H., Boulot S., Serriere S., Venturi E., Martinat-Botte F., 2010. Post insemination level of feeding does not influence embryonic survival and growth in highly prolific pigs. *Anim. Reprod. Sci.*, 120, p.120-124.

Reimert I., Bolhuis J.E., Kemp B., Rodenburg T.B., 2013. Indicators of positive and negative emotions and emotional contagion in pigs. *Physiol. Behav.*, 109, p.42-50.

Renaudeau D., Quiniou N., Noblet J., 2001. Effects of exposure to high ambient temperature and dietary protein level on performance of multiparous lactating sows. *J. Anim. Sci.*, 79, p.1240-1249.

- Salak-Johnson J.L., Niekamp S.R., Rodriguez-Zas S.L., Ellis M., Curtis S.E., 2007. Space allowance for dry, pregnant sows in pens: Body condition, skin lesions, and performance. *J. Anim. Sci.*, 85, p.1758-1769.
- Salak-Johnson J.L., DeDecker A.E., Horsman M.J., Rodriguez-Zas S.L., 2012. Space allowance for gestating sows in pens: Behavior and immunity. *J. Anim. Sci.*, 90, p.3232-3242.
- Saxena P., Parasher Y., 2019. Application of Artificial Neural Network (ANN) for Animal Diet Formulation Modeling. *Procedia Computer Science*, 152, p.261-266.
- Schild S.L.A., 2018. Giving birth outdoors: Impact of thermal environment on sow' parturition and piglet survival. Thèse de Doctorat, Aarhus University, Foulum, Danemark, 177p.
- Schinckel A.P., de Lange C.F.M., 1996. Characterization of Growth Parameters Needed as Inputs for Pig Growth Models. *J. Anim. Sci.*, 74, p.2021-2036.
- Schwartz M., 2011. A comparison of group-housed gestation and stalled gestation within a system. In : Proceedings Allen D. Lemay Swine Conference, Minneapolis, Etats-Unis, p.207-209.
- Seddon Y.M., Cain P.J., Guy J.H., Edwards S.A., 2013. Development of a spreadsheet based financial model for pig producers considering high welfare farrowing systems. *Livest. Sci.*, 157, p.317-321.
- Shafiullah A.Z., Werner J., Kennedy E., Leso L., O'Brien B., Umstätter C., 2019. Machine Learning based Prediction of Insufficient Herbage Allowance with Automated Feeding Behaviour and Activity Data. *Sensors*, 19, 4479.
- Shi C., Teng G., Li Z., 2016. An approach of pig weight estimation using binocular stereo system based on LabVIEW. *Comput. Electron. Agric.*, 129, p.37-43.
- Silva B., Gonçalves M.F., Domingos R.L., 2023. Precision feeding for high-performance sows (2/2). *Pig 333 Nutrition*, 16 mars 2023. Consulté le 3 mai 2023. URL: https://www.pig333.com/articles/precision-feeding-for-high-performance-sows-2-2_18818.
- Soerensen D.D., Pedersen L.J., 2015. Infrared skin temperature measurements for monitoring health in pigs: a review. *Acta Veterinaria Scandinavica*, 57, 5.
- Spoolder H.A.M., Vermeer H.M., 2015. Gestation group housing of sows. In : C. Farmer (Ed.), *The gestating and lactating sow*, Wageningen Academic Publishers, Wageningen, Pays-Bas, p.47-72.
- Stevenson J.S., Pollmann D.S., Davis D.L., Murphy J.P., 1983. Influence of Supplemental Light on Sow Performance during and after Lactation. *J. Anim. Sci.*, 56, p.1282-1286.
- Talling J.C., Waran N.K., Wathes C.M., Lines J.A., 1996. Behavioural and physiological responses of pigs to sound. *Appl. Anim. Behav. Sci.*, 48, p.187-201.

- Tedeschi L.O., Fonseca M.A., Muir J.P., Poppi D.P., Carstens E., Angerer J.P., Fox D.G., 2017. Invited Review. A glimpse of the future in animal nutrition science. Current and future solutions. *Brazilian J. Anim. Sc.*, 46, p.452-469.
- Tedeschi L.O., 2022. ASAS-NANP SYMPOSIUM - Mathematical modeling in animal nutrition: The progression of data analytics and artificial intelligence in support of sustainable development in animal science. *J. Anim. Sci.*, 100, p.1-11.
- Town S.C., Putman C.T., Turchinsky N.J., Dixon W.T., Foxcroft G.R., 2004. Number of conceptuses in utero affects porcine fetal muscle development. *Reproduction*, 128, p.443-254.
- Trottier N.L., Johnston L.J., de Lange C.F.M., 2015. Applied amino acid and energy feeding of sows. In : C. Farmer (Ed.), *The gestating and lactating sows*, Wageningen Academic Publishers, Wageningen, Pays-Bas, p.117-145.
- Turner J.G., Parrish J.L., Hughes L.F., Toth L.A., Caspary D.M., 2005. Hearing in laboratory animals: strain differences and nonauditory effects of noise. *Comp. Med.*, 55, p.12-23.
- Veissier I., Boissy A., Désiré L., Greiveldinger L., 2009. Animals' emotions: studies in sheep using appraisal theories. *Anim. Welf.*, 18, p.347-354.
- Velarde A., 2007. Agonistic behaviour. In : A. Velarde & R. Geers (Eds.), *On farm monitoring of pig welfare*, Wageningen Academic Publishers, Wageningen, Pays-Bas, p.53-56.
- Verdon M., Rault J.L., 2018. Agression in Group Housed Sows and Fattening Pigs. In : M. Spinka (Ed.), *Advances in Pig Welfare*, Woodhead Publishing Series in Food Science, Technology and nutrition, Duxford, Royaume-Uni, p.235-251.
- Verstegen M.W.A., Curtis S.E., 1988. Energetics of sows and gilts in gestation crates in the cold. *J. Anim. Sci.*, 66, p.2865-2871.
- Villain A.S., Hazard A., Danglot M., Guérin C., Boissy A., Tallet C., 2020. Piglets vocally express the anticipation of pseudo-social contexts in their grunts. *Sci. Rep.*, 10, 18496.
- Virolainen J.V., Love R.J., Tast A., Peltoniemi O.A., 2005. Plasma progesterone concentration depends on sampling site in pigs. *Anim. Reprod. Sci.*, 86, p.305-316.
- Volkman N., Brünger J., Zelenka C., Stracke J., Koch P., Kemper N., Spindler B., 2021. 'It's a long way until they STOP' – development of a software to annotate pecking injuries in turkeys. In : EAAP scientific committee (Ed.), *Abstracts of the 72nd Annual Meeting of the European Federation of Animal Science*, Davos, Switzerland, p.388.
- Wang Y., Yang W., Winter P., Walker L., 2008. Walk-through weighing of pigs using machine vision and an artificial neural network. *Biosys. Eng.*, 100, p.117-125.

- Wang Z., Shadpour S., Chan E., Rotondo V., Wood K.M., Tulpan D., 2021. ASAS-NANP SYMPOSIUM: Applications of machine learning for livestock body weight prediction from digital images. *J. Anim. Sci.*, 99, p.1-15.
- Weary D.M., Huzzey J.M., von Keyserlingk M.A.G., 2009. Board-Invited Review: Using behavior to predict and identify ill health in animals. *J. Anim. Sci.*, 87, p.770-777.
- Wegner K., Lambertz C., Daş G., Reiner G., Gaulty M., 2014. Climatic effects on sow fertility and piglet survival under influence of a moderate climate. *Animal*, 8, p.1526-1533.
- Wegner K., Lambertz C., Das G., Reiner G., Gaulty M., 2016. Effects of temperature and temperature-humidity index on the reproductive performance of sows during summer months under a temperate climate: Climatic Effects on Sow Reproduction. *J. Anim. Sci.*, 87, p.1334-1339.
- Wegner B., Spiekermeier I., Nienhoff H., Grobe-Kleinmann J., Rohn K., Meyer H., Plate H., Gerhardy H., Kreienbrock L., Beilage E., Kemper N., Fles M., 2019. Status quo analysis of noise levels in pig fattening units in Germany. *Livest. Sci.*, 230, 103847.
- Weldon W.C. Thulin A.J., MacDougald O.A., Johnston L.J., Miller E.R., Tucker H.A., 1991. Effects of increased dietary energy and protein during late gestation on mammary development in gilts. *J. Anim. Sci.*, 69, p.194-200.
- Welfare Quality, 2009. Welfare Quality® assessment protocol for pigs (sows and piglets, growing and finishing pigs). Welfare Quality® consortium, Lelystad, Netherlands.
- Weng R.C., Edwards S.A., Hsia L.C., 2009. Effect of Individual, Group or ESF Housing in Pregnancy and Individual or Group Housing in Lactation on Sow Behavior. *Asian-Aust. J. Anim. Sci.*, 22, p.1574-1580.
- Yang Q., Xiao D., Lin S., 2018. Feeding behavior recognition for group-housed pigs with the Faster R-CNN. *Comput. Electron. Agric.*, 155, p.453-460.
- Yin Y., Tu D., Shen W., Bao J., 2020. Recognition of sick pig cough sounds based on convolutional neural network in field situations. *Inf. Process. Agric.*, 8, p.2214-3173.
- Yu H., Lee K., Morota G., 2021. Forecasting dynamic body weight of nonrestrained pigs from images using an RGB-D sensor camera. *Transl. Anim. Sci.*, 5, p.1-9.
- Zhang J., Zhuang Y., Ji H., Teng G., 2021. Pig Weight and Body Size Estimation Using a Multiple Output Regression Convolutional Neural Network: A Fast and Fully Automatic Method. *Sensors*, 21, 3218.

2. Démarche et questionnement scientifique

2.1. Questionnement de la thèse

Les truies gestantes sont logées en groupe mais présentent une importante variabilité inter-individuelle des réponses physiologiques et comportementales aux différentes perturbations qu'elles peuvent subir au cours de leur gestation : stress thermique, maladie, mise en place de la hiérarchie, *etc.* (Durand *et al.*, 2021). Si l'effet de ces perturbations environnementales a été étudié sur les performances de reproduction, son effet sur le comportement des truies (alimentaire, social et activité physique) reste à clarifier. En effet, ces modifications comportementales peuvent modifier les besoins nutritionnels et l'état de bien-être de chaque truie.

La variabilité individuelle des besoins nutritionnels peut s'expliquer par des caractéristiques propres à l'animal (poids, âge, état corporel, stade de gestation), et notamment le niveau d'activité physique. Afin d'améliorer l'efficacité d'une stratégie d'alimentation sur mesure, fondée sur un ajustement individuel en énergie et lysine, la prise en compte de ces variations comportementales permettrait d'affiner la prédiction des apports nutritionnels pour chaque animal et chaque jour.

La variabilité individuelle de l'état de bien-être et de santé des truies peut s'expliquer par leur état émotionnel et leur expériences précédentes. L'étude du comportement et de ses variations à l'échelle individuelle pourrait permettre d'estimer l'état de bien-être et son évolution en fonction de divers événements pour chaque truie.

Ainsi, la problématique de la thèse est : ***Comment les données comportementales et environnementales peuvent améliorer l'estimation des besoins nutritionnels et du bien-être des truies en gestation ?***

Les objectifs et les hypothèses de la thèse sont les suivants :

- (i) *Evaluer les effets des perturbations environnementales sur le comportement et les besoins nutritionnels.*

La première hypothèse part du constat que différentes perturbations environnementales, s'étalant sur quelques jours auraient des effets mesurables et importants, à la fois sur le comportement (social, alimentaire, d'abreuvement, occupation de l'espace ou localisation dans l'espace) et sur les besoins nutritionnels (en lysine et énergie) des truies en gestation. De fortes variations individuelles sont attendues, notamment, en fonction de la parité ou du rang hiérarchique des truies. Ces effets seraient comparables à ceux obtenus lors d'expérimentations avec des perturbations de plus longues durées (par exemple, tout au long de la gestation) ou avec d'autres stades physiologiques (porc en croissance) tels que dans les études de Bench *et al.*, (2013), Bjerg *et al.* (2020), Lagoda *et al.* (2022) et Li *et al.* (2021).

- (ii) *Estimer les besoins individuels journaliers avec des méthodes de machine learning à partir de données comportementales et environnementales.*

La deuxième hypothèse suggère que la mobilisation des différentes données enregistrées sur les truies et dans leur milieu d'élevage par des capteurs et automates devrait permettre, à l'aide de méthodes de machine learning, de prédire leurs besoins nutritionnels journaliers. Des différences de prédiction seront attendues entre les capteurs et les différents algorithmes de machine learning utilisés. Cette hypothèse s'appuie sur les études de Kavlak *et al.* (2023) et Ollagnier *et al.* (2023) qui utilisent des techniques de machine learning avec des données issues d'automates d'alimentation pour prédire des maladies ou des épisodes de morsures de queues pour le porc en croissance.

- (iii) *Estimer le bien-être de chaque truie et leurs problèmes de santé d'une manière non invasive à l'aide de données comportementales.*

La dernière hypothèse explore l'ensemble des données comportementales enregistrées sur les truies pour estimer, à l'aide de méthodes de fouille de données et d'extraction par machine learning, le niveau de bien-être et santé des truies élevées en groupe. Des différences d'évolution de l'état de bien-être seront

attendues en fonction des perturbations environnementales induites. Cette hypothèse s'appuie sur les études de Horback et Parsons (2022) qui s'intéressent aux traits comportementaux pour évaluer l'effet de différents événements impactant le bien-être et les biais cognitifs des truies.

2.2. Démarche entreprise dans la thèse

La démarche mise en œuvre a été la suivante et est récapitulée dans la Figure 2-1.

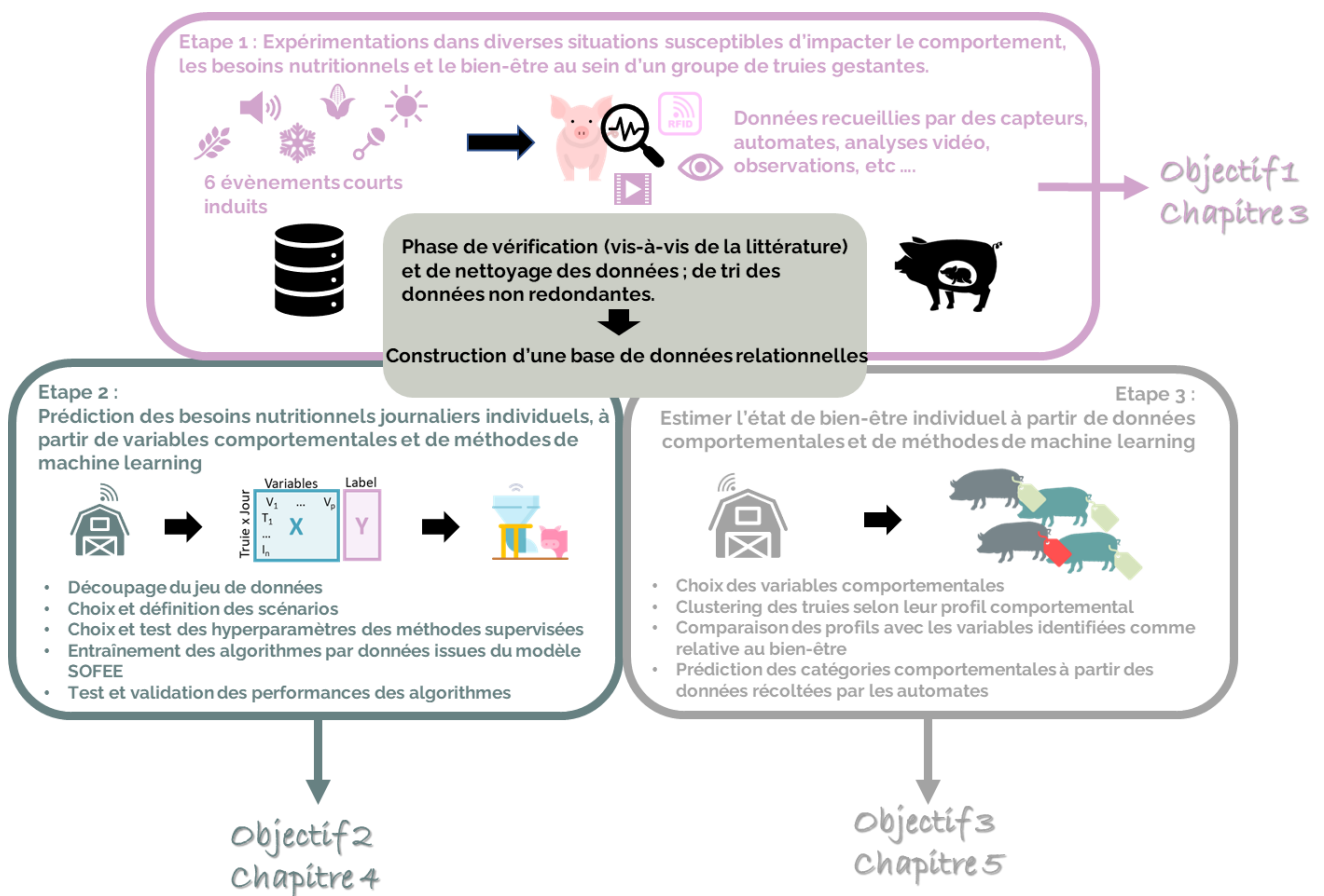


Figure 2-1 : Schéma de la démarche scientifique adoptée au cours de la thèse.

L'étape 1 a porté sur la réalisation d'expérimentations dans diverses situations tests susceptibles d'impacter le comportement et le bien-être au sein d'un groupe de truies gestantes. Cette étape a permis d'évaluer l'intérêt de nouvelles variables comportementales pour la nutrition (effet sur l'énergie et/ou les acides aminés). Une base de données provenant de capteurs, d'automates et d'annotations manuelles a ainsi été créée. Cette base de données variées, aussi

bien en terme de situation d'élevage que de critères de mesure, a permis de caractériser la variabilité inter-« truies » et inter-« élevages » des réponses comportementales, notamment alimentaires. Dans ce cadre, un stage doctoral au Québec, Canada (CDPQ et Université Laval) a été réalisé à la fin de la première année de thèse afin de collecter des données complémentaires. Cette étape 1 est développée dans le chapitre 3 du manuscrit qui répond à l'objectif 1.

L'étape 2 s'est intéressée à l'utilisation de méthodes de machine learning supervisées sur les données collectées pour prédire les besoins nutritionnels individuels et journaliers. Ces prédictions étaient comparées à celles produites par le modèle d'alimentation des truies gestantes (modifié à partir d'INRA porc) développé à INRAE nécessitant des informations de production sur chaque truie et chaque élevage. Le but était de prédire les besoins nutritionnels (en lysine digestible et énergie métabolisable) des truies gestantes à partir de variables comportementales et environnementales, facilement mesurables automatiquement en élevage. Neuf méthodes de machine learning ont été évaluées à travers cette étape. Les résultats, présentés dans le chapitre 4, répondent au second objectif.

L'étape 3 a porté sur l'utilisation de méthodes de machine learning pour estimer l'état de bien-être des truies gestantes en groupe. Une collaboration avec la start-up DILEPIX (Saint Jacques-de-la-Lande, France) a eu lieu dans ce cadre afin de développer un logiciel d'analyse d'images pour prédire automatiquement le comportement du groupe de truies. Cette entreprise est spécialisée dans l'utilisation de réseaux de neurones et d'algorithmes dans le domaine de l'agriculture. À partir des données comportementales enregistrées, trois groupes (clusters) ont été identifiés afin de regrouper les similarités de comportement des truies soumises à différentes conditions environnementales. Ces clusters ont été interprétés en fonction des caractéristiques des truies et de leur état de santé, afin d'établir un lien avec le bien-être. Puis, à partir des données enregistrées par l'automate d'alimentation et le logiciel d'analyse vidéo, chaque truie a été classée en fonction de son état de bien-être estimé. Cette partie de prédiction du bien-être de manière automatisée a également été testée sur les données issues de

l'expérimentation au Canada. Les résultats sont présentés dans le chapitre 5 pour répondre à l'objectif 3.

Enfin, la dernière étape de ce projet de recherche était de mettre au point un système d'alertes et d'actions pour anticiper la résolution de problèmes détectés tels que l'apparition d'une maladie par exemple. Cette étape est en cours de développement et s'est prolongée au-delà du délai initialement prévu en raison du temps de développement du logiciel d'analyse d'images nécessaire en amont de sa mise en place en élevage en temps réel. Une collaboration avec la start-up DILEPIX a été initiée en 2021 afin de développer le logiciel d'analyse d'images qui a permis d'obtenir une analyse du comportement à l'échelle du groupe a posteriori (Chapitre 4). Par la suite, le projet SOMOVE a été développé avec pour objectif la mise au point d'un système d'analyse vidéo automatique en temps réel permettant de mesurer l'activité physique individuelle d'une truie gestante et son comportement social. Il consiste également en la création d'un outil d'aide à la décision permettant la distribution d'une ration adaptée aux besoins nutritionnels journaliers, le suivi continu et automatisé du bien-être et de la santé et l'amélioration de ceux-ci grâce à des actions automatisées correctrices. Cette étape collaborative a occupé une part importante dans le doctorat via la recherche d'entreprises (6 tentatives) puis la participation à l'élaboration des dossiers de financements pour les appels à candidature CARNOT et CASDAR (financement acquis pour le projet SOMOVE en 2022). Le temps réel n'est toujours pas intégré actuellement dans le projet SOMOVE (2022-2025).

2.3. Références bibliographiques

Bench C.J., Rioja-Lang F.C., Hayne S.M., Gonyou H.W., 2013. Group gestation sow housing with individual feeding—II: How space allowance, group size and composition, and flooring affect sow welfare. *Livest. Sci.*, 152, p.218-227.

Bjerg B., Brandt P., Pedersen P., Zhang G., 2020. Sows' responses to increased heat load – A review. *J. Therm. Biol.*, 94, 102758.

Durand M., Dourmad J.Y., Largouët C., Tallet C., Gaillard C., 2021. Alimentation de précision des truies gestantes : prise en compte de la santé, du comportement et de l'environnement. *INRAE Prod. Anim.*, 34, p.293-304.

Horback K.M., Parsons T.D., 2022. Judgement bias of group housed gestating sows predicted by behavioral traits, but not physical measures of welfare. *PLoS ONE*, 17, e0264258.

Kavlak A.T., Pastell M., Uimari P., 2023. Disease detection in pigs based on feeding behaviour traits using machine learning. *Biosyst. Eng.*, 226, p.132-143.

Lagoda M.E., Marchewka J., O'Driscoll K., Boyle L.A., 2022. Risk factors for chronic stress in sows housed in groups, and associated risks of prenatal stress in their offspring. *Front. Vet. Sci.*, 9, 883154.

Li J., Li X., Liu H., Li J., Han Q., Wang C., Zeng X., Li Y., Ji W., Zhang R., Bao J., 2021. Effects of music stimulus on behavior response, cortisol level, and horizontal immunity of growing pigs. *J. Anim Sci.*, 99, skab043.

Ollagnier C., Kasper C., Wallenbeck A., Keeling L., Bee G., Bigdeli S.A., 2023. Machine learning algorithms can predict tail biting outbreaks in pigs using feeding behaviour records. *PLoS ONE*, 18, e0252002.

3. Quantification de l'effet de l'environnement sur le comportement du groupe de truies gestantes

Le chapitre 3 vise à évaluer l'impact d'évènements induits de courte durée sur le comportement et les besoins nutritionnels à l'échelle du groupe de truies.

Dans un premier temps, une base de données relationnelle a été créée afin de pouvoir étudier le comportement individuel des truies gestantes, à partir des données récoltées lors des différentes expérimentations. Par la suite, un exemple détaillé, des effets d'une situation de compétition alimentaire sur le comportement (alimentaire, abreuvement, social, localisation, activité physique) et les besoins en énergie métabolisable des truies gestantes, est présenté. Il est suivi d'un résumé des effets des autres évènements induits (conditions thermiques chaudes et froides, appauvrissement et enrichissement du milieu de vie et émissions sonores aléatoires).

3.1. Création d'une base de données relationnelle

Les résultats de cette partie sont issus d'un data paper (4) publié par Animal - Open Science.

Résumé en français

La base de données relationnelle SOWELL a été créée pour mieux comprendre le comportement et les réponses individuelles des truies gestantes confrontées à différents événements de courte durée : une situation de compétition alimentaire, des conditions thermiques chaudes et froides, un événement sonore (émissions sonores diverses aléatoires), un enrichissement (paille, cordes et sacs mis à disposition) et un appauvrissement (pas de paille, pas d'objets) du milieu de vie.

Les données ont été recueillies sur 102 truies croisées Large-White et Landrace équipées de capteurs d'activité, logées en groupe (16-18 truies par groupe) dans des salles de gestation équipées d'automates d'alimentation et d'abreuvement. Des caméras permettent également un enregistrement vidéo en continu des truies de la salle. Les comportements d'alimentation et d'abreuvement ont été extraits des enregistrements des automates. Les comportements sociaux, les activités physiques et la localisation dans la salle ont été répertoriés à la suite d'une analyse manuelle des vidéos à l'échelle individuelle. Un accéléromètre fixé sur l'oreille des truies a aussi permis d'enregistrer les activités physiques à l'échelle individuelle. L'activité physique a également été déterminée à l'échelle du groupe grâce à des analyses automatiques des vidéos en utilisant des techniques d'apprentissage profond (développement d'un logiciel via l'entreprise DILEPIX). Le poids corporel, l'épaisseur de lard dorsal et l'état sanitaire (propreté, dommages corporels) ont été enregistrés chaque semaine pendant toute la durée de la gestation. Les dernières données collectées dans la salle de gestation concernaient les conditions environnementales (température, humidité, niveau de bruit) et ont été enregistrées à l'aide de capteurs automatiques.

La base de données peut répondre à différents objectifs de recherche, à savoir la nutrition des truies, par exemple pour mieux calculer les besoins énergétiques en fonction des facteurs environnementaux, ou également le bien-être ou la santé pendant la gestation en fournissant des indicateurs.

A dataset to study group-housed sows' individual behaviours and production responses to different short-term events.

Durand M., Largouët C., Bonneau L., Dourmad J.Y., Gaillard C.

3.1.1. Specifications Table

Subject	<i>Behaviour and Health Management</i>
Specific subject area	Sow's behaviours in response to different short-term events
Type of data	MariaBD database structured in 18 tables
How data were acquired	Sows' feeding and drinking behaviours were collected thanks to two electronic feeders and two electronic water suppliers. Physical activities were extracted from accelerometers (individual scale) and automatic video analysis (group scale). Social behaviours and locations in the room were collected thanks to manual video analysis (individual scale). Environmental conditions (temperature, humidity, noise level) were recorded by sensors. Growth performances and body status were registered thanks to a body weight scale and a back fat thickness ultrasound portable device. Body conditions (cleanliness, body damages) were collected weekly.
Data format	The folder contains files under two formats: SQL (structure and data of each table) and .CSV files (data of each table).
Parameters for data collection	A total of 102 group-housed sows were followed during their gestation. Sows faced induced short-term events during their gestation: competitive feeding situations, cold and hot thermal conditions, unexpected sound events, enrichment or impoverishment of the pen. Each event followed a control week, that was without any unusual event.
Description of data collection	All data collected by sensors and automatons during the experiment were cleaned (removal of the outliers) and organised as a relational database.
Data source location	Pig Physiology and Phenotyping Experimental Facility (UE3P, INRAE, doi:10.15454/1.5573932732039927E12), Saint-Gilles (35590), France
Data accessibility	Repository name: Portail Data INRAE Data identification number: https://doi.org/10.57745/ER4WOJ
Related research article	Durand, M., Abarnou, J., Julienne, A., Orsini, C., Dourmad, J.Y., Gaillard, C., 2022. Effect of short-term events on the activity of gestating sows and their nutritional requirements, <i>Animal - science proceedings</i> , 13, p.445-447, https://doi.org/10.1016/j.anscip.2022.07.173 .

3.1.2. Value of the Data

- This data set presents a huge diversity of data collected on gestating sows at an individual scale: feeding and drinking behaviours, social behaviours, physical activities, reproductive performances, health and welfare status, and environmental conditions.
- High number of individual data, mostly time series, can be used by researchers for machine learning approaches or data mining tasks requiring large datasets.
- Different short-term events can be useful for scientists to better understand sow's behaviour and individual variability of response to these different types of events.
- Finally, access to the database is made public to contribute to future research in gestating sows' behaviour, health, nutrition or welfare fields.

3.1.3. Data Description

The dataset is composed of 18 tables structured as a relational database, using SQL standard (Table 3-1). These tables are organized in three groups (Figure 3-1):

- The tables named Farm, Sow, Pen, Group, Exp_sow, Event are linked to the sow's and experiment characteristics (in red, Figure 3-1)
- The tables named Water_measure, Feed_measure, Sensor, Sound_measure, Air_temperature_measure, Activity_measure contain data collected by automatons or sensors at different time scales (in green, Figure 3-1)
- The tables named Farrowing, Health_sow, Performances_sow, Sow_temperature, Activity_video_measure, Video_analysis contain other collected data (in blue, Figure 3-1).

Quantification de l'effet de l'environnement sur le comportement du groupe de truies gestantes

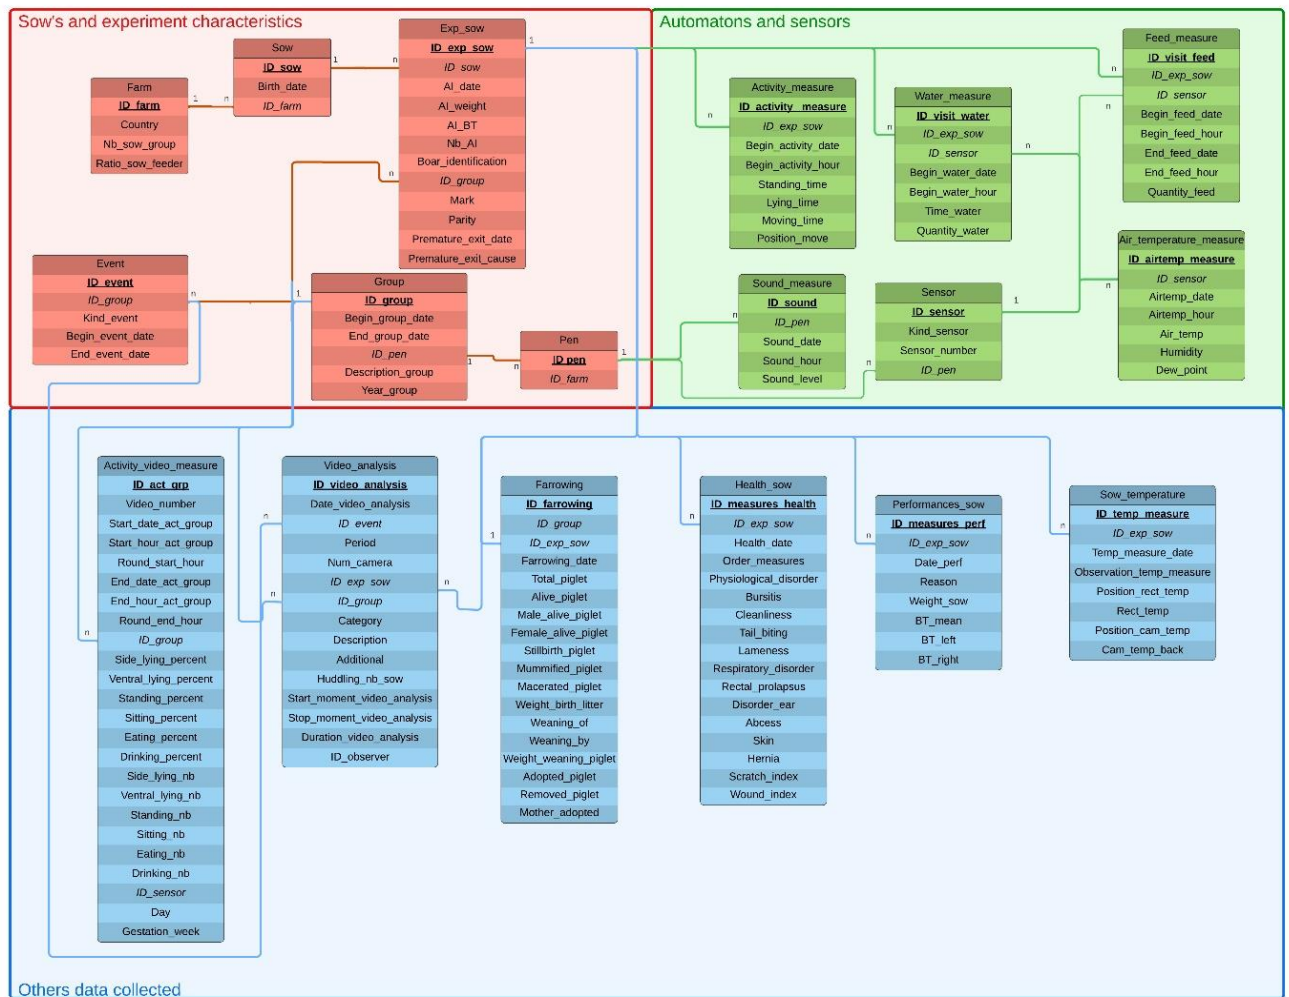


Figure 3-1: Schema of the relational database.

More precisely, Farm, Sow, Pen, Group, Exp_sow, Event and Sensor tables gather all information regarding, respectively: farms (country, number of sows per band and number of sow per feeder), sows (birth date and farm), gestation rooms (farm), groups (beginning and end date, gestation room), sows during an experiment (sow, artificial insemination date and boar identification dose, body condition at insemination, parity), events (date and kind), and sensors or automatons used (type, room of gestation).

Table 3-1: Description of the 18 tables of the relational database: primary and foreign keys, number of columns and rows.

Table's name	Primary Key ¹	Foreign keys ²	Col.	Rows
<i>Sow's and experiment characteristics</i>				
<i>Farm</i>	ID_farm (farm identification code)	none	4	3
<i>Sow</i>	ID_sow (sow identification number)	ID_farm	3	58
<i>Pen</i>	ID_pen (room identification code)	ID_farm	2	2
<i>Group</i>	ID_group (group identification code)	ID_pen	6	5
<i>Exp_sow</i>	ID_exp_sow (identification code of the sow in a gestation)	ID_sow; ID_group	12	102
<i>Event</i>	ID_event (event identification code)	ID_group	5	5
<i>Automatons and sensors</i>				
<i>Water_measure</i>	ID_visit_water (drinker visit identification number)	ID_exp_sow; ID_sensor	7	76 911
<i>Feed_measure</i>	ID_visit_feed (feeder visit identification number)	ID_exp_sow; ID_sensor	8	43 024
<i>Sensor</i>	ID_sensor (sensor or automaton identification code)	ID_pen	4	24
<i>Sound_measure</i>	ID_sound (sound measure identification code)	ID_pen	5	2 250 055
<i>Air_temperature_measure</i>	ID_airtemp_measure (air measure identification code)	ID_sensor	7	3 13 978
<i>Activity_measure</i>	ID_activity_measure (activity measure identification code)	ID_exp_sow	8	106 408
<i>Others data collected</i>				
<i>Farrowing</i>	ID_farrowing (farrowing identification code)	ID_group; ID_exp_sow	18	85
<i>Health_sow</i>	ID_measures_health (health measure identification number)	ID_exp_sow	17	1 036
<i>Performances_sow</i>	ID_performances (performance measure identification number)	ID_exp_sow	8	1 193
<i>Sow_temperature</i>	ID_temp_measure (body temperature measure identification number)	ID_exp_sow	12	453
<i>Activity_video_measure</i>	ID_act_group (group activity measure identification number)	ID_group; ID_sensor	24	29 330
<i>Video_analysis</i>	ID_video_analysis (manual video analysis measure identification number)	ID_event; ID_exp_sow; ID_group	15	170 174

Col. = Number of columns of the table; Rows = Number of rows of the table ; ¹ Primary keys are unique for the table. ; ² Foreign keys are used to link data between tables of the database.

Water_measure and Feed_measure tables describe all visits to the automatons (sow number, automatons used, date and hour of the beginning of the visit and its duration, and the amount eaten or drank). Sound_measure, Air_temperature_measure and Activity_measure tables gather the recordings of, respectively, the sound level meter (every seconds), the thermometer at group scale (every 5 minutes) and the accelerometers (every 30 minutes) at individual scale (date and hour of the measure, values measured). Farrowing table contains the number of piglets and the litter's weight at birth and weaning. Health_sow and Performances_sow tables gather the weekly recording of health problems, and body weight and back fat thickness. The rectal and body temperatures are saved in Sow_temperature table including the sow's posture at measurement. Activity_video table gathers the data provided by automatic video analysis at group level (every 30 minutes).

3.1.4. Experimental Design, Materials and Methods

i. Experimental protocol

The experiment took place at Pig Physiology and Phenotyping Experimental Facility (UE3P, INRAE, Rennes, France, doi:10.15454/1.5573932732039927E12). It included 102 crossbred sows (Landrace x Large White), divided into five groups (approximately 20 sows), monitored throughout their gestation. The sows were group-housed (a few days after their artificial insemination) in a pen with a concrete floor enriched with straw (replaced daily), and the provision of two "playing" chains. After 30 days, the sows not successfully inseminated (identified by echography) were moved out of the pen and of the experiment. The pen dimensions were 7.5 by 8.2 m, for a space allowance of 3.1 m²/sow for an initial group of 20 sows. Each sow was equipped with two radio frequency identification tags: one for the two self-locking electronic feeders (Gestal, JYGA Technologies Inc., Canada), and the other for the two electronic drinkers (Asserva, France). The feed was a blend of two diets (Low and High nutrient content), mixed and delivered daily by the feeder to each individual sow. A gestating sows' nutritional InraPorc model revised by Gaillard *et al.* (2019) was used to estimate the daily nutrient requirements of each

sow. Based on this information, the quantity of feed to supply and the daily proportions of the two diets to blend were calculated for each sow. With this feeding strategy, the quantity of feed to supply was individualised but fixed for each sow during all their gestation, except for a bump feeding of 500 g/d starting at 86 days. Two ceiling-mounted cameras (RS-CCPOE280IR4-DH, Ro-main Inc., Canada) provided a continuous day and night recording.

ii. Data acquisition and pre-treatment

Feeding and drinking behaviours were automatically recorded using automatons (electronic feeders and drinkers). Ambient temperature and humidity were recorded thanks to sensors fixed in the gestation room at 1.8 m high from the ground (Lascar Electronics, United Kingdom, precision $\pm 0.45^{\circ}\text{C}$), and the noise level by a sensor near one of the drinkers (Velleman Group, Belgium). Manual video analysis was carried out by trained observers to monitor individual social behaviour, localisation, occupation, and physical activity on defined short periods of 5-36 h. Sows were also equipped with an ear tag accelerometer (RF-Track, France) continuously recording their physical activities. Physical activities were also automatically analysed at a group scale from video recordings by a convolutional neural network algorithm (DILEPIX, France; Durand *et al.*, 2022). Data extracted from automatons and sensors were preprocessed to filter the outliers and aggregated daily sensors' files to feed a relational database. Row data from the accelerometers were not included in the database when the cumulated duration per hour was not equal to 60 minutes, and in case of duplicated rows. All the identification codes of automatons or sensors were linked to the experiment number of each sow.

Every Monday morning during the gestation, sows were led to a nearby room in order to measure their body weight (Schippers, The Netherlands, precision ± 0.5 kg), and their back-fat thickness using an ultrasound portable device (Imago, ECM, France). Body condition, including skin lesions and potential health problems, were also simultaneously recorded based on the Welfare Quality® Assessment (Dalmau *et al.*, 2009). At the end of the gestation (*i.e.* one week before parturition), sows were transferred to the farrowing room, after recording their body weight and

their back-fat thickness. During the first 6 hours after farrowing, the body weight of the sow and its piglets were registered, as well as the number of piglets alive or stillbirth. The number of artificial inseminations, the date, and the boar identification dose were also recorded.

iii. Induced short-term events

In addition to the setting up of the hierarchy at the constitution of the group, different perturbations events were induced during the experiment: a competitive feeding situation, cold and hot thermal variations, a sound event, and last, an enrichment and an impoverishment of the pen (Figure 3-2). A competitive feeding situation was created by closing one of the two available feeders for 5 consecutive days and nights. This was performed twice during gestation. The cold thermal condition was induced for three days and nights by increasing the ventilation frequency, opening the windows, and setting the thermostatic control at $12 \pm 2^\circ\text{C}$. Similarly, a hot thermal condition was induced thanks to two heaters, decreased of ventilation frequency and setting the thermostatic control at $32 \pm 2^\circ\text{C}$. The noise event was composed of random emission of 40 short sounds (alarms, animals, metallic and human voices) of 30 seconds, every 10 minutes for four consecutive hours twice a day (during the afternoon resting period, and during the night feeding period). The enrichment consisted of an extra straw supply in the pen in the first repetition and in the second by the provision of jute bags, a brush, and ropes inside the pen. During the impoverishment event, there was no straw or games in the pen. Each "event week" followed a "control week" (without any unusual perturbation event induced).



Le développement d'une base de données relationnelle était nécessaire pour les étapes d'analyse décrites ci-après dans la thèse. Différentes technologies ont été utilisées afin de mesurer le comportement des truies, soumises à différentes perturbations de l'environnement d'élevage.

Quantification de l'effet de l'environnement sur le comportement du groupe de truies gestantes




Figure 3-2: Summary of the experimental design and data collection on gestating sows.

3.2. Exemple détaillé d'une situation de compétition alimentaire

Les résultats de cette partie sont issus d'un article publié (5) dans Applied Animal Behaviour Science.

Résumé en français

Dans les groupes de truies gestantes, l'accès à l'alimentation peut être une source de tension et induire de l'agressivité et des interactions agonistiques. L'utilisation d'automates d'alimentation pour truies pourrait permettre de s'assurer que chaque truie consomme la totalité de sa ration dans un enclos collectif. L'objectif de cette étude était d'évaluer l'impact d'une situation de compétition alimentaire liée à la gestion des automates, sur le comportement général, l'activité physique et les besoins énergétiques des truies gestantes.

Au total, 32 truies, réparties en deux groupes, ont participé à l'étude. La compétition alimentaire a été créée en fermant l'accès à l'un des deux automates d'alimentation disponibles dans chaque salle de gestation pendant 5 jours consécutifs. Cette situation a été répétée deux fois, chaque fois précédée d'une semaine de contrôle pendant laquelle les deux automates étaient disponibles. Des automates, des accéléromètres et des analyses vidéo manuelles ont enregistré les comportements alimentaires, d'abreuvement et sociaux de chaque truie, son activité physique, son occupation et son emplacement dans l'enclos. Des modèles linéaires à effets mixtes ont été utilisés, incluant les effets fixes du traitement (compétition alimentaire ou contrôle), de la répétition (première ou deuxième période), du groupe (2 modalités), du classement social (3 modalités), leurs interactions et l'effet aléatoire de la truie.

Dans les situations de compétition alimentaire, le nombre d'interactions négatives a doublé ($P < 0,001$), les truies passant plus de temps debout le matin ($P < 0,001$) et dans les zones situées plus loin de l'automate ($P = 0,005$). Le nombre et la durée des visites nutritives n'ont pas été affectés par la compétition alimentaire, tandis que le nombre et la durée des visites non nutritives ont diminué ($P < 0,001$). Ce dernier effet était plus marqué chez les truies de rang

inférieur et de rang supérieur, contrairement à celles de rang intermédiaire (interaction, $P < 0,01$). Pendant la compétition alimentaire, les truies ont passé moins de temps à dormir ($P < 0,01$) et plus de temps à explorer l'automate d'alimentation ($P < 0,001$). Ces effets étaient moins marqués pendant la deuxième répétition. Les besoins en énergie métabolisable (EM) calculés, et donc la quantité d'aliment nécessaire, ont augmenté pendant la compétition alimentaire ($P < 0,001$). L'effet était plus important pendant la deuxième répétition que pendant la première (interaction, $P = 0,04$). En outre, le besoin en EM était plus important pour les truies de rang supérieur que pour les truies de rang inférieur ($P < 0,001$). La compétition alimentaire n'a pas eu d'effet significatif sur le poids et l'épaisseur de lard dorsal, ni sur les critères de santé. En conclusion, ces résultats indiquent que les dysfonctionnements à court terme d'un automate d'alimentation affectent le comportement général des truies et augmentent les interactions négatives et les besoins énergétiques, sans affecter leurs performances ou leur santé.

Effects of a competitive feeding situation on the behaviour and energy requirements of gestating sows.

Durand M., Dourmad J.Y., Julienne A., Couasnon M., Gaillard C.

3.2.1. Introduction

In Europe, sows are group-housed during most of their gestation, according to European Union Legislation (Council Directive 2001/88/CE). Unlike individual stalls, loose housing systems modify the level of physical activity, by allowing freedom of movement and social interactions (Spoolder and Vermer, 2015 ; Koketsu and Lida, 2017). Moreover, as pigs are social animals, a hierarchy naturally emerges each time the sows are mixed. This hierarchy is influenced by many factors such as the composition and size of the group, as well as the availability of equipment of interest to sows in the pen (Verdon and Rault, 2018a). Aggression between sows due to the new hierarchy may cause sow culling (due to severe injuries like lameness or spinal cord injuries) and reduce reproductive performance (Hemsworth, 2021). Access to feed is mainly influenced by the hierarchical order of the group, the order of visit to the feeder may therefore be a precise indicator of hierarchy (Lanthony *et al.*, 2022). Moreover, 69 % of aggression and intimidation behaviours occur near the feeding area instead of the resting area (Norrington *et al.*, 2019). This point is particularly important due to the restricted rations fed during gestation, which are lower than the voluntary consumption of sows (D'Eath *et al.*, 2018). Many research projects have focused on finding solutions based on nutrition or pen equipment to reduce aggression and ensure adequate feed supply to each sow. In this context, feeding technologies were developed, such as Electronic Sow Feeders (ESF), which offer new feeding strategies based on a better adjustment of feed supply to the nutritional requirements of individual sows (precision feeding). The ESF allows subordinate sows and gilts to eat their own entire ration, without pressure from dominant sows. The data recorded by the ESF may also be used to detect potential changes in feeding behaviour patterns that may for example point to health disorders (Vargovic *et al.*, 2021).

The nutritional model developed by Gaillard *et al.* (2019) for estimating daily requirements and feed allowance is based on the characteristics of gestating sows (age, parity, body weight), and also recently integrated the level of activity per day for the calculation of estimated metabolizable energy (ME) requirements. The level of physical activity may be influenced by the characteristics of the sows and the housing system (Gaillard *et al.*, 2021), but also by different events that may occur during gestation, for example, thermal conditions (Abarnou *et al.*, 2022) or noise.

The objective of this study was to evaluate the effect of two consecutive induced competitive feeding situations during short periods on the behaviour (feeding, drinking, social interactions, behaviour, location in the pen, physical activity) of gestating sows and their impacts on nutritional requirements. The hypotheses were that feed competition would induce a higher interest in the feeder, an increase in agonistic behaviours and in the time spent in a standing position, which may increase daily ME requirements (Durand *et al.*, 2021). Repeating the feed competition situation may decrease agonistic behaviour and the level of activity, due to the habituation of the sows.

3.2.2. Materials and methods

This study was carried out from July to November 2020, at the Pig Physiology and Phenotyping Experimental facility (doi: 10.15454/1.5573932732039927E12) of the French National Research Institute for Agriculture, Food and Environment located in Saint-Gilles (France). Ethical approval concerning the French legislation on experimental animal care was approved by the Ethics Committee in Animal Experimentation in Rennes, France (authorization on living animals No. 25883-2020070711528084).

i. Animals and management

A total of 32 crossbred gestating sows (Large White x Landrace) were involved in the experiment between the third and the eighth week of gestation. The 24 multiparous (parity rank between 2 to 9) and 8 primiparous sows were divided

into two groups (A: 17 sows with 4 primiparous, and B: 15 sows with 4 primiparous). Sows were at five weeks of gestation in group A and three weeks in group B. At the start of the experiment, in group A and B, the mean body weight was 244.7 ± 39.0 kg and 223.3 ± 41.0 kg, respectively; and the mean backfat thickness was 17.2 ± 2.7 mm and 15.1 ± 2.9 , respectively. No animals have been removed and the groups remained stable during the experiment.

Each group of sows was housed in a room of 7.2 m by 8.2 m, on a concrete floor enriched by the addition of straw (in areas A2, A3 and A4, Figure 3-3) and the presence of two "playing" chains. The space allowance in the gestation room was $3.6 \text{ m}^2/\text{sow}$. The bedding was fully replaced daily in the straw-covered areas. Each room was equipped with two self-locking ESF (Gestal, JYGA Technologies Inc, Québec, Canada) and two electronic drinkers (Asserva, France) offering ad libitum access to clean water. Each sow was equipped with two Radio Frequency Identification tags: one to be identified by the feeders and one by the drinkers.




Figure 3-3: The organization of the gestating sow pen including the automatons and sensors.

Feed was delivered daily and individually at the ESF in doses of 300 g available every 1 minute and 30 seconds to avoid leftovers. Sows could eat their entire ration in one visit, provided they stayed inside the ESF long enough for the next portion to be delivered. The ration was a blend of two diets (one with a Low and one with a High nutrient content, Table 3-2) whose ingredients are presented

in Gaillard and Dourmad (2022). The blend of the two diets was calculated daily and individually to meet the SID lysine requirements. This was achieved using the nutritional model previously revised by Gaillard *et al.* (2019). The quantity of feed supplied was determined individually and was stable during gestation (2.73 ± 0.79 kg/day), except for a bump feeding of 500 g/d starting at 85 days (*i.e.* after the end of the experimental period). Under routine farm conditions, ESFs remain open at all time, and feeding starts at midnight, to reduce levels of social tensions and aggressions.

Table 3-2: Composition of the two diets (low and high nutrient content) used for feed allowance, expressed in g per kg of feed.

g/kg of feed	Low nutrient content diet	High nutrient content diet
Analysed levels		
Dry matter	897	892
Crude Protein	110	155
Crude fat	38.5	39.0
Crude fibre	47.4	39.9
Neutral Detergent Fiber	160	138
Acid Detergent Fiber	53.8	45.2
Acid Detergent Lignin	8.9	8.4
Lysine content	4.21	8.43
Phosphorus content	4.42	5.55
Gross energy, MJ/kg	16.3	16.3
Calculated contents¹		
ME ² , MJ/kg	12.7	13.0
SID ³ lysine,	3.30	8.50
Digestible Phosphorus	2.31	3.27
Total calcium	7.38	9.79

¹Calculated according to INRA-AFZ, 1984

²Metabolizable energy

³Standardized ileal digestible

Two RS-CCPOE280IR4-DH cameras (Ro-main Inc., Québec, Canada), were mounted on the ceiling of each room and recorded the sows continuously, day and night (Figure 3-3).

ii. Feed competition

The competitive feeding situation was created artificially by closing one of the two available ESF (used routinely in this farm) for 5 days (from Monday 12:00 h to Friday 12:00 h). This short-term period was chosen to represent a dysfunction of an ESF without a quick repair. Doubling the number of sows per feeder did not prevent any sows from accessing the feed.

This was performed twice during gestation; one ESF was closed during period one ("Restricted" treatment: R, Period 1) and the other during period two (R, Period 2). During each week preceding a "Restricted" week, the two feeders were opened and these weeks were used as control weeks (Control: C, periods 1 and 2). The two groups of sows were not exposed to the restriction at the same stage of pregnancy: group A was restricted at weeks six and eight after artificial insemination, and group B at weeks four and six.

iii. Data collection and calculations

Feeding and drinking behaviours were automatically recorded using automatons. Daily time spent at the feeders, the number of visits with ("nutritive visit") or without ("non-nutritive visit") feed consumption, and the amount of feed consumed were determined based on ESF records. Daily time spent at the troughs, the number of visits and water consumption were determined based on the electronic drinker records. The sow order of visits to the feeder for the first nutritive visit of the day was used as an indicator of hierarchical status within the group, with the method developed by Lanthony *et al.* (2022). The social ranking was initially identified based on the data obtained during the entire gestation. Three categories were created according to the first and third quartiles: low (LR), intermediate (IR) and high (HR) ranking sows. The social ranking throughout the entire gestation was compared to the ranking observed each day during the experiment, and to the mean ranking over the 4 weeks of the experiment.

Manual video analysis was carried out by three trained observers using the Observer software (Noldus, Wageningen, The Netherlands) during the first 36 h of each period. The observers were trained to have the same labelling on a sample

of videos. Within each repetition and group the videos from the C and R weeks were analysed by the same observer. Each sow was individually marked on her back to follow it during the behavioural sampling. The location of the sows in the pen was recorded continuously (areas 1 to 4, A1 to A4, Figure 3-3). A sow was considered to be in an area when it had both anterior legs in that area. The sow's occupation (the behaviour performed by the sow at a given time) and social interactions were also recorded (Table 3-3, adopted from Velarde and Geers, 2007).

Table 3-3: Description of the sows' behaviours recorded manually from videos.

Behaviour	Description	
Occupation		
Exploring the ESF	explores the ESF (contact with the snout).	
Exploring the floor	explores the floor, contact with the snout or digs with paws.	
Sleeping	lies without moving (during more than 30 sec) body or eyes	
Observing	raises her head and may move.	
Social interaction		
Positive	Lying in body contact	lying in contact with the body of another sow (legs, back, shoulders, ...)
	Snout to snout	touches another sow's snout with her snout
	Sniffing	sniffs or licks the body of another sow
Negative	Head knocking	knocks against another sow with a quick vigorous upward thrust of the head
	Pushing	uses shoulders or another part of the body (except the head) to move another sow aside while putting pressure on the body
	Biting	with the mouth open, and contact with the body of another sow
	Threatening	stares at another sow and walks away
	Fleeing	avoids another sow
	Attacking	runs into another sow

Every Monday morning during the gestation, the sows were transferred to another room for a few minutes to measure their body weight with a scale (Schippers, The Netherlands, precision ± 0.5 kg), and their back-fat thickness on both right and left sides using an ultrasound portable device (Imago, ECM, France), 65 mm from the midline, behind the last dorsal rib, on the back of the animal, by the same person each time. Skin lesions (severity and frequency), as well as health problems, were also simultaneously recorded. An index was calculated as the sum

of skin lesions pondered by their severity (1: for lesions under 5 cm, 5: for lesions over 5 cm, 10: for bloody or deep lesions). Skin lesions were divided into two categories for two different indexes: the scratch index (for long and straight lesions) and the wound index (round lesions). Only skin lesions without sign of healing process (thick, solid crust, no bloody or weeping, no redness/heat or open wounds) were counted, to avoid old lesions from the previous week. The data collected on Monday were linked to the previous period to see the effect over the time.

Twenty-five sows (12 in group A and 13 in group B; 7 in LR sows, 10 in IR sows and 8 in HR sows) were equipped with a randomly functional accelerometer fixed on an ear tag (RF-Track, Rennes, France) in order to continuously record the number of position changes, the daily time spent lying down (flank fully on the ground or not), standing (all 4 legs standing still), or walking (1 or more legs active) and therefore to recalculate ex-post the ME requirements for maintenance. The accelerometer's specificity and sensitivity measured in similar straw-bedding conditions were 75.9 % and 67.5 %, respectively, based on Marcon *et al.* (2017). The coefficient of $0.30 \text{ kJ ME.kg}^{-0.75}.\text{d}^{-1}.\text{min}^{-1}$ for the activity maintenance (standing posture) and $440 \text{ kJ ME.kg}^{-0.75}.\text{d}^{-1}$ for total maintenance (for 4 h/d standing activity) were used for determining ME requirements for maintenance (Noblet *et al.*, 1993). ME for maintenance did not integrate the requirements for litter and placenta growth.

iv. Statistical analysis

The statistical analyses were carried out using R studio software (version 4.1.2, R Foundation, Vienna, Austria). Due to the lower number of primiparous, the hierarchy ranking of every sow were used instead of the parity for the rest of the statistical analysis to obtain three balanced groups. To verify that the hierarchy ranking is indeed linked to the age of the sow, correlations of Pearson between the different hierarchy rankings, the age and parity of the sows were calculated using the "cor.test" function of the "stats" package (Best and Roberts, 1975).

Linear mixed-effects models were used with the “lme” function of the “nlme” package (Pinheiro *et al.*, 2022). The models included the fixed effects of the treatment (C. vs. R.), the period (1 vs. 2), group (A vs. B), social ranking (LR vs. IR vs. HR), their two-way interaction with the treatment and the random effect of each sow. The feeding and drinking behaviours were analysed as a daily average, over the 5 experimental days. The occupation, location, and social behaviours were analysed as an average of the first 36 hours of the experiment. The physical activity data were analysed as a daily average over the 5 experimental days. The nutritional requirements were analysed as a daily average of the 5 experimental days. The “performance” package (Lüdecke *et al.*, 2021) made it possible to choose the best model, by potentially removing some non-significant interactions or factors, based on multiple indices of model quality and goodness of fit (r-squared, root-mean-square error (RMSE), intraclass correlation coefficient). A *P*-value < 0.05 was considered significant. For each model built, every hypothesis (normality of predicted variable and normality of model residues) were validated.

3.2.3. Results

i. Hierarchy status

Significant correlations appeared between the ranking established over the entire gestation and the ranking established during the 4 weeks of the experiment (correlation coefficient - $R^2 = 0.91$; $P < 0.001$); and between the ranking observed throughout the entire gestation and the one determined each day of the experiment ($R^2 = 0.83$; $P < 0.001$). Throughout the entire gestation, the social ranking was correlated with the parity of the sow ($R^2 = 0.76$, $P < 0.001$), and with its age ($R^2 = 0.75$, $P < 0.001$). These results showed good stability of the social ranking throughout the entire gestation and allowed its use as a fixed effect (LR, IR, and HR) in the statistical models.

ii. Feeding behaviour

The total number of visits per day (Table 3-4 and Figure 3-4.1.) was lower for treatment R compared to treatment C, by 28 % for LR and by 34 and 37 % for IR and HR sows, respectively ($P = 0.004$), and greater in period 2 compared to period 1 ($P < 0.001$). The number of nutritive visits was 1.0 time/d on average (Table 3-4), regardless of the treatment, period, group, or social ranking, while the number of non-nutritive visits was significantly affected by all factors (Table 3-4). The difference between treatments R and C for the non-nutritive visit was lower for LR sows (-35 %, $P = 0.004$) compared to IR and HR sows (-41 and -43 %, respectively, $P = 0.004$). The sows from group B made more non-nutritive visits during treatments C than R (6.35 and 3.90 visits/d, respectively), and than group A despite treatments C or R (4.01 and 2.30 visits/d, respectively, $P = 0.08$). The number of non-nutritive visits was greater during the second period compared to the first ($P < 0.001$, Table 3-4), and increased with the social rank of the sow ($P = 0.006$, Table 3-4).

Table 3-4: Effect of the experimental treatment^a, period^b, group^c and hierarchical status of sows^d, on the feeding and drinking behaviour (number and duration of visits, and the amount of feed and water consumed), on the social behaviour (number of positive and negative interactions) and on the occupation.

	Treatment ^a		Period ^b		Group ^c		Hierarchy ^d			Statistical analysis ^e								
	C	R	1	2	A	B	LR	IR	HR	RMSE	T	P	G	H	TxP	TxG	TxH	
Number of sows	32	32	32	32	17	15	10	13	9	-	-	-	-	-	-	-	-	
Feeding behaviour																		
Visits to feeders, nb/d ^f																		
Total	6.12	4.07	4.68	5.51	4.16	6.15	4.24 ^a	4.69 ^a	6.57 ^b	2.2	0.004	< 0.001	0.003	0.006	-	0.07	0.004	
Nutritive visit	1.02	1.02	1.02	1.00	1.01	1.02	1.00	1.01	1.04	0.305	1.00	0.60	0.64	0.49	-	-	-	
Non-nutritive visit	5.11	3.05	3.66	4.50	3.16	5.12	3.24 ^a	3.68 ^a	5.53 ^b	2.215	< 0.001	< 0.001	0.003	0.006	-	0.08	0.004	
Time in the feeder, min/d																		
Total	57.4	46.0	50.8	53.1	56.1	47.5	58.6	55.8	39.6	30.64	0.19	0.12	0.28	0.63	0.24	0.18	0.40	
Nutritive	32.3	30.9	32.5	30.6	35.5	27.3	38.4 ^a	35.3 ^a	17.4 ^b	12.14	0.22	0.56	0.37	0.04	0.009	-	-	
Non-nutritive	28.4	16.3	20.9	23.8	24.1	20.4	20.1	19.7	28.9	30.86	< 0.001	0.25	0.52	0.50	-	-	-	
Feeder occupancy, h/d	7.22	12.3	6.56	6.81	7.53	5.86	4.33 ^a	6.35 ^b	2.64 ^c	0.71	0.009	0.54	< 0.001	< 0.001	-	-	0.12	
Amount of feed, kg/d	2.72	2.72	2.72	2.72	2.66	2.76	2.49 ^a	2.80 ^b	2.82 ^b	0.03	-	-	0.41	0.006	-	-	-	
Drinking behaviour																		
Visits to troughs, nb/d ^f	12.2	12.0	12.4	11.7	10.6	13.6	10.3 ^a	11.0 ^a	15.3 ^b	5.10	0.11	0.06	0.14	0.07	-	0.03	0.003	
Time in the stall, min/d	7.42	7.65	6.99	8.07	6.19	8.99	6.26	6.69	10.0	2.515	0.23	< 0.001	0.13	0.17	0.13	0.28	0.12	
Amount of water, L/d	8.53	8.67	8.24	8.96	6.69	10.7	7.23	7.62	11.4	2.887	0.37	0.01	0.11	0.23	-	-	0.03	
Positive interactions^g																		
Total, nb over 36 h	33.9	27.4	32.7	22.8	29.4	29.9	33.8 ^a	26.6 ^b	29.9 ^a	7.57	0.11	< 0.001	0.81	0.03	-	-	-	
Lying in body contact, nb over 36 h	14.2	13.6	13.5	14.5	11.7	16.4	15.3 ^a	14.3 ^a	11.6 ^b	3.63	0.04	0.003	< 0.001	0.006	-	-	-	
Snout to snout, nb over 36 h	8.84	4.69	7.97	2.00	7.37	4.60	7.48	5.33	5.92	3.45	0.08	< 0.001	0.003	0.10	-	-	-	
Sniffing, nb over 36 h	10.8	9.10	11.2	6.24	10.3	8.96	11.0 ^a	6.96 ^b	12.3 ^a	4.99	0.36	< 0.001	0.14	0.008	-	-	-	
Negative interactions^g																		
Total, nb over 36 h	4.90	12.6	9.81	10.3	15.4	3.26	6.74 ^a	10.0 ^a	13.1 ^b	8.02	< 0.001	< 0.001	< 0.001	0.04	-	-	-	
Head butting, nb over 36 h	2.22	3.27	3.70	1.12	4.47	0.99	2.18	3.18	3.24	3.37	< 0.001	< 0.001	< 0.001	0.50	-	-	-	
Pushing, nb over 36 h	1.13	3.99	2.54	4.02	4.67	0.95	0.92 ^a	3.49 ^b	4.93 ^c	2.49	< 0.001	0.69	< 0.001	0.01	-	-	-	
Biting, nb over 36 h	0.25	1.45	0.73	1.72	1.68	0.24	0.25 ^a	0.67 ^b	2.37 ^b	1.78	0.005	0.26	0.006	0.007	-	-	-	
Threatening, nb over 36 h	0.06	1.16	0.23	2.00	1.25	0.19	0.29 ^a	0.64 ^b	1.47 ^b	1.40	0.19	< 0.001	< 0.001	0.002	-	-	-	
Fleeing, nb over 36 h	0.51	2.46	2.17	1.26	2.82	0.75	2.96 ^a	1.67 ^b	1.13 ^c	2.30	< 0.001	< 0.001	< 0.001	0.03	-	-	-	
Attacking, nb over 36 h	0.43	0.30	0.42	0.17	0.51	0.14	0.11 ^a	0.38 ^b	0.53 ^b	0.64	0.79	0.03	0.005	0.04	-	-	-	
Occupation																		
Sleeping, h over 36 h	26.0	25.2	25.3	25.8	25.4	25.5	25.5	25.8	24.9	2.78	0.008	0.03	0.70	0.37	-	-	-	
Observing, h over 36 h	4.73	3.53	4.58	2.51	4.40	3.39	4.14	3.75	4.02	1.07	0.15	< 0.001	0.005	0.38	-	-	-	
Explore the ESF, h over 36 h	1.05	1.76	1.76	0.97	1.88	1.06	1.57	1.62	1.30	0.57	< 0.001	< 0.001	0.001	0.72	-	-	-	
Explore the floor, h over 36 h	2.77	2.86	2.83	2.83	2.80	2.87	3.37 ^a	2.70 ^b	2.46 ^c	0.75	0.36	0.63	0.73	0.08	-	-	-	

^a Treatment (T): C=Control; R=Restricted access to the feeder

^b Two 5-day periods (P, period 1 and period 2) of restricted access to the feeder

^c Two groups (G) of sows (A and B)

^d Hierarchy (H) ranking of sows: LR=low, IR=intermediate, HR= high

^e RMSE= Root Mean Square Error. P values of fixed effects and TxP, TxG and TxH interactions (when there are significant) on a generalized linear model with a random sow effect. Letters (a, b, c) were add to significant difference ($P < 0.05$) between the modality of the hierarchy.

^f Nb/d = number per day

^g Nb = number




Figure 3-4: Effect of the experimental treatment (Control vs. Restricted access to the feeder) and the social ranking (low (LR), intermediate (IR) and high ranking (HR) sows, on the feeding (1.) and drinking (2.) behaviour patterns, as a mean on the five experimental days.

The treatment, period, group or social ranking had no significant effect on the total duration of the visit to the feeder (Table 3-4). The time spent at the feeder for nutritive visits was, during the first period, longer by 1.32 min/d with treatment R than with treatment C, while during the second period it was shorter by 4 min/d ($P = 0.009$). The time spent at the feeder for nutritive visits decreased with the social ranking ($P = 0.04$, Table 3-4) but was not affected by the group. The treatment showed a significant effect on the time spent at the feeder for non-nutritive visits

(28.4 vs. 16.3 min/d with treatments C and R, respectively; $P < 0.001$). The feeder occupancy was higher with treatment R compared to treatment C ($P = 0.009$) and for group B compared to group A ($P < 0.001$, Table 3-4). It was also higher for IR compared to LR and HR sows ($P < 0.001$, Table 3-4).

The treatment, period or group did not have any effect on the amount of feed distributed (Table 3-4). The amount of feed distributed increased with the social ranking ($P = 0.006$, Table 3-4).

iii. Drinking behaviour

The interaction between the treatment or group and the number of visits to the water troughs was significant ($P = 0.03$), with more visits for group A with treatment R compared to treatment C (11.1 vs. 10.1 times/d), and less for group B (12.9 vs. 14.3 times/d, Table 3-4). The interaction between the treatment and social ranking was significant ($P = 0.003$, Figure 3-4.2). Only HR sows had a lower number of drinking visits with treatment R than with treatment C, compared to the two other sow categories. The period tended to have an effect on the number of visits ($P = 0.06$), with less visits in the second period (Table 3-4).

The treatment, group and social ranking did not affect the time spent at the drinking trough and the amount of water drunk. The time spent at the trough was only influenced by the period ($P < 0.001$), which also affected the amount of water consumed (8.2 and 9.0 L/d in period 1 and 2, respectively, $P = 0.01$). Only LR sows decreased their water consumption with treatment R compared to treatment C (by 1.36 L/d, $P = 0.03$).

iv. Social behaviour

The total number of positive interactions (Table 3-4) was influenced by the period ($P < 0.001$) and social ranking ($P = 0.03$), but not by the treatment ($P = 0.11$) or group ($P = 0.81$). The level of lying in body contact behaviour was lower with treatment R than with treatment C (13.6 vs. 14.2, $P = 0.04$). It was also lower during period 1 compared to period 2 ($P = 0.003$), for group A compared to group B ($P <$

0.001), and for HR and IR sows compared to LR sows ($P = 0.006$, Table 3-4). The treatment and social ranking had no significant effect on the number of snout-to-snout or sniffing interactions (Table 3-4). The number of snout-to-snout and sniffing interactions were lower during period 2 than period 1 ($P < 0.001$, Table 3-4). Group B presented more snout-to-snout interactions than group A (7.37 vs. 4.60, $P = 0.003$).

The number of negative interactions was 2.6-fold greater with treatment R compared to treatment C ($P < 0.001$, Table 3-4). It was also greater during period 2 compared to period 1 ($P < 0.001$) and in group A compared to group B ($P < 0.001$, Table 3-4). The total number of negative interactions decreased with the social ranking ($P = 0.04$, Table 3-4). More precisely, the sows showed 1.1 more head-butting ($P < 0.001$), 2.9 more pushing ($P < 0.001$), 1.2 more biting ($P = 0.005$), and 1.6 more fleeing ($P < 0.001$) interactions with treatment R compared to treatment C. The treatment had no significant effect on the number of threats and attacks (Table 3-4). All the negative interactions were significantly more frequent in group A compared to group B ($P < 0.01$, Table 3-4). The number of pushing ($P = 0.01$), biting ($P = 0.007$), threatening ($P = 0.002$) and attacking ($P = 0.04$) interactions increased with the social ranking (Table 3-4). During period 2, more head butts ($P < 0.001$), fleeing behaviour ($P < 0.001$), and attacks ($P = 0.03$) were observed, but less threats ($P < 0.001$) than in period 1 (Table 3-4).

v. Occupation time

Over the 36 h of observation, the time spent sleeping was longer by 48.0 min ($P = 0.008$), and the time spent exploring the ESF by 42.6 min ($P < 0.001$) with treatment R compared to treatment C (Table 3-4). During period 2 compared to period 1, the time spent sleeping was longer ($P = 0.03$) and the times spent observing and exploring the ESF were shorter by 2.07 h and 0.79 h, respectively ($P < 0.001$). The time spent observing was not significantly affected by the treatment, but was longer for group A than for group B ($P < 0.01$). The time spent exploring the feeder was longer for group A than for group B ($P < 0.001$). The time spent exploring the floor tended to decrease with the social ranking ($P = 0.08$) but it was not significantly affected either by the treatment, the group or the period. The social

ranking had no significant effect on the time spent sleeping, observing or exploring the feeder.

vi. Location in the pen

The treatment, period, group or social ranking did not have any significant effect on the time spent in the areas next to the feeder (A2 and A4).

IR sows stayed less time in the area in front of the feeder (A5), compared to LR and HR sows ($P = 0.03$). The time spent in the A5 area was longer for the sows from group A compared to sows from group B (4.31 vs. 3.05 h over 36 h, $P = 0.03$). The treatment and period had no significant effect on the time spent in A5.

Regarding the areas further away from the feeder (A1 and A3), with treatment R, the sows spent more time in area A1 ($P = 0.005$) and less time in area A3 ($P = 0.07$) on average, than with treatment C: the lower the social ranking, the higher the time spent in the A1 area ($P < 0.001$). Indeed, LR sows spent 15.7 h in area A1 compared to 8.6 h and 4.9 h for IR and HR sows, respectively. The period and group had no effect on the time spent in area A3. LR sows tended to spend less time in area A3 (7.46 h) compared to IR and HR sows (11.76 h and 11.35 h, respectively; $P = 0.07$). In period 1, the sows spent 0.81 h more over 36 h in area A1 compared to period 2 ($P = 0.03$).

vii. Body condition, sow performance, and health

Sows had 15.03 ± 3.48 piglets born alive and 1.42 ± 1.86 stillbirths on average, for a litter weight of 23.17 ± 3.87 kg at farrowing. The social ranking or group had no significant effect on the litter size ($P = 0.79$ and $P = 0.46$, respectively) and weight at birth ($P = 0.81$ and $P = 0.70$, respectively).

The period, group or social ranking had no effect on the body weight and back-fat thickness gains of sows (Table 3-5). LR sows had a greater scratch index with treatment R compared to treatment C (63.4 vs. 36.5, $P = 0.02$). The scratch index was greater for LR sows compared to IR ($P = 0.002$) and HR sows ($P = 0.008$, Table

3-5). The period and group had no significant effect on the scratch index (Table 3-5).

The wound index was higher with treatment C than treatment R for group A (4.57 vs. 1.69, interaction $P = 0.05$), while the opposite was observed for group B (1.79 vs. 3.75). It was lower in period 2 than in period 1 ($P = 0.04$, Table 3-5). The social ranking had no significant effect on the wound index (Table 3-5).

There were no problems of health detected during all the experiment (control and competitive situation for feed).

Table 3-5: Effect of the experimental treatment^a, period^b, batch^c and hierarchical status of sows^d, on the body condition (body weight and backfat thickness gain), on the skin lesions (scratch and wound index), on the posture and on the nutritional requirements.

	Treatment ^a		Period ^b		Group ^c		Hierarchy ^d			Statistical analysis ^e							
	C	R	1	2	A	B	LR	IR	HR	RMSE	T	P	G	H	TxP	TxG	TxH
Number of sows	32	32	32	32	17	15	10	13	9	-	-	-	-	-	-	-	-
Body condition																	
Body weight gain, kg	4.03	3.82	3.85	4.00	4.29	3.52	4.56	3.90	3.39	4.88	0.81	0.86	0.41	0.62	-	-	-
BT ¹⁶ gain, mm	0.59	0.37	0.54	0.42	0.36	0.62	0.50	1.00	0.49	1.19	0.31	0.58	0.25	0.98	-	-	-
Skin lesions⁶																	
Scratch index	22.2	29.8	25.8	26.2	24.1	28.2	50.0 ^a	19.5 ^b	12.9 ^c	18.6	0.82	0.91	0.33	0.02	-	-	0.005
Wound index	3.27	2.63	4.17	1.68	3.14	2.75	3.33	3.06	2.47	6.53	0.08	0.04	0.12	0.83	-	0.05	-
Number of sows	25	25	25	25	12	13	7	10	8	-	-	-	-	-	-	-	-
Posture in the morning (00:00-11:59)																	
Lying, h/12 h	7.06	6.53	6.72	6.90	6.89	6.70	6.74	6.71	6.98	0.88	< 0.001	0.04	0.31	0.46	< 0.001	< 0.001	-
Moving, min/12 h	52.9	59.4	56.7	55.9	39.7	72.0	52.7	52.5	58.4	11.7	0.01	0.04	0.05	0.92	< 0.001	< 0.001	0.008
Standing, h/12 h	4.02	4.46	4.29	4.20	4.41	4.10	4.37	4.30	4.03	0.73	< 0.001	< 0.001	0.20	0.86	< 0.01	0.003	-
Position change, nb/12 h	26.4	28.8	26.8	28.4	26.4	28.9	27.2	28.7	26.7	7.39	< 0.001	< 0.001	0.39	0.91	0.001	< 0.001	< 0.001
Posture in the afternoon (12:00-23:59 h)																	
Lying, h/12 h	10.7	10.8	10.7	10.6	10.5	10.9	10.4 ^a	10.9 ^b	10.7 ^a	1.62	0.30	0.98	0.007	0.004	-	-	-
Moving, min/12 h	10.8	10.7	10.0	11.3	8.62	12.6	13.4	8.1	11.6	6.17	0.002	0.18	0.028	0.21	< 0.001	0.004	-
Standing, h/12 h	0.72	0.66	0.66	0.71	0.74	0.63	0.82 ^a	0.50 ^b	0.83 ^a	0.35	< 0.001	0.19	0.36	0.002	< 0.001	0.003	0.003
Position change, nb/12 h	13.0	12.7	12.3	13.3	13.7	12.1	15.3 ^a	11.7 ^b	11.8 ^b	6.08	< 0.001	< 0.001	0.88	0.02	-	0.007	< 0.001
Nutritional requirements for maintenance⁸																	
ME, MJ/d	30.7	31.1	30.5	31.3	31.6	30.3	27.1 ^a	31.5 ^b	34.4 ^c	0.45	< 0.001	< 0.001	0.05	< 0.001	0.04	-	-
Feed, kg/d	2.34	2.37	2.32	2.39	2.41	2.30	2.06 ^a	2.40 ^b	2.62 ^c	0.03	< 0.001	< 0.001	0.05	< 0.001	0.04	-	-

⁶ Index created as the sum of skin lesions pondered by their severity (1: for lesions under 5 cm, 5: for lesions upper 5 cm, 10: for lesions with blood or deep). Skin lesions were divided in two categories for two different index: scratch index (for long and straight lesions) and wound index (round lesions).

⁷ BT = Backfat thickness

⁸ Estimated metabolizable energy (ME) for maintenance (MJ/d) = $((0.30 \cdot \text{BodyWeight}^{0.75} \cdot \text{Activity}) + (440 \cdot \text{BodyWeight}^{0.75})) \cdot 0.001$ where BodyWeight is in kg and Activity is the time in standing position (min /d). Feed allowance is the ME for maintenance with a diet of 13.14 MJ of ME /kg.

^a Treatment (T): C=Control; R=Restricted access to the feeder

^b Two 5-day periods (P, period 1 and period 2) of restricted access to the feeder

^c Two groups (G) of sows (A and B)

^d Hierachy (H) ranking of sows: L=low, M=intermediate, H= high

^e RMSE= Root Mean Square Error. P values of fixed effects and TxP, TxG and TxH interactions (when there are significant) on a generalized linear model with a random sow effect. Letters (a, b, c) were add to significant difference ($P < 0.05$) between the modality of the hierarchy

viii. Physical activity

As shown in Figure 3-5, physical activity was strongly affected by the time of day, as most of the activity occurred in the morning after the start of a new "feeding day" (at midnight). In the morning (00-00 to 11-59 h) and afternoon (12-00

to 23-59 h) respectively, the sows spent 6.80 vs. 10.73 h/12 h lying down ($P < 0.001$), 4.25 vs. 0.70 h/12 h standing ($P < 0.001$), 56.3 vs. 10.7 min/12 h moving ($P < 0.001$), and changed posture 27.7 vs. 12.9 times/12 h ($P < 0.001$), on average.




Figure 3-5: Effect of the treatment (Control vs. Restricted access to the feeder) on the time stamp of the posture (lying, moving and standing) during the 5 days of the experiment.

In the morning, the difference between treatments R and C was greater for period 1 than period 2 for the time spent lying down (-21 vs. -5 %, $P < 0.001$), the time spent moving (+16 vs. +9 %, $P < 0.001$), the time spent standing (+18 vs. +5 %, $P < 0.01$), and the number of position changes (+11 vs. +8 %, $P < 0.001$, Table 3-5). The differences between treatments R and C were greater for group B than for group A regarding the time spent lying down (-10 vs. -6 %, $P < 0.001$), the time spent moving (+22 vs. +1 %, $P < 0.001$), and the time spent standing (+12 vs. +9 %, $P = 0.003$), except for the difference in the number of position changes which was greater for group A than for group B (+11 vs. +7 %, $P < 0.001$). The number of position changes was higher with treatment R compared to treatment C, and for HR and LR sows compared to IR sows (+17 and +11 vs. +3 %, respectively, $P < 0.001$). With treatment R, the sows spent less time lying down ($P < 0.001$), more time moving ($P = 0.01$),

more time standing ($P < 0.001$), and changed positions more often ($P < 0.001$) than with treatment C.

In the afternoon, the time spent moving and standing was lower with treatment R compared to treatment C in period 2, while the opposite was observed for period 1 ($P < 0.001$, Table 3-5). With treatment R compared to treatment C, the time spent moving was greater for group A (8.7 vs. 8.5 min over 12 h) and lower for group B (12.5 vs. 12.8 min over 12h, interaction, $P = 0.004$). With treatment R compared to treatment C, LR sows were the only ones with a reduced number of position changes compared to IR and HR sows (-17 vs. +4 and +8 %, respectively, $P < 0.001$). The difference between treatments R and C was greater for the time spent standing for group B than for group A (-14 vs. -4 %, $P = 0.03$), while the opposite was observed for the number of positions changes, which was greater for group A than for group B (-4 vs. -3 %, $P = 0.007$). Regarding the time spent standing, the difference between treatments R and C was greater for HR sows than for LR and IR sows (-12 vs. -8 and -6 %, respectively, $P = 0.003$). With treatment R, the sows spent less time moving ($P = 0.002$) and standing ($P < 0.001$) than with treatment C, and the number of position changes was lower ($P < 0.001$).

ix. Nutritional requirements for maintenance

When calculating ex-post nutritional requirements for maintenance while considering the effect of the treatment on physical activity, ME and feed requirements for maintenance were greater by 0.4 MJ/d and 50 g/d (for a diet at 13.14 MJ/d) with treatment R compared to treatment C ($P < 0.001$, Table 3-5). The treatment and period interaction had a significant effect ($P = 0.04$). ME requirements were greater during period 1 compared to period 2 with treatments R (31.5 vs. 30.8 MJ/d) and C (31.3 vs. 30.2 MJ/d). They were also greater for group A compared to group B ($P = 0.05$). ME and feed requirements for maintenance increased with the social ranking ($P < 0.01$, Table 3-5).

3.2.4. Discussion

i. Feeding Behaviour

The short-term feed competition also affected feeding behaviour and the way sows used the feeder. In restricted access situations, sows spent more time exploring the ESF, but the total number of visits, of non-feeding visits and time at the ESF decreased. This decrease in non-feeding visits with the increase in sows per ESF is in accordance with the results of Olsson *et al.* (2011). The queue to access the ESF is longer with one feeder open instead of two, leading to a greater interest in the feeder (Bench *et al.*, 2013). Moreover, Olsson *et al.* (2011) showed that more than half of the sows entering the feeder were attacked, which explains the aggressiveness of sows. This is probably related to the occupancy rate of the feeder which significantly increased during the restricted treatment. By changing the timing of feeding, behavioural changes can be observed, more specifically in a small group of sows where there is more fighting compared to a large group (Hemsworth *et al.*, 2013). However, in this study, the number of sows per ESF was quite low during the control and restricted treatment periods, compared to the literature (40-60 sows per ESF, Bench *et al.*, 2013) or commercial sow farms. Therefore, we would have expected limited or no changes in behaviour to take place because of the small numbers of sows per ESF. Thus, the results of this study highlighted that only considering the number of sows per feeder is not sufficient, and it is important to ensure stability in the number of functioning feeders.

ii. Feeding and drinking patterns

During the day, the feed competition had an impact on drinking and feeding behaviour patterns, with a time lag of visits to the automatons in the morning. Junge *et al.* (2012) showed that the daily pattern of drinking behaviour was similar to that of feeding. Sows eat and drink in the morning, a period with a higher level of activity. Due to the fact that the feeding period was extended for the entire group, the drinking period was also extended. Verdon *et al.* (2018b) also showed the impact of social rank on the feeding pattern. Even if the feeder was mostly occupied in the morning, lower-ranking sows ate later, around midday. Even though the feed

competition did not have an impact on water consumption, this could be linked to the fact that during the experimental days, the daily quantity of feed supply was the same (restricted feeding).

iii. Aggressiveness and lesions

During the short-term feed competition, sows were more aggressive toward each other with an increase in agonistic interactions but without any consistent effects on skin lesions. Verdon and Rault (2018a) explained that aggression may occur when accessing or defending a restricted resource. Moreover, agonistic interactions during the control weeks were lower than in other studies (Anil *et al.*, 2006), maybe due to the stability over the experiment of the group composition, which is known to reduce aggression (Campler *et al.*, 2019 ; Lagoda *et al.*, 2021, Jowett and Amory, 2021). Skin lesions may be an indicator of direct aggression (Verdon and Rault, 2018a) but they do not reflect agonistic interactions without contact, such as threats and avoidance behaviour (Turner *et al.*, 2006). That is why in the present study, the ethogram contains aggressive behaviours representing non-physical aggression ("threat based") as pushing or fleeing behaviour that are significantly affected by the feed competition. These results indicate a clear increase in social tensions in the context of reduced accessibility to the feeder, with marked effects on behaviour, especially for low-ranking animals.

iv. Physical Activity

In situations of short-term feed competition, sow activity increased by around 8 % (with less time spent sleeping or lying down), even during the control treatment the daily standing time was around 20 % higher than that reported in the literature (Anil *et al.*, 2006; Boyle *et al.*, 2002). This longer time spent standing might be related to the composition of the group, with rather low average parity, the pen design, with the provision of straw, and the type of equipment. The lower specificity and sensibility of the accelerometer used, could also be an explanation. Mc Glone (2013) suggested that posture could be used as an indicator of sow welfare, reduced access to the feeder (*i.e.* increased number of sows per feeder) therefore

having a negative effect on the welfare of group-housed gestating sows fed with an ESF. The increased standing activity is due to the longer time spent waiting to enter the ESF, in line with the increased time exploring it, and the tendency to spend longer time in the area close to it observed in the present study. It may also be caused by unrest due to aggression in the pen, which disturbs more sows causing them to stand for longer periods of time in between meals. This is corroborated by the increased frequency of negative interactions while the frequency of skin lesions was only slightly affected and mainly in low-ranking sows. Physical activity was highly influenced by agonistic behaviours as seen in the results with more position changes in the restricted group, and especially for the high- and low-ranking sows, which is indicative of more interactions between the highest and lowest ranked sows. This is also a typical cause of distress which inflicts the entire group, prompting less rest and more standing time. It can also be indicative of lower ranked sows pulling the average activity levels up as they try to access resources more frequently the more hungry, thirsty or tired they get. These results suggest that some behavioural adaptations occurred to response to the potentially stressful situation induced by the restricted access to the ESF.

The results also suggest that overall sow comfort decreased. They spent more time in the only area without straw and made more frequent position changes. According to Bench *et al.* (2013), competition for straw may appear in a group of sows raised on straw bedding. This is confirmed by the present results that indicate that low-ranking sows spent more time in area without straw to avoid the competition and associated aggressions for this resource, given that tensions were already heightened in the pen due to restricted feeder access.

v. Energy requirements

The study's results show that in the situation of restricted access to the feeder, sows spend more time standing, which increases their energy requirements. Therefore, the ex-ante estimation of sow feed requirements indicates that they were underestimated. In fact, during the 4 weeks of the experiment, sows spent one additional hour standing compared to the 4 h usually

used to calculate the maintenance energy requirements (Dourmad *et al.*, 2008). This underestimation may have had consequences for foetal growth or body reserves for some sows. These results highlight the need of real time technologies to follow the level of activity of sows during the gestation and consequently adapt the supply of energy. However, this did not significantly affect their body weight and back-fat thickness gain, maybe due to the duration of the feed competition period induced being too short. The increase in ME requirements with the social ranking of sows could be accounted for by the greater body weight of dominant sows, which were also mostly multiparous (Kranendonk *et al.*, 2007). The restricted access to the feeder also increased the number of posture changes during the morning and the afternoon. The accuracy of the requirements calculation could be improved with the inclusion of energy lost during posture changes, as showed by Labussière *et al.* (2022).

vi. Social ranking

Access to the pen resources appeared to be facilitated with increased ranking. Indeed, the time spent by sows in the area without straw decreased with their ranking, while the time spent in the quiet resting area with straw and close to the drinker increased. Strawford *et al.* (2008) failed to prove that hierarchy influences the preference for lying-down area, but they suggested that sows limit their interaction with others by going to non-favourite places as done by the present low-ranking sows. This confirms the results of Verdon *et al.* (2018b), which show that lower-ranking sows avoid the feeding area.

Time spent at the drinker and the amount of water drunk increased with social rank. Conversely, low-ranking sows spent more time eating than the others, in agreement with the results of Vargovic *et al.* (2021) who measured a lower feeding speed in young sows, compared to older ones, to get away from their pen mates during feeding times. The present results indicate a lower scratch index, less fleeing behaviour, but more agonistic interactions when the ranking increased. Pierdon and Parsons (2018) and Brajon *et al.* (2021) also showed that lower-parity sows faced a higher risk of lesions due to aggressions. Our results agree with

Verdon *et al.* (2016) and Brajon *et al.* (2021), who showed that dominant sows were responsible for the majority of aggressions. The time spent exploring the floor decreased with the increasing rank. These results contradict the results of Chapinal *et al.* (2010), who report that gilts had lower activity than older sows. However, this study showed a different size and group composition compared to the present paper, with more gilts (30 % compared to 23-26 % of gilts in the group).

vii. Group effect

This study highlighted behavioural differences between groups. In particular, group B seemed to be calmer than A with less time spent moving, observing and exploring the ESF, but showed more negative interactions and a greater wound index (especially during the control treatment). The experiment started at different gestation weeks (three vs. five for B and A, respectively) for these two groups, which may partly explain the different behaviours. The establishment of hierarchy when sows enter the group pen may lead to aggression and fights between sows and the number of injuries decreased following mixing and hierarchy establishment (Greenwood *et al.*, 2019). In both groups, the hierarchical order was stable according to the order of access to the feeder, but in group B the hierarchy was probably not completely established, as according to literature, the time required for its establishment varies between three (Verdon *et al.*, 2016) and nine weeks (Hulbert and Mc Glone, 2006). Despite the two groups were stable and the number of primiparous was the same, group B had lower number of sows and consequently a higher percentage of primiparous sows. Maybe this could be an explanation regarding the higher activity and agonistic behaviour observed in this group, as showed Greenwood *et al.* (2019) and Lagoda *et al.* (2021).

viii. Repetition effect, habituation or reinforcement?

During the repetition of the feed competition situations, the effect of the treatments on the time spent active and the time spent in the area without straw

was less marked during the second than during the first period, which may point to the habituation of sows to feed competition. Conversely, during the second period compared to the first one, the number of positive interactions (such as oral-nasal interactions) decreased and the number of negative ones (such as attacks or fleeing behaviour), as well as the number of position changes increased significantly, thus suggesting a reinforcement of the effect of feed competition. Even though welfare was not measured in the present study, oral-nasal-face behaviour could be used as an indicator of welfare as suggested by McGlone (2013). Therefore, the present results may suggest a deterioration of the welfare status in the second competitive feeding situation compared to the first one. Some physiological or stereotypic measurements on sows, such as cortisol (Murphy *et al.*, 2021) could help to draw conclusions about the habituation or reinforcement effect of the repetition of feed competition.

3.2.5. Conclusion

This study found that a competitive feeding situation using ESF increase physical activity and aggressiveness without increasing skin lesions. They also increase estimated metabolizable energy requirements in the first days after the event. The social ranking had a huge impact on the overall behaviour enhanced by feed competition, particularly on the lowest- and highest-ranking sows. The habituation, or not, of sows to feed competition later in the gestation is unclear. In practice, when gestating sows have access to at least two ESF, a short-term dysfunction of one ESF has therefore detrimental effects on the behaviour of the sows with potential effects on their welfare, but without affecting their performance.



La compétition alimentaire induite a provoqué une augmentation de l'agressivité, de l'activité et donc des besoins énergétiques. Le classement hiérarchique a eu un impact important sur le comportement général des truies et a été renforcé par la compétition alimentaire pour les truies de haut et bas rangs. L'habituation ou non des truies à la compétition alimentaire à un stade ultérieur de la gestation n'a pas été clairement démontrée dans cette étude.

3.3. Influence de différents événements sur le comportement et les besoins nutritionnels des truies

Les résultats de cette partie ont été, partiellement, présentés lors du 73^{ème} Congrès annuel de l'EAAP en 2022 à Porto et lors du 7^{ème} congrès de l'ISEP en 2022 à Grenade. Ils sont également issus de quatre publications publiées ou en cours de publication (3), (5), (6) et (9).

3.3.1. Introduction

Divers événements peuvent induire des adaptations comportementales chez les truies en gestation. En effet, un stimulus de l'environnement va induire chez la truie une réponse cognitive, physiologique et comportementale selon sa perception de celui-ci (Mormède *et al.*, 2018). Il peut s'agir d'une vague de chaleur, d'un dysfonctionnement du distributeur d'aliment, d'émissions de sons aléatoires, ou d'un enrichissement du milieu d'élevage (Otten *et al.*, 2004 ; Quesnel *et al.*, 2019). Le plus souvent, ces adaptations nécessitent de l'énergie et peuvent détériorer les performances de production comme le développement et croissance de la portée ou l'état corporel de la truie (Brito *et al.*, 2022). Cependant, leurs effets ont été peu étudiés sur de courtes périodes de quelques jours, pourtant plus représentatives

d'un aléa en élevage : dysfonctionnement d'un automate d'alimentation (voir précédemment), épisode caniculaire, températures hivernales, émissions sonores, enrichissement et appauvrissement de la salle de gestation.

L'objectif de cette étude est d'évaluer les effets d'évènements induits de courte durée sur les comportements (alimentaire, d'abreuvement, social), les occupations, l'activité physique et les besoins énergétiques de truies au cours de leur gestation.

3.3.2. Matériels et méthodes

Deux groupes d'environ 18 truies chacun ont été filmés en continu pendant deux gestations consécutives. Chaque semaine de test, au cours de laquelle un événement spécifique a été induit (variation de température, enrichissement, émission de sons), a toujours été précédée d'une semaine contrôle, sans aucun événement provoqué. Le détail des évènements induits est présenté dans la partie 1 de ce chapitre. Pour les conditions thermiques chaudes et froides, le comportement de 37 truies a été analysé. L'effet de l'enrichissement et de l'appauvrissement de l'enclos sur le comportement de 28 truies multipares a également été évalué. Enfin lors des émissions aléatoires de sons, le comportement de 31 truies a été étudié.

Des données comportementales (alimentation, abreuvement, social, activité physique) ont été enregistrées et le besoin énergétique individuel a été calculé (pour plus de détails *cf.* parties 1 et 2 du chapitre 3).

L'analyse statistique a été réalisée à l'aide du logiciel R studio (version 4.0.3). Un modèle linéaire à effets mixtes a été appliqué sur la variable d'intérêt intégrant la période (PM, Night), la semaine (test vs. contrôle), et leurs interactions comme facteurs fixes, ainsi que l'effet aléatoire de la truie.

3.3.3. Résultats et discussion

i. Comportement alimentaire

Tout comme lors de la compétition alimentaire, le comportement alimentaire a été impacté lors des semaines de variation des conditions thermiques, d'enrichissement et d'appauvrissement. Cependant, il n'y a eu pas d'effet significatif des semaines d'émissions de sons sur le comportement alimentaire (Tableau 3-6).

Tableau 3-6 : Effets des évènements sur le comportement des truies, par rapport à leur semaine contrôle respective (en rose si augmentation et en bleu si diminution significative).

	Emissions aléatoire de sons	Enrichissement	Appauvrissement	Conditions thermique chaude	Condition thermique froide	Compétition alimentaire
Comportement alimentaire	Pas d'effet significatif	Diminution du nombre de NNV	Augmentation du temps passé dans l'automate	Diminution du nombre de NNV	Augmentation du nombre de NNV	Diminution du nombre de NNV
Comportement d'abreuvement	Pas d'effet significatif	Pas d'effet significatif	Pas d'effet significatif	Augmentation de la consommation d'eau et du nombre de visites (notamment NNV).	Diminution du nombre de visites	Pas d'effet significatif
Comportement social	Augmentation du temps des interactions positives durant Nuit au cours du temps	Diminution du nombre d'interactions négatives	Pas d'effet significatif	Diminution de la proximité entre les truies et du nombre d'interactions négatives	Augmentation de la proximité entre les truies et du nombre d'interactions négatives	Augmentation du nombre d'interactions négatives
Activité physique	Augmentation du nombre de changements d'occupation	Pas d'effet significatif	Pas d'effet significatif	Diminution de l'activité physique	Augmentation de l'activité physique	Augmentation du temps actif et de l'exploration

NNV = visite non-nutritive et NV = visite nutritive

Les truies ont effectué moins de visites non nutritives pendant les semaines d'enrichissement par rapport au contrôle (5,3 vs. 6,1 NNV/j/truie, $P = 0,03$) et ont eu tendance à faire plus de visites non nutritives en condition thermique froide que chaude (6,1 vs. 5,4 NNV/j/truie, $P = 0,06$). Le temps passé dans l'automate d'alimentation était également plus important en semaine d'appauvrissement comparé au contrôle (+11 min/j, $P = 0,03$). Les truies (uniquement du groupe 1) ont passé plus de temps dans l'automate d'alimentation en période contrôle qu'en condition thermique chaude (79,2 vs. 49,4 min/j, respectivement, $P = 0,03$).

Les visites et le temps à l'alimentateur peuvent être motivées par la faim ou par l'ennui (D'eath *et al.*, 2018). En effet, le besoin lié à la thermorégulation augmente de 10 kJ/kg de poids métabolique/j/°C, pour des températures inférieures à 16°C (Dourmad *et al.*, 2008), ce qui était le cas dans notre étude. Cette augmentation du besoin dans un contexte de rationnement alimentaire peut ainsi augmenter la sensation de faim chez les truies. L'ennui des truies pendant la période d'appauvrissement peut s'être traduit par un attrait plus important pour l'alimentateur. Inversement, le nombre réduit de visites non nutritives pendant la période d'enrichissement peut s'être fait au profit de l'exploration des nouveaux enrichissements, réduisant également l'ennui (Elmore *et al.*, 2012).

i. Comportement d'abreuvement

Tout comme lors de la compétition alimentaire, il n'y a pas eu d'effet des semaines d'émissions de sons, d'enrichissement ou d'appauvrissement sur le comportement d'abreuvement. Seules les semaines de variation des conditions thermiques ont impacté le comportement d'abreuvement (Tableau 3-6).

Pendant la condition thermique chaude, les truies ont davantage visité l'abreuvoir que pendant les semaines contrôle ou froide (15,3 vs. 13,4 ou 12,9 visites/jour/truie, $P < 0,05$). Les truies (uniquement du groupe 2) avaient tendance à boire plus d'eau en condition thermique chaude qu'en froide (11,3 vs. 8,5 L/j, respectivement $P = 0,06$). Pour faire redescendre leur température corporelle, les truies peuvent augmenter leur consommation d'eau mais aussi se rafraichir en jouant avec l'eau (Renaudeau *et al.*, 2001 ; Chen *et al.*, 2020). Cette stratégie de

thermorégulation pourrait expliquer l'augmentation des visites et de la consommation d'eau en condition thermique chaude. L'augmentation de la température corporelle (de 0,03°C) uniquement dans le groupe 1 peut expliquer le succès de cette stratégie chez les truies du groupe 2 (Lucy et Safranski, 2017).

ii. Comportement social

Comme lors de la compétition alimentaire, il y a eu un effet significatif de tous les événements sur le comportement social positif et/ou négatif (Tableau 3-6).

La proximité sociale a varié en fonction des conditions thermiques. Les truies se sont plus isolées en condition thermique chaude (109 vs. 30,5 min sur 10 h en semaine froide, $P < 0,001$). De plus, le temps passé couché par groupe de 4 truies a été plus faible en condition chaude que lors du contrôle ou en condition froide (13 vs. 41 et 51 min/10 h, $P < 0,05$). Ce comportement est en lien avec la thermorégulation des truies, qui évitent les contacts pour maximiser les pertes de chaleur. A l'inverse, en situation thermique froide, les truies ont tendance à se blottir les unes aux autres afin de limiter les pertes de chaleur (Huynh *et al.*, 2005 ; Dourmad *et al.*, 2008 ; Schild, 2018). Les résultats de l'étude confirment ces hypothèses.

Pendant la période Nuit des semaines d'émissions de sons, le temps passé à avoir des interactions positives a augmenté lors du troisième jour d'émission par rapport au premier jour et au contrôle (+59,4 ; +13,2 et +19,8 s/5h, $P < 0,01$). Cependant, il n'y avait pas d'effet significatif sur la fréquence et le nombre d'interactions sociales ($P = 0,07$). L'augmentation de la durée des comportements sociaux positifs peut être liée à une rapide habituation des truies entre le premier et le troisième jour d'émission de sons. Otten *et al.* (2004) ont montré que les porcs s'habituèrent rapidement à l'émission répétée de sons lorsqu'ils n'ont pas la capacité d'y échapper, comme c'est le cas dans notre étude. Otten *et al.* (2004) avait cependant montré une diminution du nombre d'interactions positives chez le porc en croissance au début, ce qui est le contraire des résultats de notre étude. Les différences entre cette étude et celle présentée ici sont les types de sons émis et

la durée totale de l'exposition de 4h pendant trois jours ici contre 2h pendant 11 jours pour Otten *et al.* (2004).

En ce qui concerne le comportement agressif, pendant la période d'enrichissement, le nombre d'interactions négatives a diminué par rapport à la semaine contrôle (7,3 vs. 5,3 interactions/truie sur 10h, $P < 0,05$). La réduction des agressions est l'un des objectifs de l'enrichissement du milieu de vie des truies en groupe et semble atteint lors de l'étude (Hemsworth, 2021).




Figure 3-6 : Nombre de comportements agressifs en fonction des conditions thermiques et du groupe (les lettres a, b et c montrent une différence significative des tests post-hocs).

Uniquement dans le groupe 2, les truies ont été plus agressives en condition thermique froide qu'en chaude (1,9 contre 0,7 comportements agressifs sur 10 h par truie, $P = 0,009$, Figure 3-6). Ces variations dans les comportements agressifs peuvent être en lien avec la proximité entre les animaux et présenter un risque de mal-être (Groo *et al.*, 2018). Les truies étant plus proches en condition thermique chaude, elles ont pu réaliser plus d'interactions, notamment des négatives. En effet, la proximité de couchage est reliée au comportement social (Camerlink *et al.*, 2022). Cependant, la différence entre les deux groupes de truies peut s'expliquer par une prolongation de la condition thermique froide sur la semaine contrôle

suivante pour le groupe 1 suite à un problème technique (15,5 vs. 18,6°C pour le groupe 2). Cela a pu impacter les résultats de la semaine de condition thermique chaude.

iii. Activité physique

Comme lors de la compétition alimentaire, l'effet sur l'activité physique était significatif uniquement pour les semaines de variation des conditions thermiques et l'émissions de sons (Tableau 3-6).

Les semaines d'enrichissement et d'appauvrissement n'ont pas eu d'effet significatif sur le temps d'exploration de l'environnement et des matériaux manipulables ($P = 0,28$). L'enrichissement de la salle ou l'appauvrissement n'a pas également affecté significativement le temps passé couché ($P = 0,80$), debout ($P = 0,68$) ou en mouvement ($P = 0,83$). Cependant, numériquement, les truies ont passé plus de temps inactives en semaine d'appauvrissement comparé au contrôle (82,3 vs. 78,2 %, respectivement). En effet lors de l'appauvrissement, les truies ne se levaient pas pour aller manipuler la paille et étaient plus calmes. Ainsi, l'enrichissement et l'appauvrissement testé dans cette étude n'ont que peu influencé le comportement et l'activité physique des truies.

Lors de l'émission de sons, le temps passé à dormir a diminué comparé à la semaine contrôle (96,5 vs. 44,8 min/10h lors du premier jour, $P < 0,01$) et le nombre de changements d'occupation a augmenté (43,4 contre 16,4 changements, $P < 0,01$). Or, le niveau sonore induit lors des émissions était en dessous de la recommandation de 85 dB. Ainsi, le faible niveau sonore émis a quand même modifié l'activité physique des truies et les comportements mesurés précédemment lors du premier jour. Cependant, la rapide habitude des truies à ce niveau sonore lors du troisième jour peut s'expliquer par le fait que le niveau sonore peut atteindre 95-104 dB lorsque des porcs s'alimentent (Kristensen et Gimsing, 1988 ; Weeks, 2008).

Les truies du groupe 1 étaient moins actives pendant la semaine thermique chaude que la froide (83 vs. 103 min/5h Nuit, $P < 0,001$). De plus, les truies passaient moins de temps couché latéralement (82,2 vs. 53,2 % des 5h en PM, en condition chaude vs. froide, $P < 0,001$). D'autres études ont montré également une diminution

de l'activité chez la truie ou le porc en croissance dans des conditions de températures élevées (Huynh *et al.*, 2005 ; Canaday *et al.*, 2013 ; Lucy et Safranski, 2017). Le but est de diminuer la production de chaleur interne et d'augmenter les pertes thermiques, notamment en augmentant le temps passé couché (sol frais). Due à la présence de paille dans la salle, les truies devaient la pousser afin d'augmenter la surface de contact et d'échange avec le sol plus froid. De plus, la réduction de l'activité physique peut être liée également à la réduction du nombre de visites à l'alimentateur (Bjerg *et al.*, 2020).

iv. Besoins nutritionnels

L'enrichissement et l'appauvrissement de l'enclos n'a pas affecté significativement les besoins nutritionnels, tout comme les émissions sonores (Figure 3-7). Cependant, le calcul ne tient pas compte des besoins liés à un changement de posture, pourtant augmentant significativement lors des émissions sonores.

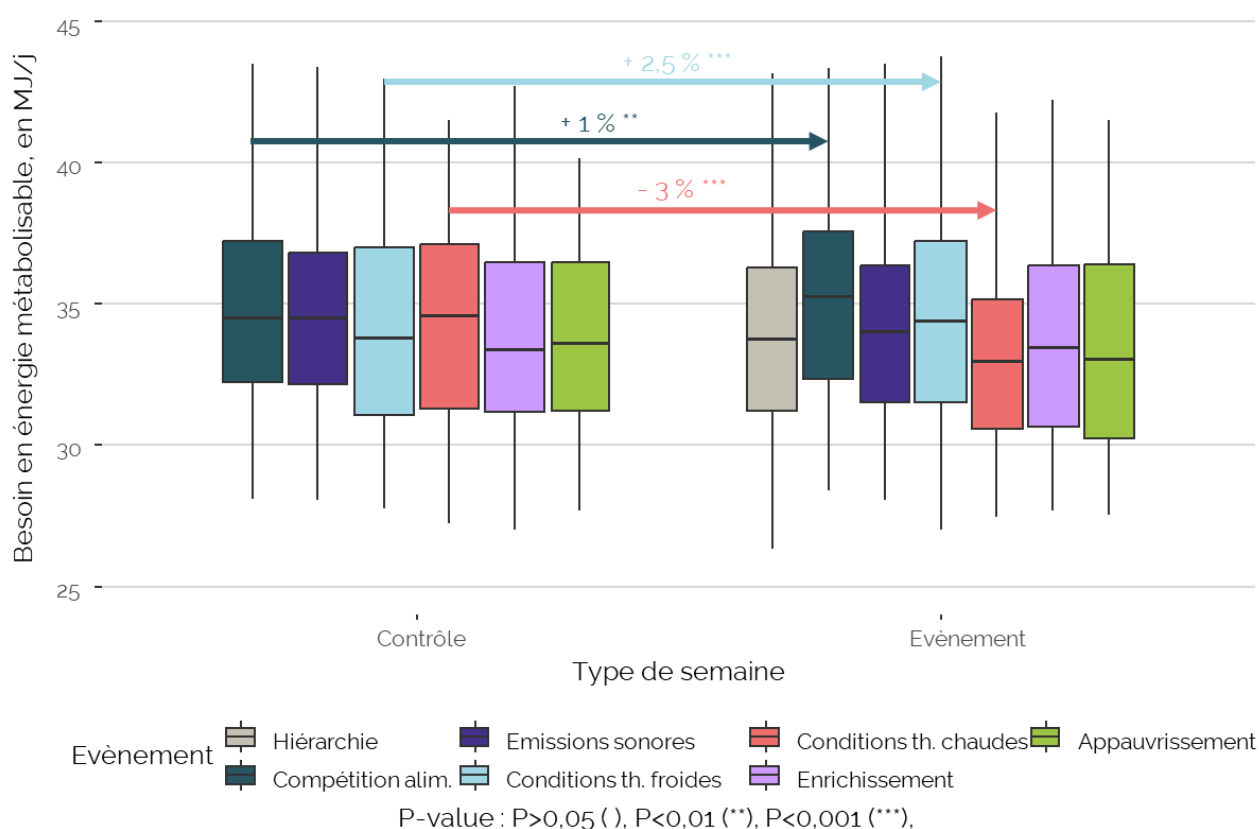


Figure 3-7 : Effet des différents événements à court terme sur la médiane et les quantiles du besoin en énergie métabolisable (en MJ/d) pour les truies gestantes.

Les besoins en énergie métabolisable ont augmenté de 2,5 % pendant la semaine froide ($P < 0,001$) et diminué de 3 % pendant la semaine chaude (Figure 3-7). Le coefficient de variation entre truies de ce changement de besoin en énergie était de 57 % et 51 % respectivement. Ce résultat montre l'importante variabilité individuelle des besoins.

Les besoins en énergie métabolisable ont été recalculés *a posteriori* à partir du temps passé en position debout et de la température ambiante. Ce nouveau calcul montre que les besoins énergétiques ont été sous-estimés de 2,5 % au cours des semaines contrôles, de 1,6 % durant l'enrichissement, de 3,3 % durant les conditions thermiques froides et de 3,4 % durant la compétition alimentaire. Les besoins ont été uniquement surestimés de 1,2 % pour la condition thermique chaude. Ces potentielles erreurs d'estimation (notamment de sous-estimation) ont pu entraîner des conséquences négatives sur la reconstitution des réserves ou la croissance des foetus chez certaines truies. Ces besoins recalculés tiennent compte uniquement du temps passé debout et de réelles performances de mises-bas. Il pourrait être intéressant d'identifier des coefficients de dépense d'énergie métabolisable en fonction du temps passé en mouvement (debout immobile ou en déplacement) ou en fonction d'un changement de position (passage de couché à debout, par exemple).

3.3.4. Conclusion

Ces résultats préliminaires suggèrent que divers événements à court terme (conditions thermiques, enrichissement/appauvrissement et émissions de sons) pendant la gestation modifient différemment les comportements d'alimentation, social et l'activité physique des truies. Seules les variations des conditions thermiques ont impacté le comportement d'abreuvement, avec une augmentation de l'eau bue lors d'une augmentation de température. Ces comportements pourraient représenter des indicateurs pertinents de l'apparition de ces événements et du bien-être des truies. En effet, l'émission de sons a été

caractérisée par plus d'interactions positives et de changement de postures. L'enrichissement était caractérisé par une diminution des interactions négatives et des visites à l'alimentateur. L'augmentation du temps passé à l'alimentateur était spécifique de l'appauvrissement. Les conditions thermiques chaudes et froides se sont opposées sur de nombreux paramètres mesurés. Par exemple, pour le chaud, la proximité sociale, le nombre d'interactions sociales négatives, le nombre de visites à l'alimentateur ainsi que l'activité physique diminuaient par rapport au contrôle, tandis qu'ils augmentaient lors du froid.

Cette étude indique que les conditions thermiques et la compétition alimentaire à court terme ont un impact sur l'activité physique et la thermorégulation de la truie, et par conséquent sur les besoins énergétiques pour l'entretien. Les événements d'enrichissement et d'appauvrissement, tout comme l'émission de sons, n'ont pas eu d'effet sur l'activité physique ou les besoins en énergie métabolisable.



Ce chapitre souligne l'importance de prendre en compte le comportement, et plus particulièrement l'activité physique de chaque animal pour prédire au mieux les besoins en énergie. Idéalement cette information doit être prise en compte en « temps réel », ou pour le moins régulièrement (ex. à la fin de chaque journée). Dans ce cas, l'analyse de vidéo manuelle n'est pas possible. Ces informations doivent être collectées automatiquement via des capteurs, automates ou logiciels d'analyse à développer.

3.4. Références bibliographiques

- Abarnou J., Durand M., Dourmad J.Y., Gaillard C., 2022. Effects of thermal conditions on gestating sows' behaviors and energy requirements. *J. Anim. Sci.*, 101, skac413.
- Anil L., Anil S.S., Deen J., Baidoo S.K., Walker R.D., 2006. Effect of group size and structure on the welfare and performance of pregnant sows in pens with electronic sow feeders. *Can. J. Vet. Res.*, 70, p.128-136.
- Bench C.J., Rioja-Lang F.C., Hayne S.M., Gonyou H.W., 2013. Group gestation sow housing with individual feeding II: How space allowance, group size and composition and flooring affect sow welfare. *Livest. Sci.*, 152, p.218-227.
- Best D.J., Roberts D.E., 1975. Algorithm AS: The Upper Tail Probabilities of Spearman's. *J. Appl. Stat.*, 24, p.377-379.
- Bjerg B., Brandt P., Pedersen P., Zhang G.Q., 2020. Sows' responses to increased heat load – A review. *J. Thermal. Biol.*, 94, 18.
- Boyle L.A., Leonard F.C., Lynch P.B., Brophy P., 2002. Effect of gestation housing on behaviour and skin lesions of sows in farrowing crates. *Appl. Anim. Behav. Sci.*, 46, p.119-134.
- Brajon S., Ahloy-Dallaire J., Devillers N., Guay F., 2021. Social status and previous experience in the group as predictors of welfare of sows housed in large semi-static groups. *PLoS ONE*, 16, 6.
- Brito A.A., da Silva N.A.M., Dias A.L.N.A., Nascimento M.R.B.M., 2022. Heat wave exposure impairs reproductive performance in primiparous sows and gilts in a tropical environment. *Int. J. Biometeorol.*, 66, p.2417-2424.
- Camerlink I., Scheck K., Cadman T., Rault J.L., 2022. Lying in spatial proximity and active social behaviours capture different information when analysed at group level in indoor-housed pigs. *Appl. Anim. Behav. Sci.*, 246, 105540.
- Campler M., Pairis-Garcia M., Kieffer J., Moeller S., 2019. Sow behavior and productivity in a small stable group-housing system. *J. Swine Health Prod.*, 27, p.7-86.
- Canaday D.C., Salak-Johnson J.L., Visconti A.M., Wang X., Bhalerao K., Knox R.V., 2013. Effect of variability in lighting and temperature environments for mature gilts housed in gestation crates on measures of reproduction and animal well-being. *J. Anim. Sci.*, 91, p.1225-1236.
- Chapinal N., de la Torre J.L.R., Cerisuelo A., Gasa J., Baucells M.D., Coma J., Vidal A., Manteca X., 2010. Evaluation of welfare and productivity in pregnant sows kept in stalls or in 2 different group housing systems. *J. Vet. Behav.-Clin. Appl. Res.*, 5, p.82-93.
- Chen C., Zhu W., Steibel J., Siegford J., Han J., Norton T., 2020. Classification of drinking and drinker-playing in pigs by a video-based deep learning method. *Biosyst. Eng.*, 196, p.1-14.

Quantification de l'effet de l'environnement sur le comportement du groupe de truies gestantes

Council Directive 2001/88/CE. 2001. Laying down minimum standards for the protection of pigs. Official J. European Union. 23.10.2001. <https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:32001L0088&from=EN> (accessed 6 July 2022).

Dalmau A., Velarde A., Scott K., Edwards S., Butterworth A., Veissier I., Keeling L., Overbeke G., Bedaux V., 2009. Welfare Quality® Assessment for Pigs (Sows and Piglets, Growing and Finishing Pigs). Welfare Quality® Consortium, Lelystad, Pays-Bas.

D'Eath R.B., Jarvis S., Baxter E.M., Houdijk J., 2018. Mitigating hunger in pregnant sows. In : M. Spinka (Ed.), *Advances in pig welfare*, Woodhead Publishing Series in Food Science, Technology and Nutrition, Cambridge, Royaume-Uni, p. 199-234.

Dourmad J.Y., Etienne M., Valancogne A., Dubois S., van Milgen J., Noblet J., 2008. InraPorc: A model and decision support tool for the nutrition of sows. *Anim. Feed Sci. Technol.*, 143, p.372–386.

Durand M., Julienne A., Dourmad J.Y., Gaillard C., 2021. Effect of feed competition on activity and social behaviour of gestating sows. In : EAAP scientific committee (Ed.), *Book of abstracts of the 72nd Annual Meeting of the European Federation of Animal Science*, Davos, Switzerland. p.411.

Durand M., Simon M., Foisil J., Dourmad J.Y., Largouët C., Gaillard C., 2022. Evaluation of the physical activity of a group of gestating sows using an artificial neural network. In : EAAP scientific committee (Ed.), *Book of Abstracts of the 73rd Annual Meeting of the European Federation of Animal Science*, Porto, Portugal, p.455.

Elmore M.R.P., Garner J.P., Johnson A.K., Kirkden R.D., Patterson-Kane E.G., Richert B.T., Pajor E.A., 2012. Differing results for motivation tests and measures of resource use: The value of environmental enrichment to gestating sows housed in stalls. *Appl. Anim. Behav. Sci.*, 141, p.9-19.

Gaillard C., Gauthier R., Cloutier L., Dourmad J.Y., 2019. Exploration of individual variability to better predict the nutrient requirements of gestating sows. *J. Anim. Sci.*, 97, p.4934-4945.

Gaillard C., Durand M., Dourmad J.Y., Largouët C., Tallet C., 2021. Effects of the environment and animal behavior on nutrient requirements for gestating sows: Future improvements in precision feeding. *Anim. Feed. Sci. Technol.*, 279, 115034.

Gaillard C., Dourmad J.Y., 2022. Application of a precision feeding strategy for gestating sows. *J. Anim. Feed Sci. Technol.*, 287, 115280.

Greenwood E.C., Dickson C.A., Wettere W.H.E.J., 2019. Feeding Strategies Before and at Mixing: The Effect on Sow Aggression and Behavior. *Animals*, 9, 23.

Groo Z., Szenczi P., Banzegi O., Nagy Z., Altbacker V., 2018. The influence of familiarity and temperature on the huddling behavior of two mouse species with contrasting social systems. *Behav. Proc.*, 151, p.67-72.

Quantification de l'effet de l'environnement sur le comportement du groupe de truies gestantes

Hemsworth P.H., Rice M., Nash J., Giri K., Butler K.L., Tilbrook A.J., Morrison R.S., 2013. Effects of group size and floor space allowance on grouped sows: Aggression, stress, skin injuries, and reproductive performance. *J. Anim. Sci.*, 91, p.4953-4964.

Hemsworth P.H., 2021. Optimising pig welfare in breeding and gestation. In : S. Edwards (Ed.) Understanding the behaviour and improving the welfare of pigs, Burleigh Dodds Science Publishing Series in Agricultural science, Dublin, Irlande, p.87-120.

Hulbert L.E., Mc Glone J.J., 2006. Evaluation of drop versus trickle-feeding systems for crated or group-penned gestating sows. *J. Anim. Sci.*, 84, p.1004-1014.

Huynh T.T.T., Aarnink A.A., Gerrits W.J.J., Heetkamp M.J.H., Canh T.T., Spoolder H.A.M., Kemp B., Verstegen M.W.A., 2005. Thermal behaviour of growing pigs in response to high temperature and humidity. *Appl. Anim. Behav. Sci.*, 91, p.1-16.

Jowett S., Amory J., 2021. The stability of social prominence and influence in a dynamic sow herd: A social network analysis approach. *Appl. Anim. Behav. Sci.*, 238, 105320.

Junge M., Herd D., Jezierny D., Gallmann E., Jungbluth T., 2012. Water intake and drinking behavior of pregnant sows. In : ASABE (Ed.), 9th International Livestock Environment Symposium, Valencia, Spain, 8-12 July 2012.

Koketsu Y., Lida R., 2017. Sow housing associated with reproductive performance in breeding herds. *Mol. Reprod. Dev.*, 84, p.979-986.

Kranendonk G., Van der Mheen H., Fillerup M., Hopster H., 2007. Social rank of pregnant sows affects their body weight gain and behaviour and performance of the offspring. *J. Anim. Sci.*, 85, p.420-429.

Kristensen S., Gimsing S., 1988. Brief communication: occupational hearing impairment in pig breeders. *Scandinav. Audio*, 17, p.191-192.

Labuissiere E., Dubois S., Esnault J., van Milgen J., 2022. Energy cost of physical activity (standing and walking) in finishing pigs and sows. *Anim. Sci. P.*, 13, p.325-326.

Lagoda M.E., Boyle L.A., Marchewka J., Calderon D.J.A., 2021. Mixing aggression intensity is associated with age at first service and floor type during gestation, with implications for sow reproductive performance. *Animal*, 15, 100158.

Lanthony M., Danglot M., Spinka M., Tallet C., 2022. Dominance hierarchy in groups of pregnant sows: characteristics and identification of related indicators. *Appl. Anim. Behav. Sci.*, 254, 105683.

Lucy M.C., Safranski T.J., 2017. Heat stress in pregnant sows: Thermal responses and subsequent performance of sows and their offspring. *Mol. Reprod. Dev.*, 84, p.946-956.

Lüdecke D., Ben-Shachar M.S., Patil I., Waggoner P., Makowski D., 2021. Performance: An R Package for Assessment, Comparison and Testing of Statistical Models. *J. Open Source Softw.* 6, 3139.

Quantification de l'effet de l'environnement sur le comportement du groupe de truies gestantes

- Marcon M., Meunier-Salaün M.C., Le Mer M., Rousselière Y., 2017. Accelerometer technology to perform precision feeding of pregnant sows and follow their health status. In : D. Berckmans & A. Keita (Eds.), Proceedings of the 8th European Conference on Precision Livestock Farming, Nantes, FR, p.666-673.
- McGlone J.J., 2013. Review: updated scientific evidence on the welfare of gestating sows kept in different housing systems. *Prof. Anim. Sci.*, 29, p.189-198.
- Mormède P., Boisseau-Sowinski L., Chiron J., Diederich C., Eddison J., Guichet J.L., Le Neindre P., Meunier-Salaün M.C., 2018. Animal welfare: context, definition, evaluation. *INRA Prod. Anim.*, 31, p.145-162.
- Murphy E., Melotti L., Mendl M., 2021. Assessing emotions in pigs: determining negative and positive mental states. In : S. Edwards (Ed.), Understanding the behaviour and improving the welfare of pigs, Burleigh Dodds Science Publishing Series in Agricultural science, Dublin, Irlande, p.455-496
- Noblet J., Shi X.S., Dubois S., 1993. Energy cost of standing activity in sows. *Livest. Prod. Sci.*, 34, p.127-136.
- Norring M., Valros A., Bergman P., Marchant-Forde J.N., Heinonen M., 2019. Body condition, live weight and success in agonistic encounters in mixed parity groups of sows during gestation. *Animal*, 13, p.392-398.
- Olsson A.C., Andersson M., Bottermans J., Rantzer D., Svendsen J., 2011. Animal interaction and response to electronic sow feeding (ESF) in 3 different herds and effects of function settings to increase capacity. *Livest. Sci.*, 137, p.268-272.
- Otten W., Kanitz E., Puppe B., Tuchscherer M., Brüßow K.P., Nürnberg G., Stabenow B., 2004. Acute and long-term effects of chronic intermittent noise stress on hypothalamic-pituitary-adrenocortical and sympatho-adrenomedullary axis in pigs. *Anim. Sci.*, 78, p.271-283.
- Pierdon M.K., Parsons T.D., 2018. Effect of familiarity and mixing method on gestating sow welfare and productivity in large dynamic groups. *J. Anim. Sci.*, 96, p.5024-5034.
- Pinheiro J., Bates D., R Core Team, 2022. Nlme: Linear and Nonlinear Mixed Effects Models. R package version 3, p.1-158, <https://CRAN.R-project.org/package=nlme>.
- Quesnel H., Peuteman B., Père M.C., Louveau I., Lefaucheur L., Perruchot M.H., Prunier A., Meunier-Salaün M.C., Gardan-Salmon D., Gondret F., Merlot E., 2019. Effect of environmental enrichment with wood materials and straw pellets on the metabolic status of sows during gestation. *Livest. Sci.*, 229, p.43-48.
- Renaudeau D., Quiniou N., Noblet J., 2001. Effects of exposure to high ambient temperature and dietary protein level on performance of multiparous lactating sows. *J. Anim. Sci.*, 79, p.1240-1249.

Quantification de l'effet de l'environnement sur le comportement du groupe de truies gestantes

Schild S.L.A., 2018. Giving birth outdoors: Impact of thermal environment on sow' parturition and piglet survival. Thèse de Doctorat, Aarhus University, Foulum, Danemark, 177p.

Spoolder H.A.M., Vermeer H.M., 2015. Gestation group housing of sows. In : C. Farmer (Ed.), The gestating and lactating sow, Wageningen Academic Publishers, Wageningen, Pays-Bas, p.47-72.

Strawford M.L., Li Y.Z., Gonyou H.W., 2008. The effect of management strategies and parity on the behaviour and physiology of gestating sows housed in an electronic sow feeding system. *Can. J. Anim. Sci.*, 88, p.559-567.

Turner S.P., Farnworth M.J., White I.M.S., Brotherstone S., Mendl M., Knap P., Penny P., Lawrence A.B., 2006. The accumulation of skin lesions and their use as a predictor of individual aggressiveness in pigs. *Appl. Anim. Behav. Sci.*, 96, p.245-259.

Vargovic L., Hermesch S., Athorn R. Z., Bunter K.L., 2021. Feed intake and feeding behaviour traits for gestating sows recorded using electronic sow feeders. *J. Anim. Sci.*, 99, p.1-12.

Velarde A., Geers R., 2007. On farm monitoring of pig welfare. Wageningen Academic Publishers, Wageningen, Pays-Bas, 209p.

Verdon M., Morrison R.S., Rice M., Hemsworth P.H., 2016. Individual variation in sow aggressive behaviour and its relationship with sow welfare. *J. Anim. Sci.*, 94, p.1203-1214.

Verdon M., Rault J.L., 2018a. Aggression in group housed sows and fattening pigs. In : M. Spinka (Ed.), Advances in pig welfare, Woodhead Publishing Series in Food Science, Technology and Nutrition, Cambridge, Royaume-Uni, p. 235-260.

Verdon M., Zegarra N., Achayra R., Hemsworth P.H., 2018b. Floor Feeding Sows Their Daily Allocation over Multiple Drops per Day Does Not Result in More Equitable Feeding Opportunities in Later Drops. *Animals*, 8, 86.

Weeks C., 2008. A review of welfare in cattle, sheep and pig lairages, with emphasis on stocking rates, ventilation and noise. *Anim. Welf.*, 17, p.275-284.

4. Nouvelle méthode de prédiction des besoins nutritionnels à partir d'automates et de capteurs

L'objectif de ce chapitre est de prédire le besoin journalier en énergie métabolisable et lysine digestible iléale standardisée. Cette méthode se base sur des données comportementales et environnementales, mesurées par des automates ou des capteurs (accéléromètre, caméra, alimentateur, abreuvoir et balance connectée) et à l'aide de différentes méthodes de machine learning. Pour collecter automatiquement des données comportementales à l'échelle d'un groupe de truies, un réseau de neurones a été développé.

4.1. Prédiction de l'activité d'un groupe de truies à partir d'analyses d'images par un réseau de neurones.

Les résultats de cette partie ont été, partiellement, présentés lors du 73^{ème} Congrès annuel de l'EAAP en 2022 à Porto.

4.1.1. Introduction

L'activité physique influence les besoins énergétiques des truies gestantes logées en groupe. En effet, une augmentation d'une heure du temps passé en position debout correspond à une augmentation du besoin en énergie métabolisable de 0,30 kJ par kg de poids métabolique et par minute (Noblet *et al.*, 1993). Des modifications de l'activité ou du comportement des truies peuvent être le signe de troubles du bien-être ou de la santé (Escalante *et al.*, 2013). Les accéléromètres, fixés à l'oreille habituellement utilisés pour évaluer l'activité, sont des capteurs fragiles, coûteux et invasifs (Chapa *et al.*, 2020). En revanche, les caméras peuvent enregistrer des vidéos du groupe de truies mais nécessitent d'innombrables heures pour analyser manuellement les différentes activités des truies. Il faudrait pouvoir analyser automatiquement ces vidéos dont la qualité des images ne sont pas idéales : densité importante d'animaux, luminosité, aire non couverte par le champ de caméra, *etc...* (Matthews *et al.*, 2016 ; Benjamin *et Yik*, 2019 ; Arulmozhi *et al.*, 2021). L'objectif de cette étude était d'évaluer les performances d'un algorithme d'apprentissage profond développé pour la détection automatique de différentes activités des truies en gestation à partir d'images (Figure 4-1).

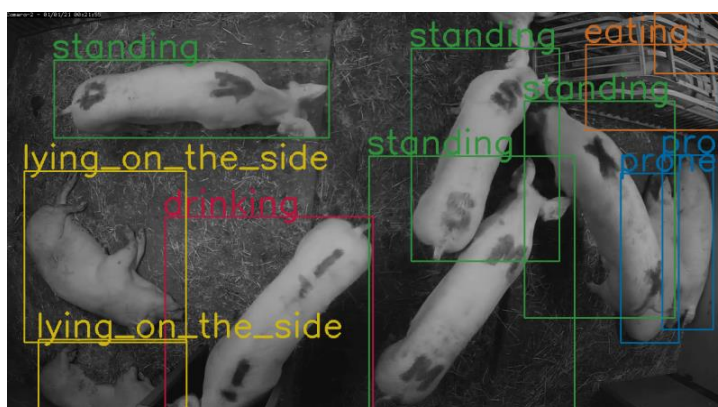


Figure 4-1 : Détection de l'activité des truies par le logiciel développé.

4.1.2. Matériel et Méthodes

Deux groupes de 18 truies, logées dans deux salles à l'UE3P Saint Gilles, ont été inclus dans l'expérience et suivis pendant deux gestations consécutives. Deux caméras ont enregistré chaque groupe en continu. Six activités (« couchée sur le ventre », « couchée sur le côté », « assise », « debout », « mange » et « boit ») ont été annotées manuellement par des experts en comportement animal sur les 1331 images (données d'apprentissage) extraites des vidéos (Figure 4-2).

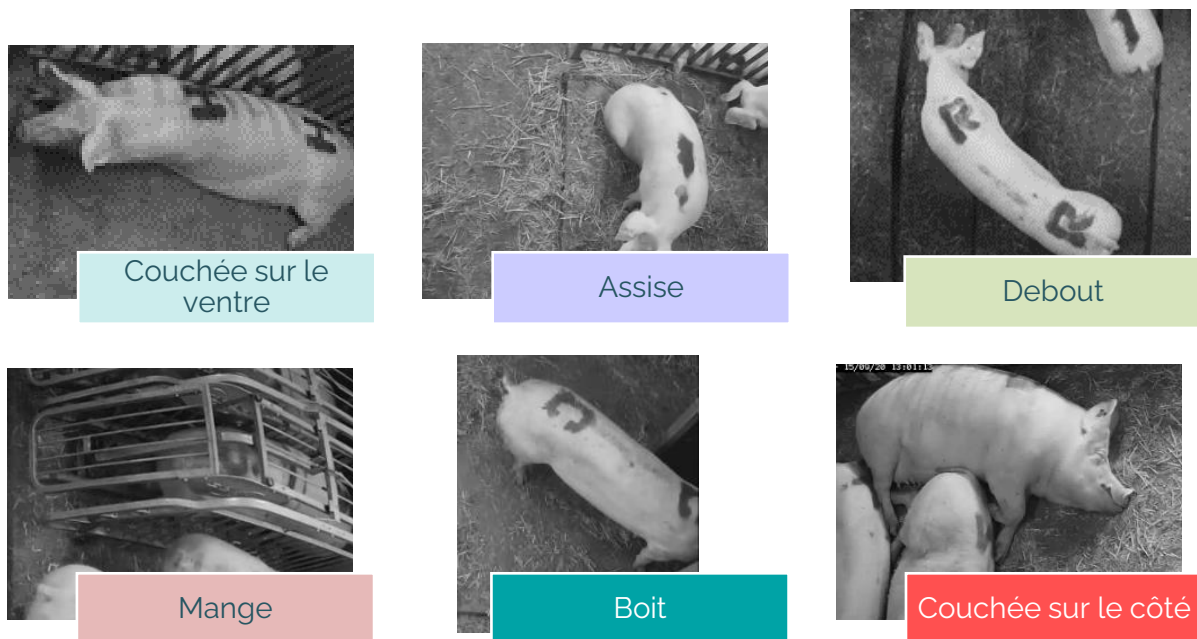


Figure 4-2 : Différentes activités détectées par le réseau de neurones.

Cet ensemble d'images annotées a été utilisé pour entraîner l'algorithme, un modèle de détection d'objets qui utilise des réseaux neuronaux convolutifs pour détecter et classer les objets dans une image. Un autre ensemble de 403 images (données de validation) a été utilisé afin d'ajuster les hyperparamètres du modèle et ainsi les performances de l'algorithme. Enfin, un dernier ensemble de 727 images (données de test) a été utilisé afin de valider les performances de l'algorithme. Afin de renforcer les performances de l'algorithme (Figure 4-3), des images de position plus rares chez les truies (« assise » et « boit ») ont ensuite été ajoutées uniquement dans les données d'apprentissage (pour un total de 2050 images) et de validation (540 images). Afin d'évaluer les performances de

prédiction, deux métriques, la précision et le rappel, ont été utilisées (cf. Chapitre 1.4).




Figure 4-3 : Schéma de la démarche du travail.

4.1.1. Résultats et Discussion

i. Performances du réseau de neurones avant et après renforcement

Le Tableau 4-1 résume les performances de l'algorithme avant et après renforcement. Les plus faibles précisions avant renforcement ont été générées par les activités « assise » (47 %) et « boit » (53 %), probablement en partie à cause du manque d'images incluant ces activités dans l'ensemble de données d'entraînement. En effet, « assise » représentait 3 % des activités étiquetées dans l'ensemble de données d'entraînement, et « boit » seulement 1 %. Le renforcement a permis d'améliorer uniquement le rappel pour « Assise » et la précision et le rappel pour « boit ». Après renforcement, la précision de la classification des truies couchées sur le ventre et en train de manger était satisfaisante de 86 % et 80 %, respectivement. En ne tenant pas compte des activités « assise » et « boit », la précision et le rappel étaient de respectivement 0,72 et 0,80 avant et 0,69 et 0,80 après renforcement (Tableau 4-1). Ainsi, le renforcement a ainsi permis d'améliorer ou de stabiliser l'ensemble des prédictions.

Tableau 4-1 : Performances de l'algorithme avant et après renforcement.

Activité	Avant renforcement		Après renforcement	
	Précision	Rappel	Précision	Rappel
Couchée sur le côté	0,49	0,80	0,61	0,79
Couchée sur le ventre	0,82	0,52	0,86	0,63
Assise	0,47	0,07	0,26	0,27
Debout	0,73	0,90	0,77	0,91
Mange	0,87	0,98	0,80	0,88
Boit	0,53	0,27	0,73	0,68
MOYENNE	0,65	0,59	0,67	0,69

Par ailleurs, les activités « assise » et « boit » étaient détectées comme « debout » (Figure 4-4A.), expliquant les faibles précision et rappel. Une autre d'explication pour la position « assise » peut être l'angle de vue de la caméra. En effet, si la caméra est à l'exact perpendiculaire, la distinction entre assis ou debout est difficile, même pour un observateur entraîné. La catégorie « Fond » sur la Figure 4-4 correspond à de fausses détections de truies par l'algorithme. Les faibles valeurs dans la matrice de confusion montrent que très peu d'éléments de l'environnement sont ainsi détectés par erreur comme une truie.

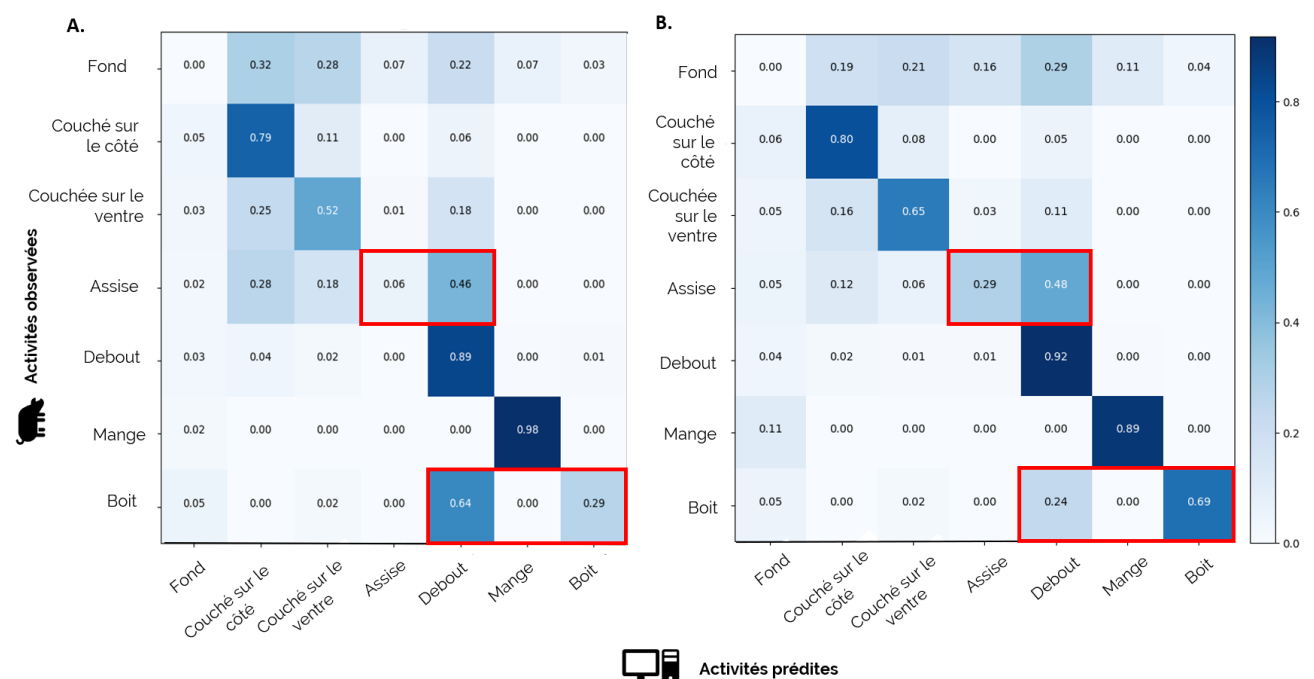


Figure 4-4 : Matrice de confusion avant (A.) et après renforcement (B.).

ii. Comparaison aux observations humaines

La comparaison entre les activités détectées par l'humain et par l'algorithme montre quelques différences au niveau des positions quand la truie était couchée (Tableau 4-2).

Tableau 4-2 : Comparaison des pourcentages d'activités détectées sur les vidéos par un observateur humain et l'algorithme.

Activité	% détectées par l'humain	% détectées par l'algorithme
Couchée sur le côté	55.3	25.5
Couchée sur le ventre	29.1	52.7
Assise	1.2	1.0
Debout	19.4	17.7
Mange	6.8	4.3
Boit	1.3	0.4

La position « couchée sur le côté » était principalement rapportée par l'observateur humain alors que l'algorithme détectait souvent une position « couchée sur le ventre ». Une piste d'explication peut être liée aux règles d'apprentissage de l'algorithme. En effet, en cas de position ambiguë, comme dans la Figure 4-5, la règle pour l'algorithme était « couchée sur le ventre », tandis qu'elle variait selon les observateurs humains.




Figure 4-5 : Capture d'écran d'une vidéo avec une position couchée ambiguë.

iii. Exploration de l'activité du groupe de truies au cours d'une journée

Grâce au logiciel d'analyse de vidéos développé, l'activité des truies a pu être observée sur une journée complète. Au quotidien, les truies passaient 75 % de leur temps « couchée sur le côté » (54 %) ou « sur le ventre » (21 %) (Figure 4-6A), ce qui est en accord avec les données de la littérature (Weng *et al.*, 2009). Elles étaient plus actives (c'est-à-dire debout) entre 00:30 et 09:00, en raison du début de la nouvelle journée d'alimentation à 00:00 (Figure 4.6B). De plus, les truies sont de nouveau plus actives vers 08:00, au moment du paillage de la salle (Figure 4-6B.). L'activité physique des truies gestantes est en effet très liée au comportement alimentaire (Haskell *et al.*, 2000; Chapinal *et al.*, 2010), ce qui peut expliquer ce pattern comportemental dans les conditions de l'étude (alimentation de nuit).




Figure 4-6 : Activité de la moyenne des deux groupes de truies à la journée (A.) et par heure (B.).

Des variations de l'activité physique sont apparues entre les deux gestations consécutives pour chaque groupe de truies ($P < 0,05$). En effet, entre la première et la seconde gestation, les truies ont augmenté le temps passé en position couché sur le côté (53 vs 56 %, $P < 0,05$) et diminué le temps passé en position debout (22 vs 19 %, $P < 0,05$). De plus, il existait des différences entre les groupes de truies ($P < 0,05$). Le temps passé en position assise était le plus élevé pour le groupe A lors

de sa première gestation (2 % vs. 1 % pour la seconde gestation ou le groupe B lors de ses deux gestations, $P < 0,001$). En effet, le groupe de truies, et plus particulièrement sa composition (*i.e.* nombre de primipares) peut influencer le comportement et le niveau d'activité physique de chaque truie (Bench *et al.*, 2013). Il existe également un effet significatif du jour de la semaine ($P < 0,001$) et de la semaine de gestation ($P < 0,001$). En effet, les truies étaient moins « debout » ou à manger le samedi et le dimanche. Cette différence peut être liée au changement de gestion pendant le weekend : heure de paillage variables, moins de bruit dans le bâtiment, *etc...* Parmi les semaines de gestation avec un événement induit, les variations au niveau du groupe se retrouvent principalement sur la position debout entre 17 et 24 % (en lien avec les résultats du chapitre 3).

4.1.2. Conclusion

Ce travail a montré que le réseau de neurones convolutifs développé avait des performances de prédiction satisfaisantes, notamment pour l'activité debout (rappel de 91 %). Pour améliorer cet algorithme, de nouvelles données d'apprentissage seront collectées et un module de suivi sera intégré pour détecter l'activité de marche et l'identifier des truies afin de travailler au niveau individuel. Pour cela, un projet CASDAR est en cours (projet SOMOVE).



La méthode d'analyse automatique d'images développée est ainsi précise et fiable pour l'étude de l'activité physique d'un groupe de truies gestantes. L'utilisation de ces données peut servir pour la prédiction des besoins nutritionnels journaliers.

4.2. Prédiction des besoins journaliers nutritionnels des truies gestantes à partir de données de capteurs et d'algorithmes de machine learning.

Les résultats de cette partie ont été, partiellement, présentés lors du 14^{ème} *European Symposium of Porcine Health Management (ESPHM)*, en 2023 à Thessalonique. Ils sont également issus d'un article publié dans *Journal of Animal Science* (7).

Résumé en français

L'alimentation sur mesure est une stratégie visant à fournir une quantité et une composition d'aliments aussi proches que possible des besoins en nutriments de chaque animal. Le but est de réduire le coût alimentaire et les pertes environnementales. Habituellement, les besoins en nutriments des truies gestantes sont déterminés par un modèle nutritionnel mécaniste nécessitant des données d'entrée, telles que les caractéristiques de la truie et du troupeau, ainsi qu'une estimation des performances futures à la mise bas. De nouveaux capteurs et automates, comme les alimentateurs et les abreuvoirs automatiques, ont été développés au cours des dernières décennies dans les élevages de porcs et ont produit de grandes quantités de données. Cette étude a évalué l'utilisation de méthodes de machine learning pour prédire les besoins nutritionnels quotidiens (définis ici comme l'énergie métabolisable et les acides aminés digestibles iléaux standardisés) des truies gestantes, à partir de données issues des capteurs et d'automates, selon différentes configurations de fermes numériques (avec ou deux capteurs combinés).

Les données de 73 truies gestantes ont été enregistrées par des automates d'alimentation et d'abreuvement électroniques, des balances connectées, des accéléromètres et des caméras. Neuf algorithmes d'apprentissage automatique ont été entraînés sur 22 scénarios de configurations de fermes numériques (avec un ou deux capteurs/automates)

afin de prédire les besoins quotidiens en énergie et en lysine de chaque truie. Les résultats des prédictions ont été comparés à ceux prédits par le modèle InraPorc, un modèle mécaniste pour l'alimentation sur mesure des truies gestantes. Les prédictions des scénarios ont également été évaluées avec ou sans les données de l'élevage (c'est-à-dire les conditions de logement et les caractéristiques de la truie lors de l'insémination artificielle) habituellement fournies au modèle InraPorc.

L'ajout des caractéristiques du logement et des truies aux données d'un capteur ou automate a amélioré l'erreur moyenne absolue en pourcentage de 5,58 % pour la lysine et de 2,22 % pour l'énergie. Les valeurs R^2 les plus élevées pour la lysine (0,99) et pour l'énergie (0,95) ont été obtenues pour les scénarios impliquant un système d'alimentation automatique seul (durée et nombre de visites journalières avec ou sans consommation). Les scénarios combinant un système d'alimentation avec un autre capteur (accéléromètre, abreuvoir automatique ou système de pesée) avaient aussi de bonnes performances de prédiction. Pour les scénarios avec l'automate d'alimentation et les caractéristiques des truies et du logement, les erreurs quadratiques moyennes sont plus faibles (et ainsi meilleurs) avec le Gradient Tree Boosting (0,91 MJ/j pour l'énergie et 0,08 g/j pour la lysine) que ceux obtenus avec la régression linéaire (2,75 MJ/j et 1,07 g/j). Les résultats de cette étude montrent que les besoins quotidiens en nutriments des truies gestantes peuvent être prédits avec précision grâce aux données fournies par certains capteurs ou automates et aux méthodes de machine learning. Ils ouvrent la voie à des solutions plus simples pour la mise en place de l'alimentation sur mesure en élevage.

Prediction of the daily nutrient requirements of gestating sows based on sensor data and machine-learning algorithms.

Durand M., Largouët C., Bonneau de Beaufort L., Dourmad J.Y., Gaillard C.

4.2.1. Introduction

Precision feeding can be defined as a nutritional strategy aimed at matching feed supply as close as possible to an individual's nutrient requirements, to prevent nutrient supply deficit and excess (Pomar *et al.*, 2019). For gestating sows, this strategy reduced lysine intake by 25%, nitrogen excretion by 18.5% (Gaillard and Dourmad, 2022), and feed costs by 3.4€ per gestation (Gaillard *et al.*, 2020a) without impacting sow performances. Precision feeding is based on the availability of smart feeders that make it possible to supply feed at individual or small group levels, based on the accurate prediction of nutrient requirements and on the determination of the nutritional value of feed ingredients. Electronic feeding stations allow individual feed supply (Gaillard *et al.*, 2020b), and tables are available for determining the nutrient value of feed (Sauvant *et al.*, 2004). The nutrient requirements of gestating sows are usually provided by a mechanistic nutrition model that requires inputs such as herd performances, sow age and body condition at artificial insemination, but also an estimation (or actual data a posteriori) of farrowing performances (Cooper *et al.*, 2001; Hansen *et al.*, 2014; Gaillard *et al.*, 2019).

Sensors and automatons are being increasingly used on farms (Galaz *et al.*, 2021) to automatize tasks, manage large groups of animals in real-time, or help optimize production costs (Berckmans, 2017; Neethirajan, 2020; Siegford *et al.*, 2021). These technologies allow individual monitoring thanks to Radio Frequency Identification (RFID) (Mahfuz *et al.*, 2022). The huge amount of real-time data collected, especially behavioral data, requires efficient approaches of classification

or prediction issues, such as machine learning (Neethirajan, 2020; Llonch *et al.*, 2022). Indeed, machine learning uses methods that learn from data in order to solve a specific task, such as classification or clustering, prediction, anomaly detection or recommendation (Géron, 2019). These algorithms have already been used on pig feeder data to predict biting outbreaks with an accuracy of 96% (Ollagnier *et al.*, 2023) and to predict body weight with an accuracy of 89% (He *et al.*, 2021).

This study aims at exploring the prediction of daily and individual nutrient requirements (here defined as metabolizable energy and standardized ileal digestible amino acids) of gestating sows based on data measured by sensors (electronics feeder and drinker, automatic weighting system, camera and accelerometer). This study also proposes to test various digital farm configurations and to compare the results according to the number and type of sensors (22 scenarios), as well as nine different machine-learning algorithms (linear-based, polynomial, Tree-based, support vector machine, nearest neighbour and neural network).

4.2.2. Materials and Methods

This study was carried out from July to April 2021, at the Pig Physiology and Phenotyping Experimental facilities (UE3P, doi: 10.15454/1.5573932732039927E12) of the French National Research Institute for Agriculture, Food and the Environment (INRAE) located in Saint-Gilles (France). Ethical approval concerning the French legislation on experimental animal care was given by the Ethics Committee for Animal Experimentation in Rennes, France (authorization for experiments on living animals No. 25883-2020070711528084). The data used in this study is available for public access and described in the data paper (Durand *et al.*, 2023).

i. General approach

The study was designed to evaluate the prediction of the nutrient requirements of sows based on sensor data and machine-learning methods. The first question to be answered is the following: "What is the best sensor(s) that may be required on a farm for correctly predicting sow nutrient requirements?" Other questions regarding algorithm optimization are considered: (i) "Which is the best

algorithm, i.e. with the highest accuracy, for predicting those requirements?" (ii) "Does the integration of sow and housing characteristics into the predictive variables improve prediction?"

Predicting nutrient requirements is a regression problem since it is needed for predicting continuous values. For that purpose, 9 supervised algorithms were chosen for their high performance in regression tasks as well as their representability of the diversity of machine-learning algorithms (Géron, 2019). A Linear Regression (LR), a linear regression with a LASSO regularization (LASSO), a linear regression with a RIDGE regularization (RIDGE), a Polynomial Regression (PR), a Support Vector Machine for Regression (SVR), a Random Forest (RF), a k-nearest-Neighbors (KNN), a Gradient Tree Boosting (GTB), as well as a Multilayer Perceptron (MLP), were therefore evaluated.

The supervised machine-learning algorithms were trained on different scenarios to represent digital farm configurations with one or two sensors, in order to limit investment costs for farmers. Five sensors were considered for their availability during the study:

- The presence of an electronic sow feeder (ESF) for recording feeding behavior (scenario 1).
- The presence of an automatic weighing system in the gestation room (scenario 2).
- The presence of accelerometers (scenario 3i) or cameras (scenario 3g) for measuring individual or group activity, respectively.
- The presence of electronic drinkers for recording drinking behavior (scenario 4).

A total of 11 scenarios were defined (Figure 4-7) depending on farm sensors configurations (a single sensor, or a combination of two sensors). Each scenario was tested with the possible addition of sows and housing characteristics (11 scenarios) or without (11 scenarios). The sow and housing characteristics included the average temperature measured in the gestation room (throughout the gestation), body weight, backfat thickness and the age of the sow on the day of the artificial insemination. In all scenarios (with or without sow and housing characteristics), the

“Day of gestation” variable was considered to take into account the “bump feeding” (i.e. an increase in feed supply) after 85 days of gestation.

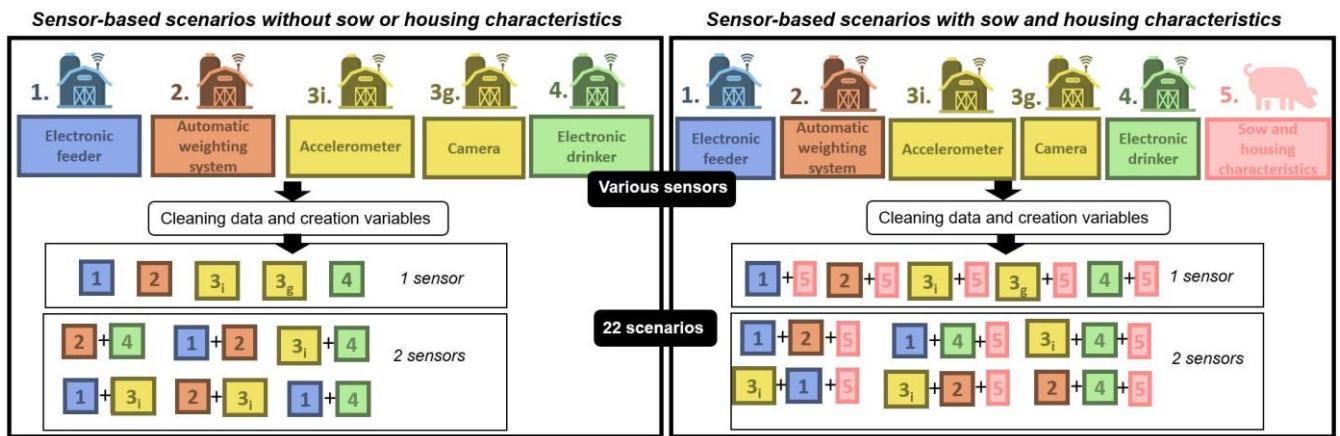


Figure 4-7: Creation of scenarios with or without sow and housing characteristics based on various sensors (one only or two combined) used in the study.

Nutrition model INRAPorc (Dourmad *et al.*, 2008) modified by Gaillard *et al.* (2020a) produced reference values of metabolizable energy (ME, in MJ/d) and standard ileal digestible lysine (SID Lys, in g/d) (Figure 4-8). These reference values have been used to evaluate the results provided by machine-learning techniques. These values were calculated ex-post, by taking into account the average daily temperature measured in the gestation room, the daily individual time spent in a standing position (given by accelerometers), the farrowing performances (number and weight of piglets), and the daily body weight (Table 4-3).

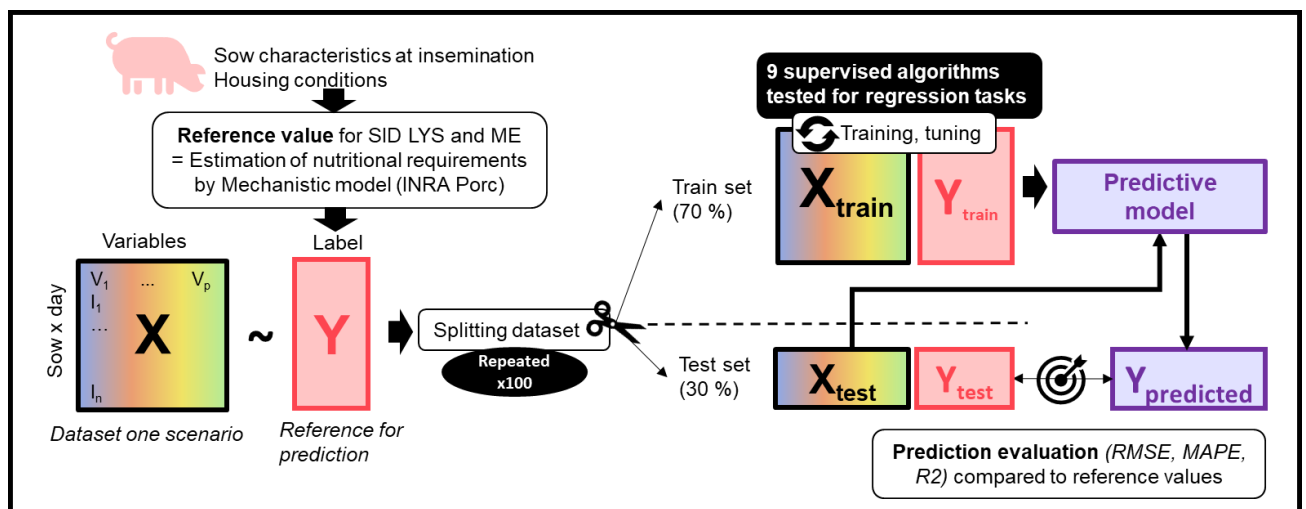


Figure 4-8: Evaluation of the algorithm's performance with the nutrition model.

Table 4-3: Description of the daily variables predicted and used in the nutritional model as well as sow and housing characteristics.

Variables	Primiparous	Multiparous
Number of sows	8	65
Nutritional model inputs		
Age at insemination, day ⁴	275.30 ± 15.30	821.63 ± 322.85
Body weight of sows, kg ⁴	163.30 ± 7.70	238.14 ± 37.08
BT ¹ of sows, mm ⁴	17.125 ± 2.62	15.52 ± 3.13
Daily temperature, °C ⁴	19.60 ± 2.47	20.38 ± 2.30
Time in standing position, h/d	4.26 ± 1.28	3.93 ± 1.99
Number of piglets stillbirth	15.60 ± 3.18	16.35 ± 4.40
Weight of litter, kg	21.80 ± 3.90	23.94 ± 4.88
Predicted		
SID LYS ³ , g/d	10.29 ± 2.30	8.76 ± 2.62
ME ⁴ , MJ/d	32.40 ± 2.92	36.03 ± 4.06

¹ Back fat Thickness

² SID LYS = standard ileal digestible lysine

³ ME = metabolizable energy

⁴ Features defining "sow and housing characteristics" on the model.

ii. Data collection and pre-processing

A total of 73 crossbred sows (8 primiparous and 65 multiparous), housed in four gestation rooms, were studied from a few days after artificial insemination to nearly the end of their gestation (104 days). The ambient temperature (°C) was continuously measured (every 5 min) in the gestation rooms thanks to sensors set up at 1.8 m above (Lascar Electronics, United Kingdom, precision ± 0.45°C).

Feeding behavior, including each visit to the feeder, the number and the duration (in minutes) of feeding visits (and the amount of feed consumed), the number and the duration of non-feeding visits (without consumption), and the feeder access order, was collected thanks to two self-locking ESF (Gestal, JYGA Technologies Inc., Canada) and by identifying the sow using their RFID ear tag (Table 4-4, scenario 1). The body weight of each sow was measured weekly using a scale (Schippers, The Netherlands, precision ± 5 kg) and uniformly distributed on a daily basis using the Weibull equation (Quiniou, 2021) (Table 4-4, scenario 2).

Sows were also equipped with a tri-axial accelerometer (RF-Track, Rennes, France), to record their physical activities on an individual scale: the time (in minutes) spent lying down, standing, moving time, and the number of posture changes (Table 4-4, scenario 3i). Two cameras (RS-CCPOE280IR4-DH, Ro-main Inc., Canada), mounted on the gestation room ceiling, continuously recorded the sow pen. The physical activities of the sows were evaluated on a group scale by

automatically analyzing videos with a convolutional neural network algorithm (Dilepex, France; Durand *et al.*, 2022). Both tools, the accelerometer and algorithm, produced data every 30 minutes, as a representative summary of the last 30 minutes. This algorithm's outputs were the proportion of sows in different positions: ventral lying, lateral lying, standing, sitting, eating and drinking (Table 4-4, scenario 3g). Another RFID ear tag was used to record the drinking behavior of sows at two electronic drinkers (Asserva, France): the number and duration of visits with or without water consumption, and the total quantity of water drunk (in L) (Table 4-4, scenario 4).

Table 4-4: Description of the variables studied per scenario, as a daily mean value by parity (primiparous and multiparous sows).

Scenario	Variables	Primiparous	Multiparous
	n =	8	65
1 (feeder)	Number of NNV ¹ /d	3.93 ± 2.77	5.27 ± 3.60
	Number of NV ² /d	1.01 ± 0.14	1.02 ± 0.16
	Duration of NNV ¹ , min/d	21.75 ± 37.25	31.63 ± 42.14
	Duration of NV ² , min /d	33.80 ± 15.79	33.81 ± 25.33
	Feeder order	15.81 ± 2.07	8.84 ± 3.73
2 (weight scale)	Live body weight mean, kg	191.17 ± 22.47	266.23 ± 35.43
3i (accelerometer)	Lying time, h/d	17.28 ± 3.10	18.12 ± 3.17
	Standing time, h/d	4.26 ± 1.28	3.93 ± 1.99
	Moving time, h/d	1.29 ± 0.75	1.10 ± 0.77
	Postures changes, nb/d	39.77 ± 14.70	34.46 ± 17.98
3g (camera)	Side lying time, %/d		54.96 ± 9.42
	Ventral lying time, %/d		19.89 ± 5.18
	Standing time, %/d		20.71 ± 5.36
	Sitting time, %/d		1.11 ± 0.88
	Eating time, %/d		2.68 ± 1.94
	Drinking time, %/d		0.62 ± 0.34
4 (drinker)	Number of NNV ¹ /d	3.51 ± 4.50	3.04 ± 5.01
	Number of NV ² /d	10.13 ± 7.20	11.27 ± 7.72
	Duration of NNV ¹ , min/d	1.07 ± 2.08	0.90 ± 1.91
	Duration of NV ² , min /d	5.92 ± 4.23	8.49 ± 7.09
	Water drunk, mL /d	5.92 ± 4.21	8.81 ± 7.89

¹NNV = non-nutritive visit (without consumption of feed or water)

²NV = nutritive visit (with consumption of feed or water)

Sensor data was cleaned to avoid outliers and regrouped on a daily scale (Table 4-4). All visits to the ESF lasting over 6 hours of duration (less than 1 % of observations) and all hourly accelerometer data having a sum different from a 1 hour duration (less than 1 % of observations) were removed from the dataset.

iii. Algorithm hyperparameter tuning and evaluation of performances

The supervised machine learning algorithms were implemented in Python using the scikit-learn library (Pedregosa *et al.*, 2011). The 8 323 observations (*i.e.* an observation being a sow per day of gestation, 'n' in the metrics formula) were randomly split 100 times ('t' in the metrics formula) into a training dataset (70 % of the original dataset) and a test dataset (30 %), to avoid possible overfitting of the predictive learning model. A K-fold learning strategy was also tested without giving better results, these K-fold results are therefore not presented in this paper.

In order to optimize the performance, the hyper-parameter tuning (detailed in Table 4-5) was evaluated through a 3-fold cross-validation method on the training dataset due to the limited amount of data (70% of the global dataset) (Pedregosa *et al.*, 2011). Hyper-parameter tuning was carried out for each tested ML algorithm and each scenario.

The relevance of sow and housing characteristics variables (Table 4-3) was tested in an ablation study for the best algorithm and scenario (one sensor). These variables were excluded one after the other and the performance results were compared.

Three metrics were used to evaluate the performances of the prediction model (' \hat{y} ' in the metrics formula) applied to the test dataset: the coefficient of determination R^2 score (between 0 and 1), the Root Mean Square Error (RMSE, in the unit of the predicted variable), and the Mean Absolute Percentage Error (MAPE, in %). Let's recall that the reference values ('y' in the metrics formula) are given by the INRAPorc nutrition model applied to individual sows (Gaillard *et al.* (2020a). The R^2 score measures the quality of the regression prediction and allows a comparison between models. RMSE and MAPE values were used to measure the accuracy and the prediction errors of the models. The higher the R^2 score, and the lower the RMSE and MAPE values, the higher the accuracy of the prediction is. A mean value of the metrics was calculated based on the 100 validation steps of the split dataset, to increase the repeatability of the presented results and avoid overfitting.

$$R^2 = 1 - \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{\sum_{t=1}^n (y_t - \bar{y})^2} ; \text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} ;$$

$$\text{MAPE} = \frac{100}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|$$

Table 4-5: Hyper-parameters tested on the selected supervised learning algorithms.

Algorithms	Hyperparameters	Description	Values
Linear Regression			
LASSO Regression	alpha	Constant that controlling the regularization strength.	[10 ⁻⁵ ; 10 ¹]
RIDGE Regression	alpha	Constant that controlling the regularization strength.	[10 ⁻⁵ ; 10 ¹]
Polynomial Regression	degree	Degree of the polynomial features.	2,3
Random Forest			
	Bootstrap	Whether bootstrap samples are used when building trees.	True
	max_depth	The maximum depth of the tree.	80, 90, 100, 110
	max_features	The number of features to consider when looking for the best split.	2, 3
	min_samples_leaf	The minimum number of samples required to be at a leaf node.	3, 4, 5
	min_samples_split	The minimum number of samples required to split an internal node.	8, 10, 12
	n_estimators	The number of trees in the forest.	100, 200, 300, 1000
Support Vector Machine			
	kernel	Specifies the kernel type to be used in the algorithm.	Linear, rbf
	gamma	Kernel coefficient for 'rbf',	Scale, 1, 0.1, 0.001, 0.0001
	C	The strength of the regularization is inversely proportional to C.	0.1, 1, 10, 50, 80, 100
K-nearest-neighbors	n_neighbors	Number of neighbors to use.	[1 ; 50]
Gradient Tree Boost			
	n_estimators	The number of boosting stages to perform.	1, 8, 16, 32, 64, 100, 1000
	learning rate	Learning rate shrinks the contribution of each tree.	0.01, 0.05, 0.1, 0.25, 0.5, 1
	max_depth	Maximum depth of the individual regression estimators.	1, 2, 3, 4, 5, 6, 7, 8
Multilayer Perceptron			
	hidden_layer_sizes	The number of neurons in the hidden layer.	2, 10, 20, 30, 40, 50, 80, 100, 200
	activation	Activation function for the hidden layer.	Tanh, relu, logistic
	solver	The solver for weight optimization.	sgd, adam, lbfgs

4.2.3. Results

Overall, sensor-based scenarios with sow and housing characteristics had lower RMSE and MAPE mean values for standard ileal digestible lysine (SID Lys) than scenarios without that information (0.70 vs. 1.28 g/d, and 5.54 % vs. 11.12 %, respectively). When using data from a single sensor, the prediction for metabolizable energy (ME) was more accurate for scenarios with sow and housing characteristics (Table 4-6) than for scenarios without (Table 4-8), while it was similar

when using data from two sensors (Tables 4-6 and 4-8). First, the results of the scenarios that only use data from sensors were presented, followed by those of scenarios that include sow and housing characteristics. The latter were developed based on an ablation study.

Table 4-6: Prediction performances (RMSE, MAPE, R²) of standard ileal digestible lysine (SID Lys) and metabolizable energy (ME) with sensor-based scenarios (one or two) only (as a mean value ± SD of the 9 algorithms).

	One sensor					Two sensors*					
	1	2	3i	3g	4	1+2	1+3 _i	1+4	2+3 _i	2+4	3+4
Standard ileal digestible lysine (SID Lys)											
RMSE, g/d	1.39 ± 0.21	1.00 ± 0.20	1.65 ± 0.07	1.71 ± 0.06	1.68 ± 0.07	0.85 ± 0.30	0.71 ± 0.32	0.69 ± 0.33	1.72 ± 0.07	1.65 ± 0.09	1.71 ± 0.07
MAPE, %	11.49 ± 2.28	7.92 ± 2.01	14.81 ± 0.82	15.45 ± 0.45	15.80 ± 0.81	6.78 ± 2.86	6.18 ± 2.90	5.48 ± 2.94	14.83 ± 2.92	15.31 ± 1.09	15.95 ± 0.49
R ²	0.71 ± 0.08	0.85 ± 0.06	0.60 ± 0.03	0.58 ± 0.03	0.59 ± 0.03	0.88 ± 0.07	0.91 ± 0.06	0.91 ± 0.07	0.58 ± 0.03	0.60 ± 0.05	0.58 ± 0.03
Metabolizable energy (ME)											
RMSE, MJ/d	2.88 ± 0.42	3.10 ± 0.51	3.31 ± 0.26	3.40 ± 0.25	3.36 ± 0.30	2.46 ± 0.76	2.03 ± 0.66	2.01 ± 0.66	3.49 ± 0.19	3.36 ± 0.31	3.41 ± 0.24
MAPE, %	6.24 ± 1.08	6.87 ± 1.32	7.52 ± 0.58	7.76 ± 0.54	7.62 ± 0.72	5.27 ± 1.82	4.23 ± 1.56	4.23 ± 1.60	8.04 ± 0.40	7.60 ± 0.74	7.73 ± 0.56
R ²	0.50 ± 0.15	0.42 ± 0.19	0.35 ± 0.10	0.31 ± 0.10	0.32 ± 0.12	0.61 ± 0.22	0.73 ± 0.15	0.73 ± 0.16	0.28 ± 0.08	0.33 ± 0.12	0.31 ± 0.10

*only activity scenarios 3i was tested due to their higher performances compared to 3g. Sensors: sensor 1 = feeder ; sensor 2 = weight scale ; sensor 3i = accelerometer ; 3g = camera ; sensor 4 = drinker

i. Sensor-based scenarios without sow or housing characteristics

Among these scenarios, the differences in MAPE values between scenarios 3i (individual level) and 3g (group level) were small, with a slight superiority of individual levels (14.81 % vs. 15.45 %, respectively, for SID LYS and 7.52 % vs. 7.76 %, respectively, for ME Table 4-6). For that reason, only scenario 3i with the combination of two sensors was used.

For SID LYS, the scenarios combining feeder data with data from another sensor (1+4 drinker, 1+3_i accelerometer and 1+2 scale, in order of performance) had the highest R² score (0.88-0.91, Table 4-6) and lowest RMSE and MAPE values, followed by the scale data only (2, Table 4-6). For ME, the 1+3_i (R² = 0.75) followed by the 1+4 scenarios (R² = 0.73) gave the best performances for two sensors and scenario 1 (feeder, R² = 0.50) among the single-sensor scenarios (Table 4-6).

Table 4-7: Prediction performances (RMSE, MAPE, R²) of metabolizable energy (ME) and standard ileal digestible lysine (SID Lys) per algorithm (as a mean value ± SD of the 22 scenarios with or without sow and housing characteristics).

	LR	LASSO	RIDGE	PR	RF	SVR	KNN	GTB	MLP
Scenario sensors with sow and housing characteristics									
Standard ileal digestible lysine (SID Lys)									
RMSE, g/d	1.09 ± 0.03	1.09 ± 0.03	1.09 ± 0.03	0.86 ± 0.05	0.44 ± 0.12	0.51 ± 0.12	0.65 ± 0.12	0.12 ± 0.04	0.48 ± 0.07
MAPE, %	9.15 ± 0.33	9.15 ± 0.32	9.15 ± 0.32	7.09 ± 0.53	3.22 ± 0.94	3.19 ± 0.83	4.53 ± 0.93	0.82 ± 0.18	3.56 ± 0.51
R ²	0.83 ± 0.01	0.83 ± 0.01	0.83 ± 0.01	0.89 ± 0.01	0.97 ± 0.02	0.96 ± 0.02	0.94 ± 0.02	0.99 ± 0.01	0.97 ± 0.01
Metabolizable energy (ME)									
RMSE, MJ/d	2.86 ± 0.08	2.84 ± 0.10	2.84 ± 0.10	2.30 ± 0.15	1.15 ± 0.12	1.73 ± 0.18	1.85 ± 0.16	0.91 ± 0.02	1.37 ± 0.09
MAPE, %	6.39 ± 0.23	6.32 ± 0.28	6.31 ± 0.28	4.93 ± 0.33	2.25 ± 0.26	3.39 ± 0.43	3.46 ± 0.36	1.55 ± 0.21	2.78 ± 0.22
R ²	0.52 ± 0.03	0.52 ± 0.03	0.52 ± 0.03	0.69 ± 0.04	0.92 ± 0.02	0.82 ± 0.04	0.80 ± 0.03	0.95 ± 0.01	0.89 ± 0.02
Scenario sensors with sow and housing characteristics									
Standard ileal digestible lysine (SID Lys)									
RMSE, g/d	1.50 ± 0.29	1.49 ± 0.29	1.49 ± 0.29	1.37 ± 0.34	1.13 ± 0.47	1.18 ± 0.44	1.22 ± 0.42	0.99 ± 0.58	1.13 ± 0.46
MAPE, %	13.29 ± 3.16	13.25 ± 3.14	13.26 ± 3.16	12.22 ± 3.47	9.76 ± 4.68	9.43 ± 4.30	10.25 ± 4.42	8.79 ± 5.54	9.80 ± 4.53
R ²	0.66 ± 0.12	0.67 ± 0.12	0.67 ± 0.12	0.71 ± 0.13	0.78 ± 0.14	0.77 ± 0.14	0.76 ± 0.14	0.80 ± 0.15	0.78 ± 0.14
Metabolizable energy (ME)									
RMSE, MJ/d	3.44 ± 0.36	3.43 ± 0.37	3.43 ± 0.38	3.11 ± 0.43	2.36 ± 0.72	2.70 ± 0.55	2.68 ± 0.49	2.29 ± 0.80	2.52 ± 0.63
MAPE, %	7.76 ± 0.89	7.73 ± 0.94	7.73 ± 0.94	6.91 ± 1.05	5.17 ± 1.82	5.76 ± 1.38	5.75 ± 1.42	4.99 ± 2.03	5.56 ± 1.55
R ²	0.29 ± 0.14	0.30 ± 0.14	0.29 ± 0.14	0.42 ± 0.15	0.64 ± 0.18	0.55 ± 0.16	0.56 ± 0.15	0.65 ± 0.19	0.60 ± 0.17

LR = Linear Regression, LASSO = linear regression with a LASSO regularization, RIDGE = linear regression with a RIDGE regularization, PR= Polynomial Regression, SVR=Support Vector Machine for Regression, RF= Random Forest, KNN=k-nearest-Neighbors, GTB=Gradient Tree Boosting, MLP= Multilayer Perceptron

The lowest MAPE and RMSE values (Table 4-7) and the highest R² scores (0.78-0.80 for SID LYS and 0.60-0.65 for ME) were obtained with GTB first, followed by RF, then MLP. The lowest prediction performances for SID LYS and ME were obtained with LR, LASSO and RIDGE (Table 4-7).

ii. Sensor-based scenarios with sow and housing characteristics

Among these scenarios, the differences in MAPE values between scenarios 3_i (individual level) and 3_g (group level) were small, with a superiority of individual levels (5.41 % vs. 6.92 %, respectively, for SID LYS and 4.26 % vs. 4.31 %, respectively, for ME Table 4-8). That is why only scenario 3_i with the combination of two sensors, was used.

Table 4-8: Prediction performances (RMSE, MAPE, R²) of standard ileal digestible lysine (SID Lys) and metabolizable energy (ME) with sensor-based scenarios (one or two) including sow and housing characteristics (as a mean value ± SD of the 9 algorithms).

	One sensor					Two sensors*					
	1	2	3 _i	3 _g	4	1+2	1+3 _i	1+4	2+3 _i	2+4	3 _i +4
Standard ileal digestible lysine (SID Lys)											
RMSE, g/d	0.64 ± 0.36	0.65 ± 0.39	0.70 ± 0.33	0.86 ± 0.23	0.70 ± 0.34	0.67 ± 0.36	0.69 ± 0.32	0.68 ± 0.33	0.96 ± 0.17	0.79 ± 0.31	0.89 ± 0.17
MAPE, %	5.10 ± 3.17	5.16 ± 3.46	5.41 ± 2.93	6.92 ± 2.01	5.44 ± 3.07	5.31 ± 3.11	5.44 ± 2.88	5.40 ± 2.99	7.70 ± 1.61	6.24 ± 2.97	6.97 ± 1.61
R ²	0.92 ± 0.07	0.92 ± 0.07	0.91 ± 0.06	0.88 ± 0.05	0.91 ± 0.07	0.92 ± 0.07	0.92 ± 0.06	0.92 ± 0.06	0.86 ± 0.05	0.89 ± 0.07	0.88 ± 0.05
Metabolizable energy (ME)											
RMSE, MJ/d	1.99 ± 0.70	1.96 ± 0.83	2.00 ± 0.77	2.02 ± 0.73	2.01 ± 0.79	1.94 ± 0.70	1.94 ± 0.68	1.95 ± 0.70	2.37 ± 0.49	2.11 ± 0.73	2.22 ± 0.58
MAPE, %	4.17 ± 1.67	4.15 ± 2.03	4.26 ± 1.90	4.31 ± 1.79	4.22 ± 1.93	4.04 ± 1.70	4.07 ± 1.66	4.03 ± 1.63	5.16 ± 1.20	4.49 ± 1.77	4.73 ± 1.44
R ²	0.74 ± 0.16	0.73 ± 0.20	0.73 ± 0.18	0.73 ± 0.18	0.73 ± 0.19	0.75 ± 0.16	0.75 ± 0.15	0.75 ± 0.15	0.65 ± 0.13	0.71 ± 0.18	0.69 ± 0.16

Sensors: sensor 1 = feeder ; sensor 2 = weight scale ; sensor 3_i = accelerometer ; 3_g = camera ; sensor 4 = drinker
 *only activity scenarios 3_i was tested due to their higher performances compared to 3_g.

For SID LYS, scenarios 1 (feeder) and 2 (weighing scale) using unique sensors had the highest R² score (0.92, Table 4-8) and the lowest RMSE and MAPE values (Table 4-8). These results are followed by scenario 1+2 which combines feeder and scale data (1+2, MAPE = 5.31 %, Table 4-8). For ME, the most accurate predictions were obtained for scenarios 1+2 (feeder + scale), 1+3_i (feeder + accelerometer) and 1+4 (feeder + drinker, R² = 0.75, Table 4-8), and finally 1 (feeder, R² = 0.73-0.74, Table 4-8).

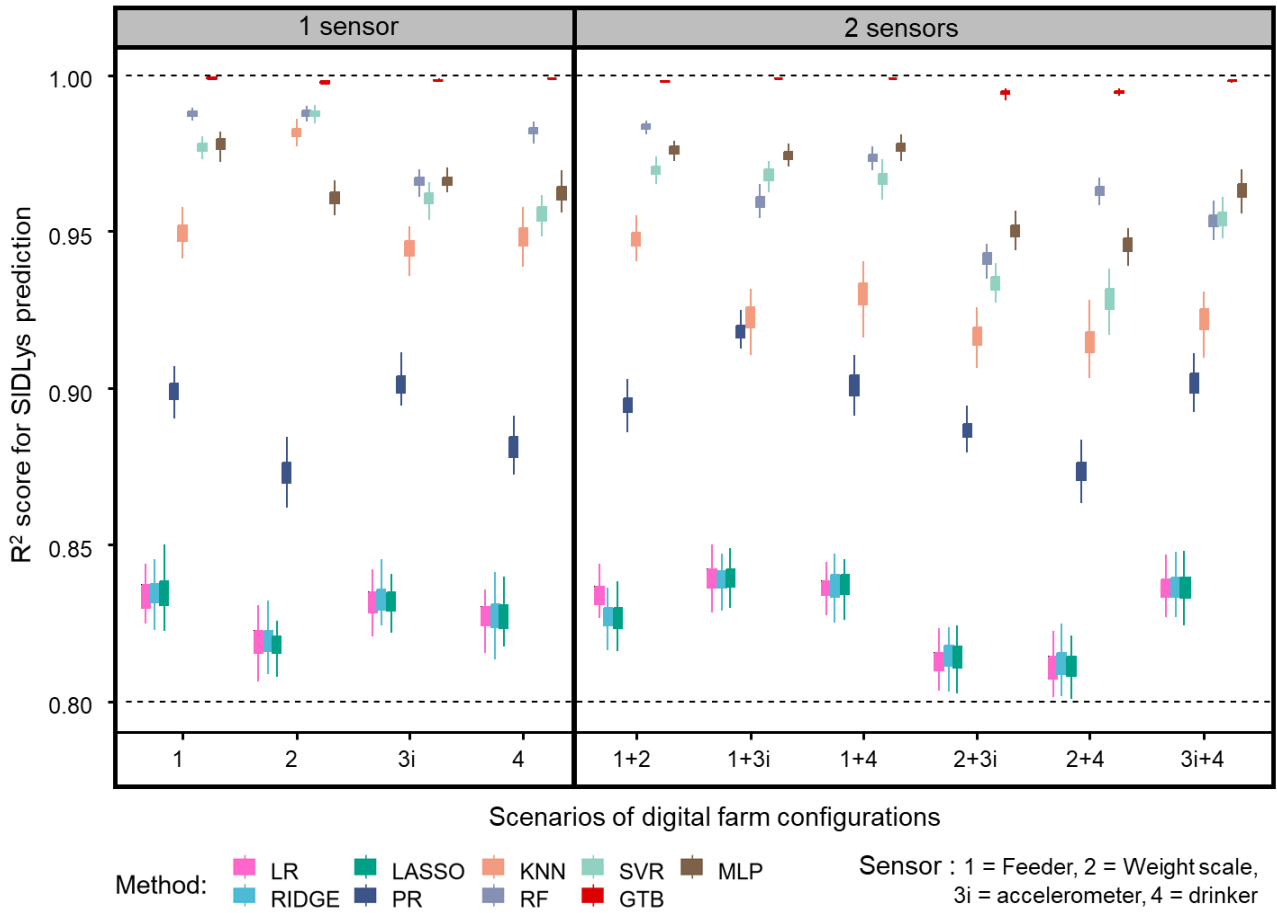


Figure 4-9: Evaluation of the 11 scenarios with sow and housing characteristics: R² scores for SID Lys prediction, according to the 9 algorithms evaluated, with 1 or 2 sensor(s).

The lowest MAPE and RMSE values (Table 4-7) and the highest R² scores (0.97-0.99 for SIDLYS and 0.89-0.95 for ME) were obtained with GTB first (Figures 4-9 and 4-10, in red), followed by RF (Figures 4-9 and 4-10, in light purple), then MLP (Figure 4-9 and 4-10, in brown). The lowest prediction performances for SID LYS and ME were obtained with LR, LASSO and RIDGE (Table 4-7). All the algorithms showed low variations between the 100 validation steps (Figures 4-9 and 4-10), except for PR (in dark blue).

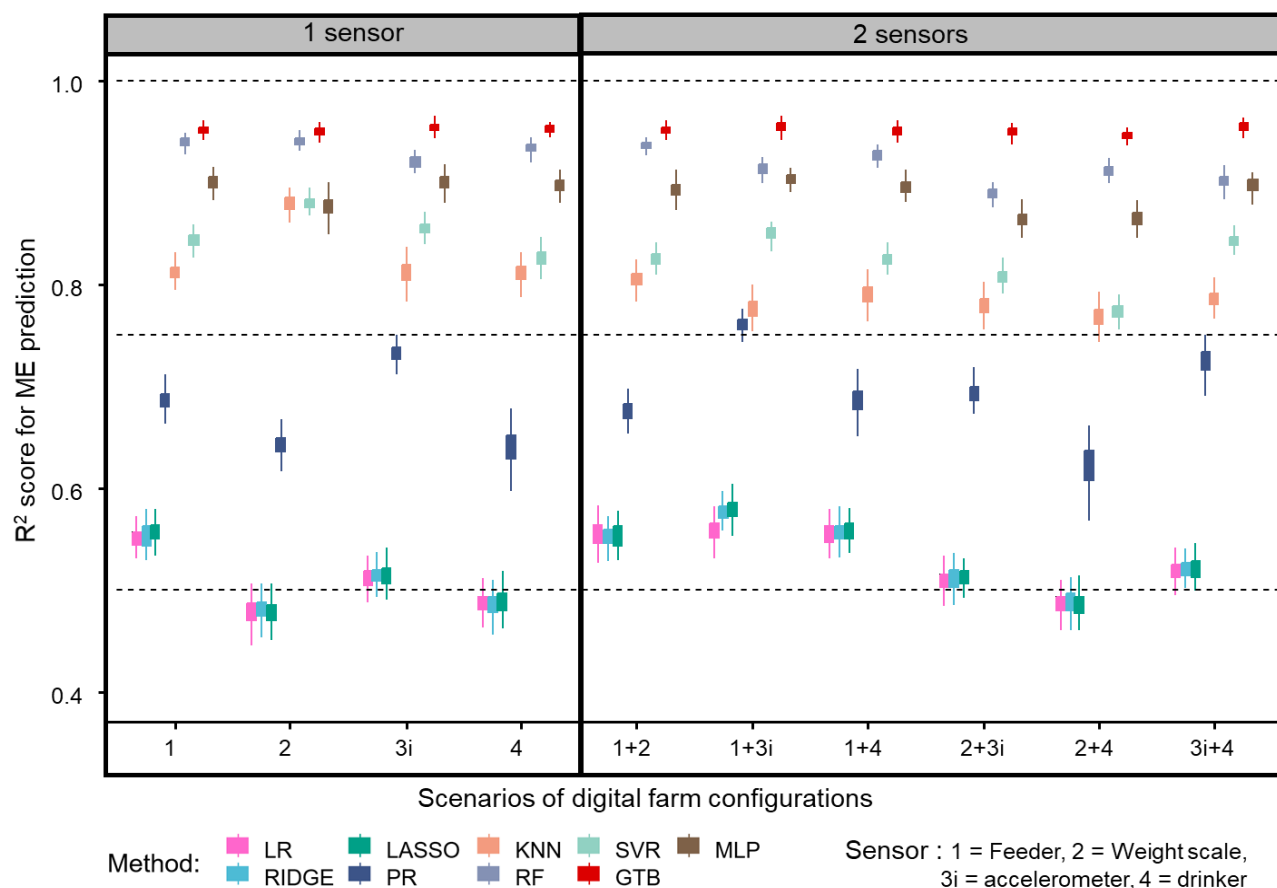


Figure 4-10: Evaluation of the 11 scenarios with sow and housing characteristics: R² scores for ME prediction, according to the 9 algorithms evaluated, with 1 or 2 sensor(s).

Due to their higher R² result with the single-sensor scenario, the ablation study was carried out on scenario 1 (feeder) using the Gradient Tree Boosting (GTB) algorithm for SID Lys and ME. Excluding 'rank_cat' from the feeder features in scenario 1 increased the MAPE values for SID Lys by 0.22 % (Figure 4-11.A.), compared to scenario 1 with all the features (feeder with sow and housing characteristics). Only the exclusion of 'nb_NNV' decreased the MAPE values of SID Lys (Figure 4-11.A.). For ME, all the features excluded increased the MAPE values, the highest increase being 0.11 % with the exclusion of 'time_NV' (Figure 4-11.B.). Among the sow and housing characteristics, the exclusion of 'day' and 'body - weight' from scenario 1 increased the MAPE values by 2.41 % and 0.60 % (Figure 4-11.A) for SID Lys, respectively. For ME, excluding the 'temperature' and 'day'

features increased the MAPE values by 0.29 % and 0.69 % (Figure 4-11.B), respectively.

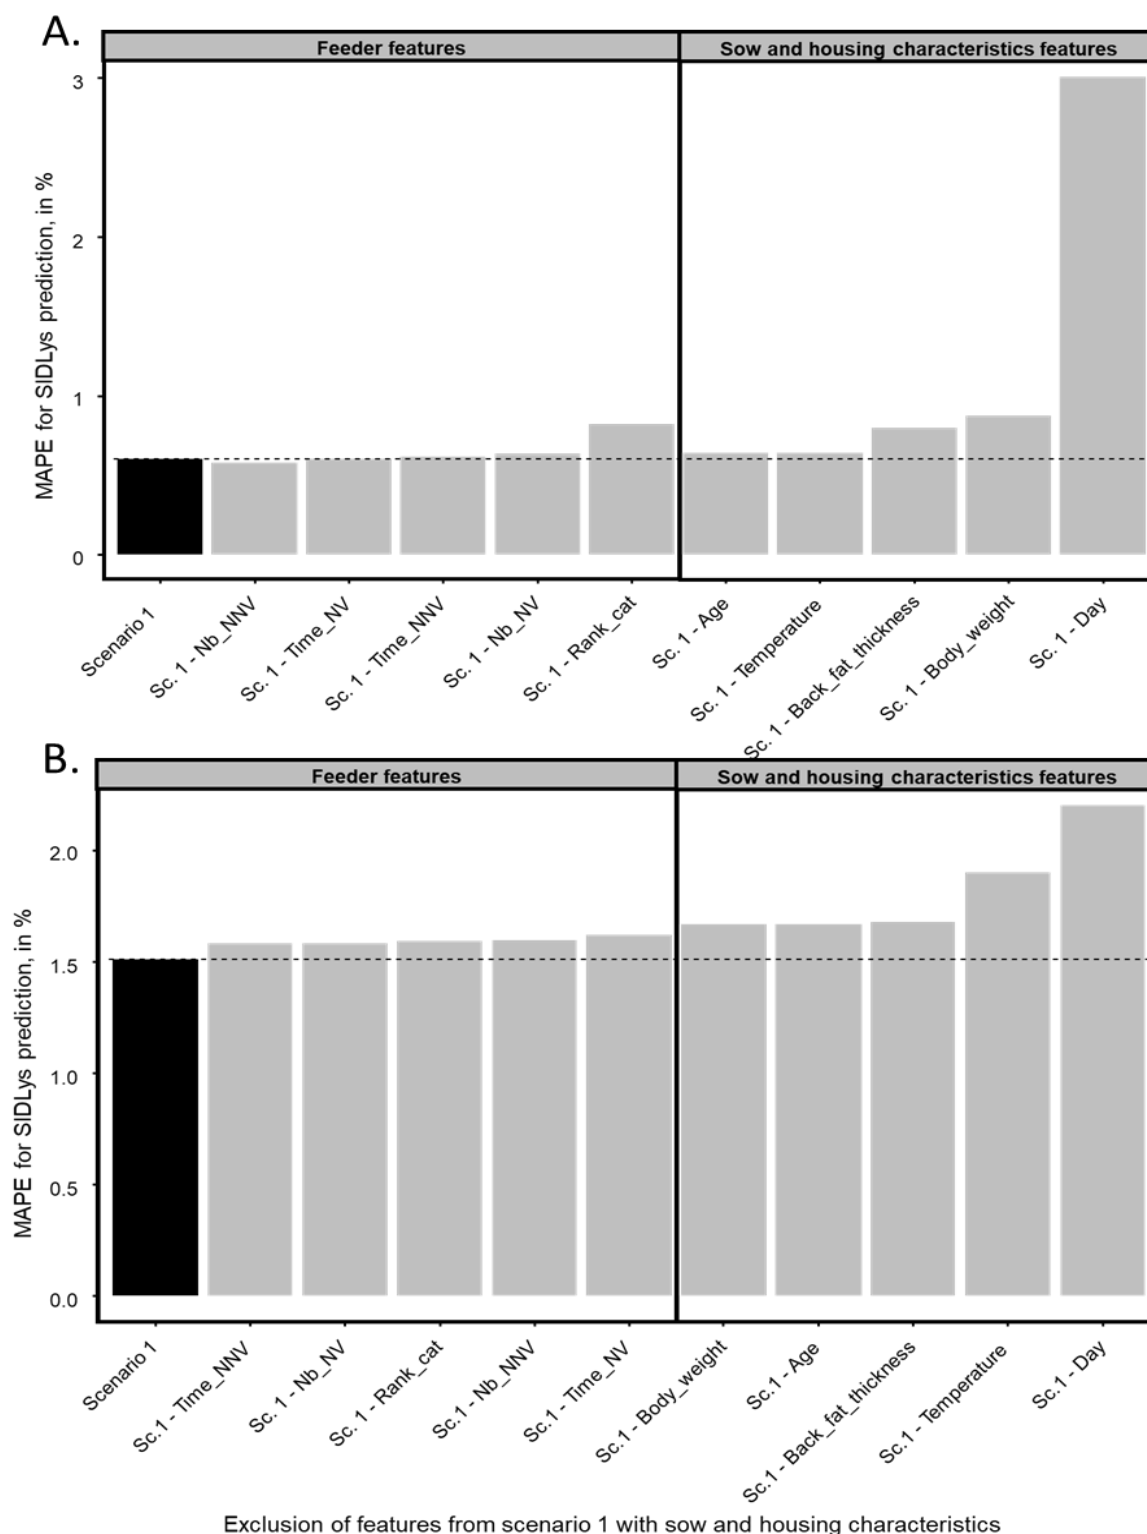


Figure 4-11: Ablation study : MAPE values (%) of GTB for standard ileal digestible lysine (SID LYS) and for metabolizable energy (ME) according to the all the

features excluded from scenario 1 (feeder data) with sow and housing characteristics.

4.2.4. Discussion

i. Overall performances

Digestible lysine and metabolizable energy are key components of the sows' feed costs during their gestation. A requirement prediction error under 5% is considered relatively satisfactory. The MAPE values showed that the machine-learning methods gave low prediction errors (under 5 and 7% for ME and SID Lys, respectively). The coefficient of determination (the R^2 score) showed that the nine supervised algorithms offered accurate prediction, especially for scenarios with sow and housing characteristics with all of the sensor data, for SID Lys (0.88-0.92) as well as ME (0.71-0.76). This study highlights the fact that predicting the daily nutrient requirement of gestating sows is possible using data measured by sensors and machine-learning methods. Moreover, in the case of two sensors, the prediction was conducted without requiring information on sow characteristics (such as their farrowing performance), which allows the integration of new sows into the herd for future application. A simple application of precision farming at an individual level in farms equipped with sensors or automatons is possible, despite using a complex mechanistic model that requires several data inputs and a prediction of farrowing performances (based on historical data). Such use of only one or two sensors, already used for other tasks on the farm, paves the way for a 'Green Artificial Intelligence' (Ferrag *et al.*, 2020; Sharma *et al.*, 2022). Sensors could be expensive for farmers, but also expensive in terms of valuable metal resources with complicated recycling processes, therefore optimizing the use of existing on-farm sensors is relevant. In addition, the nutrition prediction algorithms used in this work consume little energy, with no need for the cloud or internet, and could be run on any basic computer available on a farm.

The learning process was based on the outputs of the InraPorc model (Dourmad *et al.*, 2008) modified by Gaillard *et al.* (2020a) for gestating sows. This model was set up thank to numerous validated equations determined by invasive measures such as the metabolic chamber. The use of these techniques is increasingly limited in research, which reinforces the use of models such as this

one. However, the question of genetic progress and its possible impact on these equations, determined several decades ago, could be raised. In this case, the model will be improved, or the learning process will have to be carried out again to predict other nutrients requirements (e.g. mineral requirements).

ii. Different prediction results due to diverse digital farm configurations

The overall results showed that the feeder alone (scenario 1) or combined with other sensors (such as body weight scales) gave higher performance results for predicting ME or SID Lys. The diurnal pattern of sow physical activity (especially the time spent in a standing position) was linked to the daily feeding behavior pattern and meal schedule (Haskell *et al.*, 2000; Chapinal *et al.*, 2010). This feeding behavior could thus be used as a proxy of the time spent in a standing position, a key predictor of daily requirements in ME (Gaillard *et al.*, 2019). The importance of the time spent eating (for feeding visits) on the best model was shown by the ablation study results. The lysine requirement of the model was calculated based on body weight and parity (Gaillard *et al.*, 2019). In fact, Lanthony *et al.* (2021) showed that the feeder order could be an indicator of dominance hierarchy, which is linked to parity (or sow age) and body weight. That is why combined feeder data and daily body weight had approximately the same level of prediction performances with scenarios with or without sow and housing characteristics. This dominance hierarchy was also shown in the ablation study as a principal component of the best prediction model for lysine.

Moreover, the electronic feeder (best sensor performance) may possibly use precision feeding, which could decrease feed costs by \$3.67 per gestation (Gaillard *et al.*, 2020a). A renovation of gestation rooms from individual stalls into a group pen with electronic feeder costs between \$108-210 (Turcotte *et al.*, 2015). The return on investment was estimated as being between 9 and 18 years.

Scenario 3i, which included individual activity measures, gave a better performance for SID Lys than a prediction based on group data (scenario 3g). This could be explained by the fact that the group activity values were considered to

be the same for primiparous and multiparous sows (one value for all the sows within a group), while other studies showed that there was a difference in activity between parities (Chapinal *et al.*, 2010), as with the accelerometer in this study. However, this difference was slight for ME, which is relatively surprising. However, the group activity measures give more detailed information than individual measures, with the ventral and lateral lying positions, and the drinking and eating activities. This lateral/ventral lying behavior is linked to thermoregulation mechanisms (Geers, 2007). Therefore, room temperature could affect nutrient and energy requirements (Gaillard *et al.*, 2021), as also shown in the ablation study (MAPE values increased by 0.21% without it). An improvement of the individual level with more details on activity may thus improve prediction performances.

iii. Importance of sow and housing characteristics for prediction

Including sow and housing characteristics is relevant when only one sensor or automaton is available on the farm. It will give more accurate prediction results. When two sensors are used for prediction, these characteristics are not needed, and even decrease the prediction performance. These variables were also inputs of the model due to their impact on the calculation of requirements. The 'Day of gestation' variable had an effect on prediction, as the requirements for energy and lysine (showed with the ablation study) increased during gestation due to the fetus's growth (Trottier *et al.*, 2015). Despite the scenario or algorithm chosen, this variable had to be included in the dataset for prediction. The 'Backfat thickness' and 'Body Weight' variables at insemination were also important predictors because they are indicators of the body's reserves status before gestation, and the calculation of requirements was based on this information (Gaillard *et al.*, 2019). Real-time technology for measuring this feature would also be a good scenario to test in terms of prediction, as detailed in the study of Fernandes *et al.* (2020).

iv. Different prediction results due to various supervised algorithms

The most accurate algorithms were GTB and RF followed by MLP ($R^2=0.97-0.99$ for SID Lys and $0.89-0.95$ for ME, for scenarios with sow and housing characteristics). The GTB, RF or MLP machine-learning algorithms were also used in some studies, with good results. For instance, Kleanthous *et al.* (2018) obtained good performances with RF, GTB and MLP algorithms (especially with RF, accuracy = 96%) to classify livestock behavior, based on accelerometer data. Moreover, training GBT and RF models can be computationally expensive and time-consuming. GBT models have several hyperparameters that need to be tuned and are sensitive to noisy data. Despite these limitations, these techniques are widely used and highly effective in various machine learning applications due to their higher performances, simplicity and interpretability (Schapire, 1999; Breiman, 2001; Valetta *et al.*, 2017). Their interpretability may be a key determinant of the adoption of these algorithms for users in non-informatics domains, such as animal nutritionists or breeders. For example, with a particularly low amount of ME requirements, farmers may need to check why the algorithm gave this specific value and increase their trust in the system used.

The algorithms of linear regression (LR, LASSO and RIDGE) obtained the worst prediction performances ($R^2 = 0.83$ for SID Lys and 0.52 for ME, for scenarios with sow and housing characteristics), which means that the relationship between predictors and nutrient requirements was not linear. Misiura *et al.* (2021) also obtained accurate results with a non-linear model compared to a linear model for precision feeding for growing-finishing pigs, by predicting feed intake and growth. The prediction of the body weight of piglets at 30 days had a MAPE value of 11.0% with the linear model, and 2.1% with the allometric model.

4.2.5. Conclusion

This study showed that using machine-learning methods on behavioral data to predict the daily nutrient requirements of sows is possible and accurate. Among the different digital farm configurations tested, the feeder data (alone or combined with another sensor) obtained better performances for predicting metabolizable energy and for standard ileal digestible lysine. The inclusion of sow and housing characteristics in the sensor data improves prediction performance. However, the two pieces of equipment combined without these characteristics obtained the same level of performance as the one obtained using data from one equipment and these characteristics. When the linear regression models obtained the worst accuracy and highest prediction error, the Gradient Tree Boosting, Random Forest and Multiple Layer Perceptron obtained high prediction performances. This study paves the way for an easier application of precision feeding on farms with available sensors.



Les résultats de ce chapitre ont montré qu'il était possible de prédire précisément les besoins nutritionnels à l'aide de capteurs ou automates et des techniques de machine learning. Les données des automates et des capteurs pourraient être également utilisées pour prédire l'état de bien-être des truies gestantes.

4.3. Références bibliographiques

- Arulmozhi E., Bhujel A., Moon B.E., Kim H.T., 2021. Application of Cameras in Precision Pig Farming: An Overview for Swine-Keeping Professionals. *Animals*, 11, 2343.
- Bench C.J., Rioja-Lang F.C., Hayne S.M., Gonyou H.W., 2013. Group gestation sow housing with individual feeding – II: How space allowance, group size and composition, and flooring affect sow welfare. *Livest. Sci.*, 152, p.218-227.
- Benjamin M., Yik S., 2019. Precision livestock farming in swine welfare: A review for swine practitioners. *Animals*, 9, 133.
- Berckmans D., 2017. General introduction to precision livestock farming. *Anim. Front.*, 7, p.6-11.
- Breiman L. 2001. Random forests. *Mach. Learn.*, 45, p.5-32.
- Chapa J.M., Maschat K., Iwersen M., Baumgartner J., Drillich M., 2020. Accelerometer systems as tools for health and welfare assessment in cattle and pigs – A review. *Behav. Proc.*, 181, 104262.
- Chapinal N., Ruiz de la Torre J.L., Cerisuelo A., Gasa J., Baucells M.D., Coma J., Vidal A., Manteca X., 2010. Evaluation of welfare and productivity in pregnant sows kept in stalls or in 2 different group housing systems. *J. Vet. Behav.*, 5, p.82-93.
- Cooper D.R., Patience J.F., Zijlstra R.T., Rademacher M., 2001. Effect of energy and lysine intake in gestation on sow performance. *J. Anim. Sci.*, 79, p.2367-2377.
- Dourmad J.Y., Etienne M., Valancogne A., Dubois S., van Milgen J., Noblet J., 2008. InraPorc: A model and decision support tool for the nutrition of sows. *Anim. Feed. Sci. Technol.*, 143, p.372-386.
- Durand M., Simon M., Foisil J., Dourmad J.Y., Largouët C., Gaillard C., 2022. Evaluation of the physical activity of a group of gestating sows using an artificial neural network. In : EAAP scientific committee (Ed.), Book of Abstracts of the 73rd Annual Meeting of the European Association of Animal Production, Porto, Portugal, p.455.
- Durand M., Largouët C., Bonneau L., Dourmad J. Y., Gaillard C., 2023. A dataset to study group-housed sows' individual behaviours and production responses to different short-term events. *Animal - Open Space*, 2, 100039.
- Escalante H.J., Rodriguez S.V., Cordero J., Kristensen A.R., Cornou C., 2013. Sow-activity classification from acceleration patterns: a machine learning approach. *Comput. Electron. Agric.*, 93, p.17-26.
- Fernandes A.F.A., Dorea J.R.R., Dourado V.B., Fitzgerald R., Herring W., Rosa G.J.M. 2020. Comparison of data analytics strategies in computer vision systems to predict pig body composition traits from 3D images. *J. Anim. Sci.*, 98, p.1-9.

Nouvelle méthode de prédiction des besoins nutritionnels à partir d'automates et de capteurs

- Ferrag M.A., Shu L., Yang X., Derhab A., Maglaras L., 2020. Security and Privacy for Green IoT-Based Agriculture: Review, Blockchain Solutions, and Challenges. *IEEE Access*, 8, p.32031-32053.
- Gaillard C., Gauthier R., Cloutier L., Dourmad J.Y., 2019. Exploration of individual variability to better predict the nutrient requirements of gestating sows. *J. Anim. Sci.*, 97, p.4934-4935.
- Gaillard C., Quiniou N., Gauthier R., Cloutier L., Dourmad J.Y., 2020a. Evaluation of a decision support system for precision feeding of gestating sows. *J. Anim. Sci.*, 98, p.1-12.
- Gaillard C., Brossard L., Dourmad J.Y., 2020b. Improvement of feed and nutrient efficiency in pig production through precision feeding. *Anim. Feed. Sci. Technol.*, 268, 114611.
- Gaillard C., Durand M., Largouët C., Dourmad J.Y., Tallet C., 2021. Effects of the environment and animal behavior on nutrient requirements for gestating sows: Future improvements in precision feeding. *Anim. Feed. Sci. Technol.*, 279, 115034.
- Gaillard C., Dourmad J.Y., 2022. Application of a precision feeding strategy for gestating sows. *Anim. Feed. Sci. Technol.*, 287, 115280.
- Galaz V., Centeno M.A., Callahan P.W., Causevic A., Patterson T., Brass I., Baum S., Farber D., Fischer J., Garcia D., Mc Phearson T., Jimenez D., King B., Larcey P., Levy K., 2021. Artificial intelligence, systemic risks, and sustainability. *Technol. Soc.*, 67, 101741.
- Geers R., 2007. Lying behaviour (location, posture and duration). In : A. Velarde & R. Geers (Eds.), On farm monitoring of pig welfare, Wageningen Academic Publishers, Wageningen, Pays-Bas, p.19-23.
- Géron, A. 2019. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems. O'Reilly Media, Sebastopol, Etats-Unis, 856p.
- Hansen A.V., Strathe A.B., Theil P.K., Kebreab E., 2014. Energy and nutrient deposition and excretion in the reproducing sow: model development and evaluation. *J. Anim. Sci.*, 92, p.2458-2472.
- Haskell M.J., Mendl M.T., Lawrence A.B., Austin E., 2000. The effect of delayed feeding on the post-feeding behaviour of sows. *Behav. Proc.*, 49, p.85-97.
- He Y., Tiezzi F., Howard J., Maltecca C., 2021. Predicting body weight in growing pigs from feeding behavior data using machine learning algorithms. *Comput. Electron. Agric.*, 184, 106085.
- Kleanthous N., Hussain A., Mason A., Sneddon J., Shaw A., Fergus P., Chalmers P., Al-Jumeily D., 2018. Machine Learning Techniques for Classification of Livestock Behavior. In : ICONIP 2018: Neural Information Processing, Siem Reap, Cambodge, p. 304-315.
- Lanthon M., Danglot M., Spinka M., Tallet C., 2022. Dominance hierarchy in groups of pregnant sows: Characteristics and identification of related indicators. *Appl. Anim. Behav. Sci.*, 254, 105683.
- Llonch P., Neethirajan S., Morgan-Davies C., 2022. Editorial: Understanding animals' phenotype through automatic behavior assessment. *Front. Anim. Sci.*, 3, 1069387.

Nouvelle méthode de prédiction des besoins nutritionnels à partir d'automates et de capteurs

Mahfuz S., Mun H. S., Dilawar M. A., Yang C.J., 2022 Applications of Smart Technology as a Sustainable Strategy in Modern Swine Farming. *Sustainability*, 14, 2607.

Matthews S.G., Miller A.L., Clapp J., Plötz T., Kyriazakis I., 2016. Early detection of health and welfare compromises through automated detection of behavioural changes in pigs. *Vet. J.*, 217, p.43-51.

Misiura M.M., Filipe J.A.N., Brossard L., Kyriazakis I., 2021. Bayesian comparison of models for precision feeding and management in growing-finishing pigs. *Biosyst. Eng.*, 211, p.205-218.

Neethirajan S., 2020. The role of sensors, big data and machine learning in modern animal farming. *Sens. Bio-Sens. Res.*, 29, 100367.

Noblet J., Shi X.S., Dubois S., 1993. Energy cost of standing activity in sows. *Livest. Prod. Sci.*, 34, p.127-136.

Ollagnier C., Kasper C., Wallenbeck A., Keeling L., Bee G., Bigdeli S.A., 2023. Machine learning algorithms can predict tail biting outbreaks in pigs using feeding behaviour records. *PLoS ONE*, 18, e0252002.

Pedregosa F., Varoquaux G., Gramfort A., Michel V., Thirion B., Grisel O., Blondel M., Prettenhofer P., Weiss R., Dubourg V., Vanderplas J., Passos A., Cournapeau D., Brucher M., Perrot M., Duchesnay E., 2011. Scikit-learn : Machine Learning in Python. *J. Machine Learn. Res.*, 12, p.2825-2830.

Pomar C., van Milgen J., Remus A., 2019. Precision livestock feeding, principle and practice. In : W.H. Hendriks, M.W.A. Verstegen & L. Babinszky (Eds.), Poultry and pig nutrition, Wageningen Academic Publishers, Pays-Bas, p. 397-418.

Quiniou N., 2021. Results of 15 Years of Precision Feeding of Hyper Prolific Gestating Sows. *Animals*, 11, 2908.

Sauvant D., Perez J.M., Tran G., 2004. Tables INRA-AFZ de composition et de valeur nutritive des matières premières destinées aux animaux d'élevage : 2ème édition. INRA Editions Versailles, France, 301p.

Schapire R.E., 1999. A brief introduction to boosting. In : Proceedings of the IJCAI International Joint Conference on Artificial Intelligence, Volume 2, Stockholm, Sweden, p. 1401-1406.

Sharma A., Georgi M., Tregubenko M., Tselykh A., Tselykh A. 2022. Enabling smart agriculture by implementing artificial intelligence and embedded sensing. *Comput. Ind. Eng.*, 165, 107936.

Siegford J., Guzhva O., 2021. Editorial: Integration of ethical and social aspects into precision livestock farming-Achieving real-world impact responsibly. *Front. Anim. Sci.*, 2, 780334.

Trottier N.L., Johnston L.J., de Lange C.F.M., 2015. Applied amino acid and energy feeding of sows. In : C. Farmer (Ed.), The gestating and lactating sows, Wageningen Academic Publishers, Wageningen, Pays-Bas, p.117-145.

Nouvelle méthode de prédiction des besoins nutritionnels à partir d'automates et de capteurs

Valleta J.J., Torney C., Kings M., Thornton A., Madden J., 2017. Applications of machine learning in animal behaviour studies. *Anim. Behav.*, 124, p.203-220.

Weng R.C., Edwards S.A., Hsia L.C., 2009. Effect of Individual, Group or ESF Housing in Pregnancy and Individual or Group Housing in Lactation on Sow Behavior. *Asian-Aust. J. Anim. Sci.*, 22, p.1574-1580.

5. Estimation de l'état de bien-être des truies à partir de méthodes de machine learning

L'objectif de ce chapitre est d'estimer l'état de bien-être de deux troupes de truies différents (français et canadien) grâce à des méthodes de machine learning.

L'expérimentation française a permis la collecte de comportements analysés via des vidéos. À partir de ces données, des profils comportementaux (clusters) ont pu être reliés à différentes conditions environnementales et à l'état de santé et de bien-être des truies. Un arbre de décision, a été utilisé par la suite pour prédire les clusters à l'aide de données d'automates alimentaires et d'un logiciel d'analyse de vidéo automatique.

Les données de santé et de bien-être enregistrées lors de l'expérimentation au Canada ont permis de créer un modèle expert de classification du bien-être. Un arbre de décision, a été également utilisé pour prédire l'état de bien-être (modèle expert) à l'aide de données d'automates alimentaires et de caméra thermique.

5.1. Expérimentation française

Les résultats de cette partie font l'objet d'une publication soumise et en cours de révision à Scientific reports (8).

Résumé en français

L'estimation de l'état de bien-être à l'échelle individuelle dans des fermes est un sujet d'actualité pour améliorer le suivi des animaux d'élevage. Les nouvelles technologies offrent des possibilités d'analyse du comportement des animaux grâce au machine learning et aux capteurs. L'objectif de cette étude était d'estimer certaines composantes du bien-être des truies gestantes à l'aide de méthodes de machine learning et de données comportementales.

La base de données combinait des mesures individuelles et collectives du comportement (activité, comportement social et comportement alimentaire). Une méthode de clustering a été utilisée pour estimer le bien-être de 69 truies (réparties en quatre groupes) à différentes périodes (deux jours par semaine) de la gestation (entre 6 et 10 périodes, selon le groupe). Trois clusters ont été identifiés et labellisés (gentille, bouc-émissaire et agressive). Les conditions environnementales et la santé des truies ont influencé les proportions de truies dans les trois clusters comportementaux, contrairement aux caractéristiques de la truie (âge, poids ou état corporel). Les résultats ont également confirmé l'importance du comportement du groupe sur le bien-être de chaque individu. Un arbre de décision a été appris et utilisé, par la suite, pour classer les truies dans des catégories de bien-être issues de l'étape de clustering. La classification s'est appuyée sur des données obtenues à partir d'un automate d'alimentation et d'une analyse automatique de vidéos, avec un taux de précision supérieur à 72%. Cette étude a montré le potentiel d'un système automatique d'aide à la décision pour attribuer un niveau de bien-être en fonction du comportement de chaque truie gestante et du groupe de truie.

Estimation of gestating sows' welfare status based on machine learning methods and behavioural data

Durand M., Largouët C., Bonneau de Beaufort L., Dourmad J.Y., Gaillard C.

5.1.1. Introduction

Animal welfare may be defined as “the positive mental and physical state linked to the satisfaction of its physiological and behavioural needs, as well as its expectation. This state varies according to the animal's perception of the situation” (Anses, 2018 ; Mormède *et al.*, 2018 ; Reimert *et al.*, 2023). In literature, a lot of researchers try to evaluate the welfare of animals on farms. In Europe, one example is the Welfare Quality program, which was developed for the main species of farm animals (Dalmau *et al.*, 2009). However, these protocols, as the animal needs index (Bartussek, 1999), the qualitative behavior assessment (Rutherford *et al.*, 2012) and the semantic modelling (Bracke *et al.*, 2008), evaluated the welfare at group level for feasibility on commercial farm. Few studies have been dedicated to welfare at the individual scale with an evaluation of behaviour (social interactions or physical activity level) as a reflection of animals' emotions (Boissy *et al.*, 2007 ; Veissier *et al.*, 2009). Different events may have an impact on animal behavior and physiology, such as in pigs thermal variations (Bjerg *et al.*, 2020), sound emission (Otten *et al.*, 2004), enrichment (Douglas *et al.*, 2012), feeder competition (Chapinal *et al.*, 2010), *etc.* These events have an impact on the groups' behavior. However, variability between animals should be taken more seriously into account, due to the individual perception of an animal confronted with a stimulus (Boissy *et al.*, 2007 ; Veissier *et al.*, 2009 ; Reimert *et al.*, 2023).

Data issued from sensors or automatons used for individual monitoring could be a way to study and automatically evaluate the behavioral response of each animal to an event and its welfare state (Rushen *et al.*, 2012 ; Neethirajan, 2020). These technologies are appearing on farms due to the development of precision livestock farming, defined as “the management of livestock production using the principles and technology of process engineering” (Wathes *et al.*, 2008).

The use of sensors or other connected objects (like electronic weight scale or ventilation regulatory system) allow individual monitoring of animals, often based on a Radio Frequency Identification (RFID) recognition of the animals (Neethirajan, 2020). For example, electronic feeders could be used to feed pigs but also to predict disease outbreaks at the group level (Kavlak *et al.*, 2023) and tail biting outbreaks (Wallenbeck and Keeling, 2013; Ollagnier *et al.*, 2023) at the group level; or to predict body weight or feed intake at an individual level (He *et al.*, 2021 ; Gauthier *et al.*, 2021). To analyse the large amount of real-time data collected by sensors, machine learning methods could be used, involving algorithms learning from data to solve a specific task (Llonch *et al.*, 2022).

Identifying farm animal welfare is a growing sustainability concern for society that may benefit from automated recording. The aim of this paper was to categorize the individual welfare status of gestating sows based on behavioral data (social behavior and physical activity), including days during which environmental perturbations were induced, employing machine learning techniques. As many welfare studies failed to estimate individual welfare, this study may show a new way to approach the ideal state of really assessing welfare in focusing on the behavioral components of welfare. First, three groups of behaviors (clusters) were defined using a clustering method on the behavioral data. Then, these clusters were interpreted using sow characteristics, health status and environmental conditions to relate to welfare status. Finally, the classification of the gestating sows was performed, using the labelling issued from the clustering, to predict the welfare status of each animal. This classification relied on continuous variables, linked to feeding behavior and postures, extracted from automaton and sensor (feeder and camera) collected during two days per week over 6 to 10 weeks, depending on the group of sows.

5.1.2. Methods

i. General approach

The objective of the study was to estimate the welfare status of each animal on a farm (Figure 5-1) in an automatic manner for convenience and cost. Automaton and sensors automatically produce a lot of data at an individual scale,

linked to the animals' behaviour, that could be used for its welfare estimation. Behavioral data like social behaviour (Gonyou, 2001), postures and occupation (lying, standing, walking, eating, drinking, exploring behavior) can indeed be used to evaluate some components of the welfare status (Velarde et Geers, 2007; McGlone, 2013) of an animal or its emotional state (Kremer *et al.*, 2020; Horback et Parsons, 2022) and were therefore considered in this study as the true field (also called ground truth).

During the offline learning process, a clustering algorithm was applied on behavioral data collected from manual video analysis (Figure 5-1). Clustering results propose to group the gestating sows with similar behaviours into 3 sub-groups (called clusters). This clustering task was done on a dataset with a total of 388 individual observations from 69 sows, ie. one sow per period (sum of two days per week: Tuesday and Wednesday) on a total of 6 to 10 periods per sows (depending of the group, Figure 5-1). These periods corresponded to control periods (*i.e.* baseline behaviour) or events periods with induced perturbations of the environment during few days (three to five days) in the week, to induce changes in behaviours and welfare status). The idea of these perturbations was to increase the behavior variability between sows.

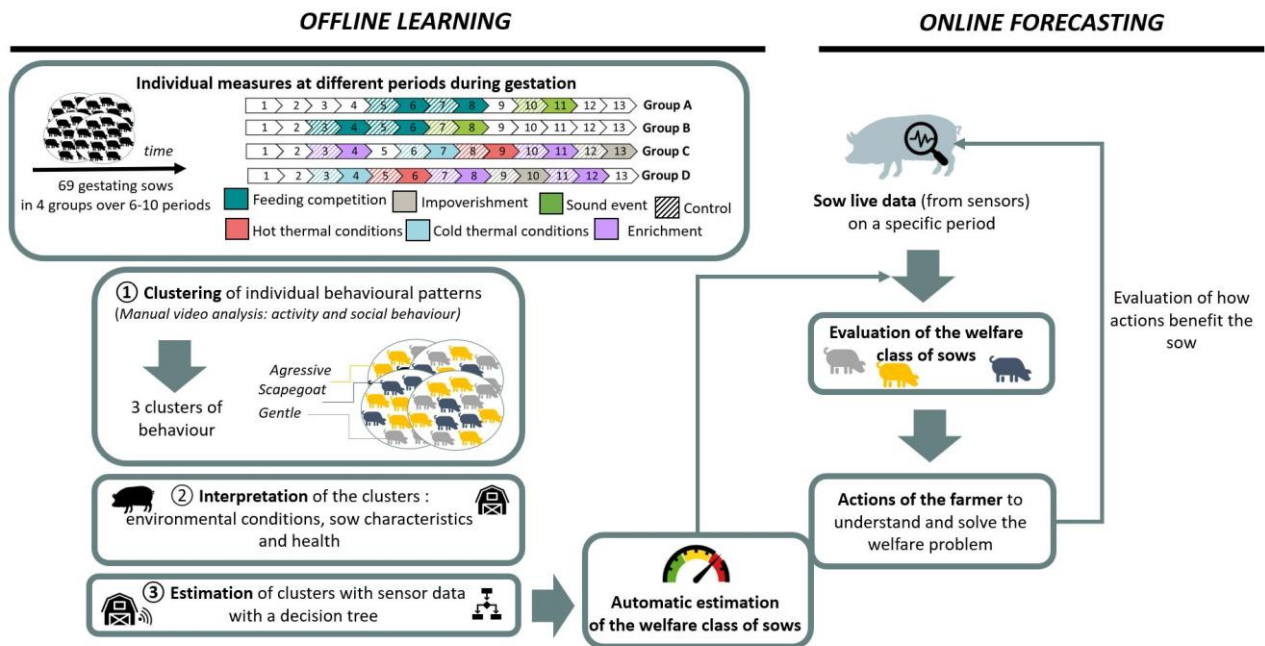


Figure 5-1: General approach of the current study (offline learning part) and practical perspectives (online forecasting). The number (first box, upper left) corresponds to the week of gestation.

The method is also composed, during the offline learning process, of the exploration of the behavioural data set which aim to produce an interpretable model, *i.e.* a decision tree. For the online forecasting, given some new data on a sow (feeder and automatic video analysis data), the already learned decision tree classifies the sow into one of the welfare group.

For the offline learning process, the relation of the clustering results with welfare status was interpreted using individual characteristics of the sows (age, body weight, back fat thickness, health status) and the experimental setup (control vs. events). This clustering step enables data annotation, paving the way for the application of a supervised and interpretable machine learning algorithm. Once the data were annotated with the cluster labels, a decision tree was learned on sensor data, feeder and automatic video analysis. The performance of this classification was evaluated using the labels obtained by the clustering step. It's a way of classifying sows into different clusters using other data, *i.e.* automatically recorded data (feeder and cameras).

For the online forecasting process, the decision tree is used for inference on new live data from the sows (feeder and automatic video analysis data) and provides the predicted welfare class label of the sow. One of the major interests of the decision tree is its interpretability, which makes it a valuable tool for understanding the algorithm decision rules behind predictions.

ii. Animal and Management

This study was carried out from July 2020 to April 2021, at the Pig Physiology and Phenotyping Experimental facility (UE3P, Saint Gilles, France; <https://doi.org/10.15454/1.5573932732039927E12>) of the French National Research Institute for Agriculture, Food and Environment (INRAE). The experimental protocol was approved by the local Ethics Committee in Animal Experimentation in Rennes (France) and the French Ministry of Higher Education, Research and Innovation (authorization on living animals No. APAFIS 25883-2020070711528084) in accordance with the French legislation on experimental

animal care. All methods used on the experimental protocol were carried out in accordance with relevant French and European guidelines and regulations and with ARRIVE guidelines.

A total of 69 crossbred sows (Landrace X Large White), housed in four gestating rooms with one pen inside (groups A, B, C and D), were studied throughout their gestation. The parity of the sows ranged from 1 to 10, included 16 primiparous (4 per group). All sows were confirmed to be pregnant (by ultrasound) 30 days after insemination. After pregnancy confirmation, the number of sows kept per group was between 17 (for group A, B and D) and 18 (for group C). Sows were group-housed from a few days after artificial insemination to almost the end of their gestation at 104 days. The gestating room had a concrete floor enriched with straw and two chains. The space allowance was of 3.1 m²/sows. Two cameras (RS-CCPOE280IR4-DH, Ro-main Inc., Canada) per room recorded continuously the sows. Ad libitum access to clean water was provided by two electronic drinkers (Asserva, France). Each sow received an individualised ration from two self-locking electronic feeders (Gestal, JYGA Technologies Inc., Canada) able to identify the sows' RFID ear tag. The quantity of feed supply was calculated individually but fixed for all the gestation (despite a general increase of 500 g/d from 86 days), while the ration composition was adjusted daily with an individual blend of two diets (a low and a high nutrient content: with a standard ileal digestible lysine content of 3.30 and 8.50 g/kg of feed, respectively). Nutrient requirements were calculated thanks to the nutritional model InraPorc (Dourmad *et al.*, 2008 ; modified by Gaillard *et al.*, 2019).

During the gestation period, different events were induced for few days (starting on Mondays at noon) in the gestation room: a competitive situation for feed (occurred twice), a sound event (occurred once), cold and hot thermal variations (occurred once each), an enrichment (occurred twice) and an impoverishment (occurred once) of the environment. Each "event week" followed a "control week" (a week without any induced event). The competitive situation for feed was created by closing one of the two available feeders in the gestation room, for five days and nights (described in Durand *et al.*, 2023a). The sound event was induced by the random emission of 40 sounds of 30 seconds, under 85 decibels, every 10 minutes,

twice a day (23:00h-04:00h ; 13:30h-18h30h) for three days (described in Gaillard *et al.*, 2023). These two moments were chosen to correspond to a moment of high activity level (the night, as new feeding day started at midnight) and a moment of low activity level (the afternoon with a resting period). The cold and hot thermal events consisted of setting the thermostatic control at 12 ± 2 °C and 32 ± 2 °C, respectively, using ventilation fans or heaters, for three days and nights (described in Abarnou *et al.*, 2022). The impoverishment was induced by removing the straw bedding on the room. Finally, the enrichments were composed of the addition of straw during the first session and by the supply of jute bags, brush and ropes during the second session.

iii. Data collection

Every Monday, animal-based measures (number of skin lesions, cleanliness of the sow, and identification of potential health problems like) were evaluated based on the Welfare Quality® assessment (Dalmau *et al.*, 2009) with the same trained observer. A sow was categorized “unhealthy” if, during the measure, a health problem was detected (bursitis, lameness, tail biting, vulvar lesion or abscesses), otherwise, the sow was categorized “healthy”. The electronic feeders automatically recorded every visit of each sow (time of the day, duration of the visit, feed intake). Extracted data were pre-processed to filter the outliers (*i.e.* visit duration over 6 h, 0.007% of all the dataset) and aggregated at an individual scale for the 7 variables described in Table 5-1. The feeder order, *i.e.* the order in which the sows had access to the feeder, was also recorded and represented a proxy of the hierarchical order (*i.e.* rank 1 for the most dominant sows, Lanthony *et al.*, 2022). Manual analysis of videos was carried out in continuous by trained observers to monitor individual behavior (social and activity) for two moments (23:00 h-04:00 h and 13:30 h-18:30 h) of two days per period. The detailed ethogram is available in Durand *et al.*, (2023a) and raw data are available in a datapaper (Durand *et al.*, 2023b). From the video analysis, 3 indexes were calculated to obtain a limited number of variables gathering the intensity and the valence of the level of activity and social interactions (Table 5-1). For example, when the “Index_activity” has a negative value, the sow spent more time passive than active, and when the

"Index_giving" has a negative value, the sow gave more negative interactions than positive ones. An automatic analysis of videos was also achieved at a group level using a convolutional neural network algorithm (Dilepex, Rennes, France ; Durand *et al.*, 2022). In that case, data were aggregated on 6 variables as the percentage of sow detected in 6 postures (Table 5-1).

Table 5-1: Ethogram and description of the features used on the study (NV = nutritive visit; NNV = nonnutritive visit; cat = categories; Avg = average; Nb = number).

Features	Description
Features from manual video analysis (used for clustering)	
Active	Total time spent by a sow in active occupation, such as standing, walking, drinking, eating, exploring, or manipulating the enrichment objects.
Passive	Total time spent by a sow in passive occupation, such as sitting, lying, or observing.
Index_activity	Time spent 'Active' minus spent 'Passive' divided by the total time spent 'Active' and 'Passive'.
Giving positive interactions	Number of times a sow gives positive social interactions, such as huddling (lying with body contact with another sow), achieving "snout to snout" or sniffing.
Receiving positive interactions	Number of times a sow receives positive social interactions, such as huddling (lying with body contact with another sow), achieving "snout to snout" or sniffing.
Giving agonistic interactions	Number of times a sow gives agonistic social interactions, such as head knocking, pushing, biting, threatening, fleeing or attacking.
Receiving agonistic interactions	Number of times a sow receives agonistic social interactions, such as head knocking, pushing, biting, threatening, fleeing or attacking.
Index_giving	Number of 'Giving positive interactions' minus number of 'Giving negative interactions' divided by the total number 'Giving positive interactions' and 'Giving negative interactions'.
Index_receiving	Number of 'Receiving positive interactions' minus number of 'Receiving negative interactions' divided by the total number 'Receiving positive interactions' and 'Receiving negative interactions'.
Features from feeder data (used for decision tree)	
Nb_NV	Total number of nutritive visits (with feed consumption) at the feeder per period
Nb_NNV	Total number of non-nutritive visits (without feed consumption) at the feeder per period
Time_NV (in min)	Total duration of nutritive visits at the feeder per period
Time_NNV (in min)	Total duration of non-nutritive visits at the feeder per period
Avg_NNV (in min/visit)	Duration of non-nutritive visits divided by the number of non-nutritive visits
Avg_NV (in min/visit)	Duration of nutritive visits divided by the number of nutritive visits
Rank_cat	Sow order of visit to the feeder (indicator of hierarchical status)
Postures features from automatic video analysis (used for decision tree)	
Side_lying (%)	% of sows in side lying position (4 legs on the same side, flank fully on the ground)
Ventral_lying (%)	% of sows in ventral lying position (1 or more legs not visible or on the same side, flank not fully touching the ground)
Standing (%)	% of sows on the 4 legs (still or moving) only on contact with the floor
Sitting (%)	% of sows with the chest off the ground, the front legs straight and the back legs on the ground
Eating (%)	% of sows in the feeder (door closed and head in the trough)
Drinking (%)	% of sows in the drinker (head and two forelegs in the trough)

The behavioural data (from the manual and automatic video analysis and from the feeder) recorded on the same time windows, were aggregated in sums over a period of 2 days (Tuesday, Wednesday) per week to exclude days with animal manipulation.

iv. Clustering, non-supervised data mining method

Clustering algorithms group similar data together based on their intrinsic characteristics without any prior knowledge of the class labels. For this study, the unsupervised algorithm used for the clustering was K-medoids. The k-medoids clustering instead of using the mean value as the center of a cluster uses the actual data point that minimizes the total dissimilarity to all other points within the cluster. The medoid is then less affected by noise and outliers (abnormal values). The k-medoid clustering helps create more accurate and robust clusters and is a suitable choice when dealing with real-data applications where noise and outliers are a concern (Parks et Jun, 2009). The principle of the clustering algorithm is first to initialize the clusters centers randomly or accordingly to some criteria. Then, the algorithm iteratively assigns data points to one of the clusters based on similarity or distance measure and updates the cluster centers until the convergence. When applying a clustering algorithm, the parametrization requires selecting appropriate values for various parameters that affect the clustering approach. These parameters may include the number of clusters to generate, the distance metric used and the convergence criteria for stopping the iterative process. Choosing optimal values for these parameters is crucial as it impacts the quality of the clustering results (Parks et Jun, 2009).

The K-medoid clustering was performed on the dataset composed of three variables extracted from the manual analysis video ('ratio_activity', 'ratio_receiving', 'ratio_giving') and normalized before the clustering (values between -1 and 1). The appropriate number of clusters (from 1 to 10) was 3 for the clustering task, as it gave the highest performances with the following metrics: inertia, silhouette coefficient and graph, elbow graph, calinski-harabasz index and Davies-Bouldin index

(Pedregosa *et al.*, 2011). The distance metric used was Euclidean. The algorithm initialized the centroids using the k-means++ method, which resulted in better initialization and potentially improved the clustering performance (Pedregosa *et al.*, 2011).

v. Decision Tree, supervised classification method based on clustering label

The supervised classification method chosen was a Decision Tree applied on the data labelled by the classes issued from the previous clustering step. A decision tree is a popular machine learning algorithm that learns from input data and uses tree-like structure to make decisions or predictions. In a decision tree each internal node represents a combination feature values and each branch corresponds to a possible value or outcome. Decision trees are commonly used for classification tasks and provide interpretability and ease of understanding due to its graphical representation (Breiman *et al.*, 1984). The dataset composed of feeder data (7 variables at individual scale) and automatic video analysis data (6 variables at group scale) was randomly split into a training dataset (70 % of the original dataset) and a test dataset (30 %), with care taken to ensure that there were a sufficient number of observations for each cluster (Table 5-2).. The hyperparameter chosen for the maximum depth of the tree was 3 (among 1 to 5), due to their optimal performance on the training dataset (Pedregosa *et al.*, 2011). The decision tree was created with the feeder data (7 variables at individual scale) and the automatic video analysis (6 variables at group scale).

vi. Statistical analyses and implementation of algorithms

The effect of factors (week, group, event) on the clusters was evaluated thanks to a Cochran's Q test, designed for paired data with more than two groups to compare. Friedman tests and post-hocs tested were used in order to assess the effects of continuous data (body weight, age, backfat thickness) on the clusters.

The threshold for statistical significance was set at $P < 0.05$ and trend-level significance between $0.05 < P < 0.10$. The implementation has been realized in Python using the scikit-learn library (version 1.2.1.) for the clustering (K-medoid) and the classification (decision tree) tasks. Statistical analyses were performed using the Python 'statsmodels', 'scipy' and 'scikit_posthocs' libraries.

5.1.3. Results

i. Behavioural patterns identified by clustering

The inertia of 3 clusters was 189.07 (better than with 5 clusters = 157.95) and the silhouette score of 0.33 (better than with 5 clusters at 0.30). The three clusters (0, 1, and 2) gathered 95, 131, and 162 observations of sows per period respectively (Table 5-2). Medoid of cluster 0 was characterised by a passive activity level (ratio_activity = -0.14), a balanced number of given interactions between positive and negative (ratio_giving = 0.08), and more negative interactions received (ratio_receiving = -0.75). Sows of cluster 0 were therefore called 'scapegoat'. Medoid of cluster 1 was characterised by a high activity level (ratio_activity = 0.07), and giving and receiving more negative interactions (ratio_giving = -0.80 ; ratio_receiving = -0.67). Sows of cluster 1 were called 'aggressive'. Medoid of cluster 2 was characterised by a passive activity level (ratio_activity = -0.18), giving more positive interactions (ratio_giving = 0.5), and receiving a balanced amount of positive and negative interactions (ratio_receiving = 0). Sows of cluster 2 were called 'gentle'.

Table 5-2: Differences of features between the three clusters. The letters a, b, and c show a significant difference for post hoc tests (NV = nutritive visit; NNV = nonnutritive visit; cat = categories; Avg = average; Nb = number).

	Cluster 0 (scapegoat)	Cluster 1 (aggressive)	Cluster 2 (gentle)	All clusters	SEM	P-value
Number of observations	95	131	162	388		
Features from manual video analysis (used for clustering)						
Index_activity	-0.14	0.13	-0.17	-0.06	0.02	0.84
Index_giving	0.08 ^a	-0.73 ^b	0.51 ^c	-0.02	0.03	< 0.001
Index_receiving	-0.72 ^a	-0.62 ^b	0.04 ^c	-0.37	0.02	< 0.001
Features from feeder data (used for decision tree)						
Nb_NV	2.48 ^a	3.11 ^b	2.39 ^a	2.66	0.05	0.02
Nb_NNV	10.40 ^a	15.40 ^b	11.10 ^a	12.40	0.51	0.008
Time_NV (in min)	90.40 ^a	105.00 ^b	80.60 ^a	91.50	3.78	0.004
Time_NNV (in min)	61.40	88.20	63.50	71.30	4.80	0.94
Avg_NNV (in min/visit)	4.94	5.90	5.35	5.44	0.30	0.79
Avg_NV (in min/visit)	37.70 ^a	34.00 ^a	33.5 ^b	34.00	1.15	0.08
Rank_cat	10.60	9.00	9.60	9.60	0.21	0.99
Features from automatic video analysis (used for decision tree)						
Side_lying (%)	51.00	50.10	50.20	50.40	0.21	0.29
Ventral_lying (%)	21.30 ^a	22.00 ^b	21.20 ^a	21.50	0.13	0.06
Standing (%)	19.20	18.60	20.40	19.50	0.12	0.49
Sitting (%)	1.13	0.93	0.93	0.98	0.02	0.10
Eating (%)	3.20 ^a	3.93 ^b	2.97 ^a	3.31	0.04	0.03
Drinking (%)	0.58	0.66	0.60	0.61	0.01	0.23

The letters a, b, c showed a significant difference for post-hocs tests. NV = nutritive visit – NNV = non nutritive visit – cat = categories.

The evolution of sows' cluster attribution in group A during the 6 periods showed differences between periods and sows (Figure 5-2). For example, one sow (the bottom line) was always classified as a 'gentle' while a majority of sows changed between 'gentle' and 'scapegoat' clusters due to the alternate of control (1, 3 and 5) and event (2, 4, 6) periods. The evolution graph also showed that sows did not stay 'aggressive' for more than two periods.




Figure 5-2: Evolution of the sows from group A between the three clusters during the six periods followed. One line between periods corresponds to one sow evolution.

ii. Interpretation of the clusters and link with welfare

There was a significant dependence between the weeks (control vs. event) and the clusters ($P < 0.01$). During the event weeks, the proportion of 'gentle' sows tended to be lower compared to control weeks (53% vs. 35%, $P = 0.07$), while the proportion of 'scapegoats' (22% vs. 26%, $P > 0.10$) and 'aggressive' sows tended to increase (25% vs. 39%, $P = 0.07$, Figure 3).

Groups A and B had a higher proportion of 'gentle' sows than groups C and D (96% and 50%, respectively, $P < 0.001$) and a lower proportion of 'aggressive' sows (49% and 75%, respectively, $P < 0.001$). While there were no differences between C and D ($P > 0.10$), there were significant differences between A and B ($P < 0.01$). Compared to group B, group A had more 'scapegoats' (4% vs. 43%) and more 'aggressive' (0% vs. 6%) and fewer 'gentle' (98% vs. 50%) sows.

There was a significant dependence between the type of event (feed competition, sound event, thermic variation, enrichment and impoverishment) and the clusters ($P = 0.02$, Figure 3). A higher proportion of 'gentle' sows were found

during the feed competition and sound events (66% and 63%) than during the other events, heat, cold & enrichment/impooverishment events ($P = 0.06$). A higher proportion of 'aggressive' sows was found during the thermic events and impoverishment (67% and 78%, $P = 0.01$) than during the other events (average 4%).




Figure 5-3: Proportions of sows in the three clusters (gentle, aggressive, scapegoat) regarding each week (control or events).

There were no effects of the body weight, backfat thickness, age of the sow or hierarchical rank ($P > 0.10$, Table 5-2) on the clusters. The health of the sows tended to be different between the clusters. Indeed, the unhealthy sows (bursitis, tail biting, vulvar lesions, lameness) were more aggressive than healthy sows (28 vs. 12 %, respectively, $P = 0.05$). This difference was particularly linked to the fact that more unhealthy sows suffered from tail biting and vulvar lesions. So, the behavioural clusters could be representative of the different states of welfare and be used for the automatic classification task.

iii. Automatic classification of welfare status

The decision tree classification results with the feeder and the automatic video analysis data had an accuracy of 80 % and 72 % (for train and test datasets respectively using the labels from the clustering step), and a F1-score of 80 % and 0.72 %. The performance results by clusters showed better results to predict 'gentle' and 'aggressive' sows (F1-score = 86 and 80 %, respectively) than

'scapegoat' (F1-score = 70 %). The decision tree classification results with the feeder data only had an accuracy of 67 and 64 % for train and test datasets respectively, and a F1-score of 61 and 56 %. The performances to predict 'scapegoat' were better with feeder data only than with feeder and automatic video analysis data together while this combination of measurements gave higher performances for 'aggressive' and 'gentle' sows (Table 5-3).

Table 5-3: Performances metrics (precision, recall, F1-score) depending of the clusters and the data used on the decision tree.

Clusters	Feeder + automatic video analysis			Feeder only		
	Precision	Recall	F1-score	Precision	Recall	F1-score
0 (scapegoat)	0.60	0.85	0.70	0.69	0.97	0.80
1 (aggressive)	0.83	0.77	0.80	0.58	0.29	0.39
2 (gentle)	0.97	0.78	0.86	0.60	0.10	0.18

The decision tree (Figure 4) showed the paths in the tree, through the various possible values of group and individual variables, to reach the class of the sow. For instance, a sow was classified as 'aggressive' by starting from the root node through the right branch of the tree to the leaf node "aggressive". It means that if the sows of the group spend more than 3.39% of their daily time eating, and if the sow did more than 3.5 non-nutritive visits per day to the feeder, and if the sows of the group spent more than 15.28% of their daily time standing, then it is classified as "aggressive".

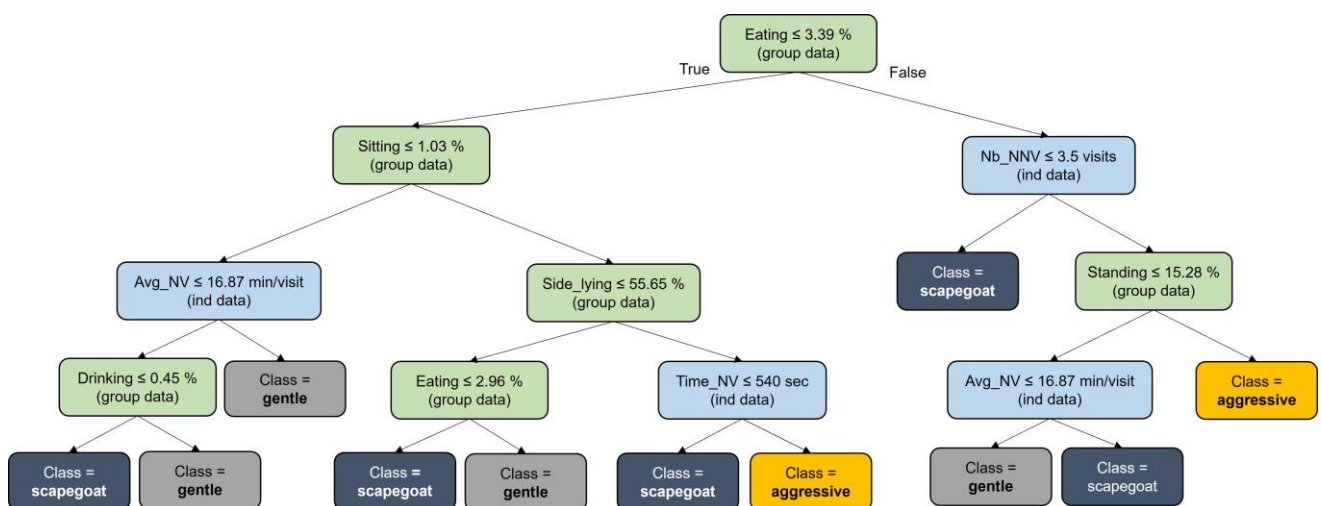


Figure 5-4: Decision Tree to predict clusters with the feeder (individual data) and automatic video analysis data (group data).

5.1.4. Discussion

The results showed that estimating the welfare status of gestating sows during a specific period may soon be possible. Using clustering in conjunction with classification on automatically recorded on-farm data opens the door to innovative research opportunities (Dawkins, 2004). The behaviour features used to build clustering (level of physical activity and social interactions) were found in literature to be linked to some components of (Gonyou, 2001; Velarde et Geers, 2007 ; Rushen *et al.*, 2012 ; McGlone *et al.*, 2013 ; Horback et Parsons, 2022). The primary concern regarding this welfare criterion was the variability in threshold definitions, which can differ based on farm conditions or groups of sows. An advantage of data mining methods (as the clustering) is that they can be readily applied to farm data owing to their unsupervised learning nature that do not require any prior knowledge or data annotation. However, one of the drawbacks of data mining for cluster interpretation is that the clusters generated may not always have straightforward and easily interpretable meanings. To validate this new and upgradeable first approach, its application on additional datasets will be necessary to improve the studied link between welfare and behavior. To establish a more robust method, it should be testing with respect to other identified welfare indicators in the literature, such as stereotypies (abnormal behaviors linked to boredom; Gonyou, 2001), which can also be measured through video analysis.

The three clusters identified in this study demonstrated a correlation with health status, particularly concerning aggressive behaviour. Animals' health status was considered as a part of welfare status (Temple *et al.*, 2018) and behavioural changes could be potential signs of illness (Matthews *et al.*, 2016). The characteristics of the sow did not significantly influence the clustering: as a result, a sow could belong to one of the three behavioral clusters depending on the studied period. This is in accordance with one welfare definition (Weary *et al.*, 2009) and showed that the clustering method may be an estimation of some components of the welfare status of an individual at a given time. However, this outcome is unexpected, considering that numerous studies have demonstrated the impact of parity on physical activity or agonistic interactions, which are variables used for the

clustering 42,43,44. However, the experimental design does not reveal any causal links but only potential correlations.

With these different proportions of sows in clusters, discrimination may be achievable not only between control and events but also among different types of events. The effect of the event on the sow's behaviour was reported in other studies. For example, the increased competition for feed resources could increase agonistic social relations and level of physical activity, inducing degradation of welfare status (Bench *et al.*, 2013). On the contrary, the enrichment of the pen decreases the agonistic social relations and improved the welfare status (Quesnel *et al.*, 2019). If these results also suggest this approach could be a method to estimate the welfare status of farms, validation on farms with varying environmental conditions must be conducted to rule out any bias in this experimental design.

Group effect on individual behaviours is also of major interest. Group behaviour could have an impact on the behaviour of all animals and may depend on the composition or size of the group (Bench *et al.*, 2013). The intensity of the event may differ based on these criteria. The difference in the proportion of 'aggressive' sows between groups A and B vs. groups C and D, during event and control periods, may suggest an important effect of the group of sows on the individual welfare status. The effect of group may be explained to the difference in events induced between groups A and B vs. groups C and D.

Predictions made using a learned decision tree on combined feeder and automatic video analysis data yielded satisfactory results (with an accuracy of over 80%). The importance of feeding behaviour and activities to determine health or welfare was also confirmed by Matthews *et al.* (2017). Due to the restricted feeding of sows, the number of non-nutritive visits and the time of eating (duration of nutritive visits) were key features to classify components of welfare. The introduction of group behavioural features (from automatic video analysis) in the decision tree model decreased the prediction performance of the 'scapegoat' compared to the feeder data only (F1 score = 60 vs. 80%). One hypothesis could be that 'aggressive' and 'gentle' classes are mainly linked to group behaviour, and

'scapegoat' class is mainly linked to individual features. This 'scapegoat' behaviour was also not significantly linked to the type of week (control/event) or health status. It would be the most difficult class to characterise and to predict, due to the lack of link with environmental conditions. On the decision tree, the importance of group behaviour on individual behaviour was also shown with the importance of group level features. Therefore, as pig is a social animal, group behavior may have an impact on the welfare of each sow (Gonyou, 2001) and is required to take it into account to predict the individual welfare status.

5.1.5. Conclusions

This study represents a significant step toward estimating the welfare status of gestating sows, particularly with the rapid advancements in the field of artificial intelligence within the realm of animal science. The approach of employing machine learning techniques, which combines an unsupervised method like clustering for data labelling with a supervised method for sensor data to learn an interpretable decision tree, yields meaningful results. However, further efforts are needed to fully interpret these clusters as "welfare estimators" and utilize them for distinguishing environmental conditions or health issues. In practice, this method could be integrated into a decision support system (DSS) to comprehensively monitor the living conditions of animals. Furthermore, the DSS can predict potential issues and alert farmers to welfare concerns, thus contributing to proactive and preventive animal welfare management.



Les résultats de ce chapitre ont montré qu'il était possible de prédire précisément l'état de bien-être individuel à l'aide de capteurs ou automates (mesurant le comportement individuel et du groupe) et de techniques de machine learning. Ce qui conforte que l'utilisation de cette méthode, alliant technique non supervisée et supervisée, est applicable sur le terrain dans différents élevages.

5.2. Expérimentation Canadienne

5.2.1. Introduction

L'utilisation de caméras se développe de plus en plus en élevage mais reste rare. Contrairement à l'expérimentation française, l'analyse du comportement (manuel ou automatique) des truies par vidéo n'était pas possible dans l'expérimentation au Canada. L'étape de clustering utilisée dans l'étude précédente ne pouvant être appliquée, un modèle expert de l'état de bien-être a été créé afin de pouvoir labeliser les données pour l'apprentissage de l'arbre de décision permettant la classification du bien-être. Les données utilisées pour cette classification supervisée portent sur les données d'automates et de capteurs : automate d'alimentation et caméra mobile thermique. L'objectif de cette étude est donc de classer les truies selon leurs niveaux de bien-être, en se basant sur des données d'automates et l'apprentissage automatique d'un arbre de décision.

5.2.2. Matériels et Méthodes

i. Dispositif expérimental

L'étude a porté sur 109 truies gestantes, croisées Large White x Landrace, issue de la maternité de recherche et de formation du CDPQ (Armagh, Québec, Canada). Elles étaient logées en groupe à partir de 35 jours de gestation, dans deux parcs (1 et 2) avec 2,45 m²/truie, sur caillebotis béton. Il y avait 19 truies de première parité et 90 de seconde parité. Les truies étaient réparties de manière aléatoire dans les deux groupes (1 et 2) et entre les cinq stratégies alimentaires (A, B, C, D et HT) décrites dans Galiot *et al.* (2023). Les stratégies A et B correspondaient à une alimentation conventionnelle, avec un bump feeding (supplémentation d'alimentation) à 90 jours de gestation pour la B. Les stratégies C et D correspondaient à l'alimentation sur mesure fondée sur l'énergie et la lysine : selon la parité (pour la C) et individuelle (pour la D). La température de la salle de gestation n'a pas été modulée dans cet essai (en moyenne à 22,1°C) et est restée dans la zone de thermoneutralité de la truie. Toutes les truies ont été vaccinées à

Clostridium perfringens en semaine 7 de mise en groupe et une deuxième dose a été administrée en semaine 9 pour les primipares.

ii. Mesures expérimentales

Quatre automates d'alimentation (Gestal, Jyga, Québec) étaient disponibles dans chacun des deux parcs de gestation. Les sept variables de comportement alimentaire ont été obtenues de la même façon que lors de l'expérimentation française : 'Nb_NNV', 'Nb_NV', 'Rank_cat', 'Time_NNV', 'Time_NV', 'Avg_NNV', 'Avg_NV' (cf. partie 1).

Les truies ont été pesées à l'aide d'une bascule (Pennsylvania Scale Company, États-Unis, précision à $\pm 0,2$ kg) lors de la mise en groupe et à 90 j de gestation. Les épaisseurs de gras et de muscle dorsaux ont été mesurées au même moment par ultrason (Alliance Medical Inc., Limerick, Irlande).

Les mesures de températures cutanées (caméra thermique Teledyne FLIR, E86, Oregon, États-Unis) étaient relevées hebdomadairement sur cinq zones corporelles non rasées : le globe oculaire, la base à l'arrière de l'oreille, le dos (au niveau de la colonne vertébrale, perpendiculairement à la dernière côte), au milieu de la vulve et entre les mamelles inguinales (Figure 5-5). Les photos étaient toujours prises à un mètre de distance. Ces mesures ont été comparées à la température rectale et la posture de la truie a été également enregistrée.




Figure 5-5 : Représentation schématique des zones où la température cutanée a été relevée par caméra thermique infrarouge (ir) : 1 : ir_oeil, 2 : ir_oreille, 3 : ir_dos, 4 : ir_vulve et 5 : ir_mamelle.

Chaque semaine, l'état corporel (y compris le nombre de lésions cutanées et l'enregistrement des problèmes de santé potentiels, tels que les bursites, les boiteries, *etc*) a été évalué à partir de la grille du Welfare Quality® programme (Dalmau *et al.*, 2009). Un indice de lésions cutanées a été calculé comme la somme pondérée des lésions cutanées en fonction de leur gravité : coefficient de 1 pour les lésions de moins de 5 cm, coefficient de 5 pour les lésions de plus de 5 cm et coefficient de 10 pour les lésions sanguinolentes ou profondes. Les lésions cutanées ont été séparées en deux catégories pour deux indices différents : l'indice de griffures (pour les lésions longues et droites) et l'indice de morsures (pour les lésions rondes). Seules les "lésions fraîches" (sans signe de cicatrisation) ont été comptabilisées, afin d'éviter de compter les anciennes lésions de la semaine précédente.

iii. Extraction et analyse des données de températures

Un ensemble de 5 733 images a été pris et analysé à l'aide du logiciel Flir Thermal Studio (Teledyne FLIR, Oregon, Etats-Unis) par le même observateur. L'émissivité de la peau, qui décrit sa capacité à émettre de l'énergie par radiation, était fixée à 0,97, comme déterminé dans l'étude de Soerensen *et al.* (2014). La température de l'air a été corrigée par celle enregistrée par les sondes au même moment. L'index THI (Temperature-Humidity Index) a été calculé à partir de l'équation suivante, déterminée par Wegner *et al.* (2016), où T est la température de l'air en °C et HR l'humidité relative de l'air en % :

$$THI = [(1,8 \times T) + 32] - \left[0,55 \times \frac{HR}{100} \right] \times [(1,8 \times T) + 32] - 58]$$

iv. Modèle expert du bien-être

Un modèle expert a été créé afin de classer les truies en trois catégories selon leur niveau de bien-être par semaine (selon des critères de santé physique), soit 938 observations. Il se base sur des variables identifiées dans la littérature (lésions corporelles et problème de santé) pour mesurer le bien-être en élevage

(Velarde et Geers, 2007) et mesurées chaque semaine lors de l'évaluation de l'état corporel. Les trois catégories suivantes ont été établies afin d'avoir un nombre significatif d'observations dans chacune d'elles :

- M3 (156 observations de truies présentant des signes de problème de bien-être ayant un **impact élevé** sur leur santé). M3 rassemble les truies qui ont été retirées de l'expérience au cours de la semaine en question (pour cause de décès ou de confinement social afin d'éviter la poursuite des agressions), avec un problème de santé déclaré ou un indice de griffure supérieur à 90 % des observations.
- M2 (211 observations de truies présentant des signes de problèmes de bien-être **sans impact élevé** sur leur santé). M2 regroupe les truies dont l'indice de griffure est compris entre 75 et 90 % et l'indice de morsures entre 75 et 90 % des observations.
- M1 (571 observations de truies ne présentant **pas de signes visibles** de problème de mal-être). M1 rassemble le reste des truies, qui ne présentent pas de griffures importantes ou de problèmes de santé décelés.

v. Analyse statistique et machine learning

La méthode d'apprentissage d'un arbre de décision utilisée pour prédire la catégorie de bien-être d'une truie pendant une semaine, ainsi que les méthodes de statistiques (tests de Cochran's Q et de Friedman) sont identiques à celles présentées dans la partie précédente 5.1. Les variables utilisées pour apprendre l'arbre de décision étaient les 7 sept variables de l'automate d'alimentation, les 5 mesures de température corporelle et le rang de portée (1 ou 2). La profondeur de l'arbre a également été fixée à 3.

5.2.3. Résultats et Discussion

i. Modèle expert

La répartition au cours du temps des trois catégories a évolué significativement selon les semaines ($P < 0.001$, Figure 5-6). Le pourcentage de M1 augmente au cours des semaines de gestation (26 % en semaine 1 contre 74 % en

semaine 10) tandis que ceux de M2 et de M3 diminuent (36 % et 38 %, respectivement contre 17 % et 9 %). Ces résultats peuvent être liés à la mise en place de la hiérarchie au sein du groupe. En effet, lors d'une mise en groupe, le nombre d'interactions agonistiques augmente fortement jusqu'à diminuer au bout de quelques jours, une fois les relations de dominance établies et stables (Campler *et al.*, 2019; Lagoda *et al.*, 2021; Jowett et Amory, 2021). Il y a également une augmentation de M3 en semaines 7 et 9 causée par la vaccination des truies, ce qui a provoqué chez certaines truies une augmentation de la température corporelle, pouvant impacter le bien-être (Temple *et al.*, 2017) La Figure 5-6 montre que certaines truies restent toujours dans la même catégorie tout au long de l'expérimentation. La proportion de M1 augmente au cours des semaines de gestation, sans doute en lien avec la stabilisation de la hiérarchie et l'absence d'évènement risquant de la déstabiliser.



Figure 5-6 : Evolution au cours du temps des catégories de bien-être (sur les truies suivies en continu soit 660 observations).

Les caractéristiques de la truie (poids, épaisseurs de lard ou de muscle dorsaux) n'ont pas influencé la répartition dans les catégories de bien-être. Les truies de rang 1 comportaient plus de M3 et moins de M1 que celles de rang 2 ($P < 0.001$). L'effet du rang de portée sur les lésions cutanées (composante du modèle expert) a été également montré par les études de Salak-Johnson (2007). Le groupe

dans lequel était la truie semble impacter le bien-être. En effet, il y avait plus de M1 dans le groupe 1 (55 vs. 66 % dans le B, $P = 0.001$). Ces résultats sont en accord avec ceux trouvés lors de l'expérimentation française, montrant l'importance du groupe sur le bien-être individuel.

La répartition des truies n'était pas la même selon le type de stratégie alimentaire ($P < 0.001$, Figure 5-7). Les stratégies A et C comportaient plus de M3 que les stratégies B et D ($P < 0.001$). Il n'y a pas de différence significative entre type conventionnel (A et B) et de précision (C et D). Ce résultat semblerait montrer que les truies nourries avec le bump feeding ou en alimentation sur mesure individuelle auraient un meilleur état de bien-être. Il est cependant à prendre avec précaution car aucune autre étude n'a montré une telle incidence de ce type d'alimentation sur le bien-être des porcs.




Figure 5-7 : Répartition des truies selon les catégories en fonction de la stratégie alimentaire.

ii. Arbre de décision pour la prédiction du bien-être

L'arbre de décision vise à prédire le bien-être des truies selon les classes établies par le modèle expert (M1, M2 et M3) en utilisant uniquement les données de l'automate d'alimentation. La précision du modèle était de 57 et 47 % pour les ensembles de données d'apprentissage et de test respectivement, ainsi qu'un score F1 de 47 et 36 %. Ces faibles performances de prédiction sont équivalentes à

celles de la partie française en utilisant les données produites par l'automate d'alimentation uniquement.

L'arbre de décision combinant les données de l'automate d'alimentation et de la caméra thermique pour prédire les groupes avait une précision de 62 et de 43 % pour les ensembles de données d'apprentissage et de test respectivement, et un score F1 de 62 et 50 %. L'arbre de décision (Figure 5-8) montre, par exemple, qu'une truie est classifiée comme en fort mal-être (niveau M3) s'il s'agit d'une première parité, avec une température infrarouge à l'oreille supérieure à 32,3 °C et un ordre de passage à l'automate inférieur ou égal à 48.




Figure 5-8 : Arbre de décision pour prédire le niveau de bien-être à l'aide de l'automate d'alimentation et la caméra thermique.

Les résultats des performances par catégorie ont montré de meilleurs résultats pour prédire les M1 (score F1 = 75 %, Tableau 5-4). Les faibles résultats pour M2 et M3 (inférieur à 50 %) semblent montrer que la combinaison de ces capteurs n'est pas adéquate pour prédire l'état de bien-être. La caméra thermique mesure un paramètre physiologique de la truie et non son comportement. L'utilisation d'une donnée physiologique est intéressante pour mettre en évidence un problème de bien-être impactant fortement la santé de l'animal, mais est sans doute moins adaptée pour une détection précoce (Matthews *et al.*, 2016). Dans l'expérimentation française, ajouter des données d'activité physique du groupe a permis d'améliorer les performances de 19 %. Des données comportementales à

l'échelle du groupe combinées aux données individuelles produites par les automates d'alimentation permettrait d'améliorer les performances de prédiction. Cette hypothèse est renforcée par l'influence du groupe sur les répartitions des truies entre les trois niveaux de bien-être.

Tableau 5-4 : Métriques de performances (precision, recall, f1-score) selon les catégories de bien-être et les données utilisées pour l'arbre de décision.

Catégories de bien-être	Automate d'alimentation et caméra thermique			Automate d'alimentation		
	Precision	Recall	F1-score	Precision	Recall	F1-score
M1	0.66	0.87	0.75	0.54	0.99	0.70
M2	0.41	0.31	0.35	0.75	0.11	0.20
M3	0.80	0.19	0.31	0.99	0.17	0.29

5.2.4. Conclusion

Les résultats de cette expérimentation canadienne montrent qu'il est difficile d'estimer de manière non invasive l'état de bien-être grâce à une méthode de machine learning (un arbre de décision) et des données produites par un automate d'alimentation et un autre capteur (ici une caméra thermique). Ces deux capteurs combinés sont à l'échelle individuelle et montrent des limites de performances pour prédire l'état de bien-être. En effet, les résultats ont également montré l'importance du groupe sur le comportement individuel des truies. Afin d'améliorer la prédiction, un capteur mesurant l'activité générale du groupe devrait être ajouté, comme lors de l'expérimentation française qui montraient de meilleurs résultats. Parmi les caractéristiques de la truie, uniquement sa parité a influencé l'état de bien-être. L'état de bien-être d'une truie évolue également au cours du temps, tout comme lors de l'expérimentation française, montrant l'importance de le mesurer en continu.



Les résultats de ce chapitre ont montré qu'il était difficile de prédire l'état de bien-être individuel à l'aide de capteurs ou automates (mesurant uniquement le comportement et la physiologie au niveau individuel) et de techniques de machine learning. Cette étude dans un autre élevage montre l'importance du choix des capteurs pour la précision de cette nouvelle méthode.

5.3. Références bibliographiques

Abarnou J., Durand M., Dourmad J.Y., Gaillard C., 2022 Effects of thermal conditions on gestating sows' behaviors and energy requirements. *J. Anim. Sci.*, 101, p.1-13.

Anses, 2018. Avis de l'Agence nationale de sécurité sanitaire de l'alimentation, de l'environnement et du travail. Saisine n° « 2016-SA-0288 ». Bien-être animal : contexte, définition et évaluation. 34p

Bartussek H., 1999. A review of the animal needs index (ANI) for the assessment of animals' well-being in the housing systems for Austrian proprietary products and legislation. *Livest. Prod. Sci.* 61, p.179-192.

Bench C.J., Rioja-Lang F.C., Hayne S.M., Gonyou H.W., 2013 Group gestation sow housing with individual feeding – II: How space allowance, group size and composition, and flooring affect sow welfare. *Livest. Sci.*, 152, p.218-227.

Bjerg B., Brandt P., Pedersen P., Zhang G.Q., 2020. Sows' responses to increased heat load - A review. *J. Thermal Biol.*, 94, 102758.

Boissy A., Manteuffel G., Jensen M.B., Moe R.O., Spruijt B., Keeling L.J., Winckler C., Forkman B., Dimitrov I., Langbein J., Bakken M., Veissier I., Aubert, A., 2007. Assessment of positive emotions in animals to improve their welfare. *Physiol. Behav.*, 92, p.375-397.

Bracke M.B.M., Edwards S.A., Metz J.H.M., Noordhuizen J.P.T.M., Algers B., 2008. Synthesis of semantic modelling and risk analysis methodology applied to animal welfare. *Animal*, 2, p.1061-1072.

Brajon S., Ahloy-Dallaire J., Devillers N., Guay F., 2021. Social status and previous experience in the group as predictors of welfare of sows housed in large semi-static groups. *PLoS ONE*, 16, 6.

Breiman L., Friedman J., Olshen R., Stone C., 1984. Classification and Regression Trees. Wadsworth, Belmont, Etats-Unis.

Campler M., Pairis-Garcia M., Kieffer J., Moeller S., 2019. Sow behavior and productivity in a small stable group-housing system. *J. Swine Health Prod.*, 27, p.7-86.

Chapinal N., de la Torre J.L.R., Cerisuelo A., Gasa J., Baucells M.D., Coma J., Vidal A., Manteca X., 2010. Evaluation of welfare and productivity in pregnant sows kept in stalls or in 2 different group housing systems. *J. Vet. Behav.-Clin. Appl. Res.*, 5, p.82-93.

Dalmau A., Velarde A., Scott K., Edwards S., Butterworth A., Veissier I., Keeling L., Overbeke G., Bedaux, V., 2009. Welfare Quality® Assessment for Pigs (Sows and Piglets, Growing and Finishing Pigs). Welfare Quality® Consortium, Lelystad, The Netherlands.

Dawkins M., 2004. Using behaviour to assess animal welfare. *Anim. Welf.*, 13, p.3-7.

Estimation de l'état de bien-être des truies à partir de méthodes de machine learning

- Douglas C., Bateson M., Walsh C., Bedue A., Edwards S.A., 2012. Environmental enrichment induces optimistic cognitive biases in pigs. *Appl. Anim. Behav. Sci.*, 139, p.65-73.
- Dourmad J.Y., Etienne M., Valancogne A., Dubois S., van Milgen J., Noblet J., 2008. InraPorc: A model and decision support tool for the nutrition of sows. *Anim. Feed Sci. Technol.*, 143, p.372-386.
- Durand M., Simon M., Foisil J., Dourmad J.Y., Largouët C., Gaillard C., 2022. Evaluation of the physical activity of a group of gestating sows using an artificial neural network. In : EAAP scientific committee (Ed.), Book of abstracts, EAAP – 73rd Annual Meeting, Wageningen Academic Publishers, The Netherlands, p.455.
- Durand M., Dourmad J.Y., Julienne A., Couasnon M., Gaillard, C., 2023a. Effects of a competitive feeding situation on the behaviour and energy requirements of gestating sows. *Appl. Anim. Behav. Sci.*, 261, 105884.
- Durand M., Largouët C., Bonneau de Beaufort L., Dourmad J.Y., Gaillard C., 2023b. A dataset to study group-housed sows' individual behaviours and production responses to different short-term events. *Animal – open space*, 2, 100039.
- Gaillard C., Gauthier R., Cloutier L., Dourmad J.Y., 2019 Exploration of individual variability to better predict the nutrient requirements of gestating sows. *J. Anim. Sci.*, 97, p.4934-4945.
- Gaillard C., Deroiné C., Misrach M., Durand M., 2023. Effects over time of different types of sounds on gestating sows' behaviour. *Appl. Anim. Behav. Sci.*, 266, 106012.
- Galiot L., Cloutier L., Guay F., Dumas G., Gaillard C., Dourmad J.Y., Simongiovanni, A., Gagnon P., 2023. Impact de l'alimentation de précision et d'un surplus d'aliment en fin de gestation sur les performances et l'état corporel de truies suivies pendant leurs deux premiers cycles de gestation et lactation. In : JRP (Ed.), Proceedings Journées Rech. Porcine, 55, p.183-188.
- Gauthier R., Largouët C., Rozé L., Dourmad J.Y., 2021. Online forecasting of daily feed intake in lactating sows supported by offline time-series clustering, for precision livestock farming. *Comput. Electron. Agric.*, 188, 106329.
- Gonyou H.W., 2001. The social behaviour of pigs. In : L.J. Keeling & H.W. Gonyou (Eds.), Social Behaviour in Farm Animals, CAB International, Wallingford, Royaume-Uni, p.147-168.
- He Y., Tiezzi F., Howard J., Maltecca C., 2021. Predicting body weight in growing pigs from feeding behavior data using machine learning algorithms. *Comput. Electron. Agric.*, 184, 106085.
- Horback K.M., Parsons T.D., 2022. Judgement bias of group housed gestating sows predicted by behavioral traits, but not physical measures of welfare. *PLoS ONE*, 17, e0264258.
- Jowett S., Amory J., 2021. The stability of social prominence and influence in a dynamic sow herd: A social network analysis approach. *Appl. Anim. Behav. Sci.*, 238, 105320.

Estimation de l'état de bien-être des truies à partir de méthodes de machine learning

Kavlak A.T., Pastell M., Uimari P., 2023. Disease detection in pigs based on feeding behaviour traits using machine learning. *Biosyst. Eng.*, 226, p.132-143.

Kremer L., Holkenborg S.E.J.K., Reimert I., Bolhuis J.E., Webb L.E., 2020. The nuts and bolts of animal emotion. *Neurosci. Biobehav. Rev.*, 113, p.273-286.

Lagoda M.E., Boyle L.A., Marchewka J., Calderon D.J.A., 2021. Mixing aggression intensity is associated with age at first service and floor type during gestation, with implications for sow reproductive performance. *Animal*, 15, 100158.

Lanthony M., Danglot M., Spinka M., Tallet C., 2022. Dominance hierarchy in groups of pregnant sows: characteristics and identification of related indicators. *Appl. Anim. Behav. Sci.*, 254, 105683.

Llonch P., Neethirajan S., Morgan-Davies C., 2022. Editorial: Understanding animals' phenotype through automatic behavior assessment. *Front. Anim. Sci.*, 3, 1069387.

Matthews S.G., Miller A.L., Clapp J., Plötz T., Kyriazakis I., 2016. Early detection of health and welfare compromises through automated detection of behavioural changes in pigs. *Vet. J.*, 217, p.43-51.

Matthews S.G., Miller A.L., Plötz T., Kyriazakis I., 2017. Automated tracking to measure behavioural changes in pigs for health and welfare monitoring. *Sci. rep.*, 7, 17582.

McGlone J.J., 2013. Review: updated scientific evidence on the welfare of gestating sows kept in different housing systems. *Prof. Anim. Sci.*, 29, p.189-198.

Mormède P., Boisseau-Sowinski L., Chiron J., Diederich C., Eddison J., Guichet J.L., Le Neindre P., Meunier-Salaün M.C., 2018. Animal welfare: context, definition, evaluation. *INRA Prod. Anim.*, 31, p.145-162.

Neethirajan S., 2020. Transforming the Adaptation Physiology of Farm Animals through Sensors. *Animals*, 10, 1512.

Ollagnier C., Kasper C., Wallenbeck A., Keeling L., Bee G., Bigdeli S.A., 2023. Machine learning algorithms can predict tail biting outbreaks in pigs using feeding behaviour records. *PLoS ONE*, 18, e0252002.

Otten W., Kanitz E., Puppe B., Tuchscherer M., Brüssow K.P., Nürnberg G., Stabenow B., 2004. Acute and long-term effects of chronic intermittent noise stress on hypothalamic-pituitary-adrenocortical and sympatho-adrenomedullary axis in pigs. *Anim. Sci.*, 78, p.271-283.

Parks H.S., Jun C.H., 2009. A simple and fast algorithm for K-medoids clustering. *Expert Syst. Appl.*, 36, p.3336-3341.

Pedregosa F., Varoquaux G., Gramfort A., Michel V., Thirion B., Grisel O., Blondel M., Prettenhofer P., Weiss R., Dubourg V., Vanderplas J., Passos A., Cournapeau D., Brucher M., Perrot M., Duchesnay E., 2011. Scikit-learn : Machine Learning in Python. *J. Machine Learn. Res.*, 12, p.2825-2830.

Estimation de l'état de bien-être des truies à partir de méthodes de machine learning

- Peikari M., Salama S., Nofech-Mozes S., Martel, A.L., 2018. A Cluster-then-label Semi-supervised Learning Approach for Pathology Image Classification. *Sci. Rep.*, 8, 7193.
- Pierdon M.K., Parsons T.D., 2018. Effect of familiarity and mixing method on gestating sow welfare and productivity in large dynamic groups. *J. Anim. Sci.*, 96, p.5024–5034.
- Quesnel H., Peuteman B., Père M.C., Louveau I., Lefaucheur L., Perruchot M.H., Prunier A., Meunier-Salaün M.C., Gardan-Salmon D., Gondret F., Merlot E., 2019. Effect of environmental enrichment with wood materials and straw pellets on the metabolic status of sows during gestation. *Livest. Sci.*, 229, p.43-48.
- Reimert I., Webb L.E., van Marwijk M.A., Bolhuis J.E., 2023. Review: Towards an integrated concept of animal welfare. *Animal*, 17, 100838.
- Rushen J., Chapinal N., de Passilé A.M., 2012. Automated monitoring of behavioural-based animal welfare indicators. *Anim. Welf.*, 21, p.339-350.
- Rutherford K.M.D., Donald R.D., Lawrence A.B., Wemelsfelder F., 2012. Qualitative Behavioural Assessment of emotionality in pigs. *Appl. Anim. Behav. Sci.*, 139, p.218-224.
- Salak-Johnson J.L., Niekamp S.R., Rodriguez-Zas S.L., Ellis M., Curtis S.E., 2007. Space allowance for dry, pregnant sows in pens: Body condition, skin lesions, and performance. *J. Anim. Sci.*, 85, p.1758-1769.
- Soerensen D.D., Clausen S., Mercer J.B., Pedersen L.J., 2014. Determining the emissivity of pig skin for accurate infrared thermography. *Comput. Electron. Agric.*, 109, p.52-58.
- Temple D., Escribano D., Jiménez M., Mainau E., Ceron J.J., Manteca X., 2017. Effect of the needle-free "intra dermal application of liquids" vaccination on the welfare of pregnant sows. *Porcine Health Management*, 3, 9.
- Temple D., Llonch P., Mainau E., Manteca X., 2018. On-farm and post-mortem health assessment. In *Advances in pig welfare*, Woodhead Publishing Series in Food Science, Technology and Nutrition, Royaume-Uni, p.357-379.
- Veissier I., Boissy A., Désiré L., Greiveldinger L., 2009. Animals' emotions: studies in sheep using appraisal theories. *Anim. Welf.*, 18, p.347-354.
- Velarde A., Geers R., 2007. On farm monitoring of pig welfare. Wageningen Academic publishers, Pays-Bas, 209p.
- Verdon M., Morrison R.S., Rice M., Hemsworth P.H., 2016. Individual variation in sow aggressive behaviour and its relationship with sow welfare. *J. Anim. Sci.*, 94, p.1203–1214.

Estimation de l'état de bien-être des truies à partir de méthodes de machine learning

Wallenbeck A., Keeling L.J., 2013. Using data from electronic feeders on visit frequency and feed consumption to indicate tail biting outbreaks in commercial pig production. *J. Anim. Sci.*, 91, p.2879-2884.

Wathes C.M., Kristensen H.H., Aerts J.M., Berckmans D., 2008. Is precision livestock farming an engineer's daydream or nightmare, an animal's friend or foe, and a farmer's panacea or pitfall? *Comput. Electron. Agr.*, 64, p.2-10.

Weary D., Huzzey J., Von Keyserlingk M., 2009. Using behaviour to predict and identify ill health in animals. *J. Anim. Sci.*, 87, p.770-777.

6. Discussion générale

Les résultats obtenus au cours des essais expérimentaux rapportés au chapitre 3 (1^{er} objectif de la thèse) ont montré que les différentes perturbations environnementales (compétition alimentaire, variations des conditions thermiques, émission aléatoire de sons, enrichissement et appauvrissement) ont impacté différemment le comportement : d'alimentation, d'abreuvement, social, et l'activité physique. Ces changements comportementaux, modifiant également les besoins nutritionnels des truies gestantes, ont pu être quantifiés à l'échelle individuelle grâce aux différents capteurs et automates. Les résultats rapportés aux chapitres 4 et 5 ont ainsi mis en évidence que l'utilisation des données produites par les capteurs et les automates mesurant le comportement, en combinaison avec des méthodes de machine learning, permettent d'estimer efficacement et précisément de manière non invasive les besoins nutritionnels individuels journaliers (objectif 2) avec une erreur absolue inférieure à 5 %, et des composantes de l'état de bien-être des truies gestantes (objectif 3) avec une précision de 80 %. Les performances de ces prédictions sont différentes selon les combinaisons de capteurs et les algorithmes utilisés. Cette thèse montre ainsi que l'utilisation de données comportementales et environnementales permet d'améliorer de manière originale et novatrice, l'alimentation sur mesure et l'estimation de l'état de bien-être. Elle permet également d'imaginer la conception d'un outil d'aide à la décision et d'actions correctrices intégrées pour l'alimentation et le bien-être des truies gestantes.

6.1. Originalité de la démarche basée sur les nouvelles technologies

6.1.1. Un ensemble de données performant

Diversité des capteurs. L'utilisation de capteurs sur les animaux ou dans leur environnement de vie augmente en élevage. Avec la baisse de leurs coûts et l'augmentation de leurs performances, l'accroissement de leur usage provient de la diversité de mesures acquises et les nombreux champs d'applications possibles. Dans la thèse, l'utilisation combinée de capteurs a permis d'obtenir des données à différentes échelles (individuelle, groupe, élevage) et décrivant différents aspects du comportement de la truie : social, alimentaire, *etc.* L'idée de s'appuyer sur l'ensemble de ces données a permis, au-delà de leur utilisation première (piloter l'alimentation, l'abreuvement, *etc.*), d'en développer deux nouvelles : la prédiction des besoins nutritionnels et la prédiction de l'état de bien-être de l'animal. Le principal défi relevé par la thèse était de repérer les informations importantes dans cet amas de données. En effet, les capteurs ont enregistré des données avec des pas de temps différents (5 ou 30 minutes, voire une heure). Un premier enjeu était donc de fixer l'échelle temporelle. Le choix a été fait d'un pas de temps journalier pour toutes les variables, suffisant pour décrire la variabilité du comportement des truies. Par exemple, si le nombre de visites avec consommation d'aliment à l'automate variait rarement d'une journée à l'autre, le temps passé cumulé à la journée de ces visites présentait une variation individuelle intéressante pour la prédiction des besoins nutritionnels ou de l'état de bien-être. Cette étape d'identification des variables d'intérêt pour répondre aux objectifs de la thèse a représenté une part non négligeable du temps de celle-ci et a participé à la précision des méthodes de prédiction développées.

Vision par ordinateur. Parmi les capteurs possibles, la caméra, avec différents logiciels d'analyse de vidéo, peut avoir plusieurs applications : évaluation du comportement social ou alimentaire, de l'activité physique, de l'état de santé, *etc.* Cependant, actuellement, la majorité des solutions opérationnelles sont essentiellement disponibles à l'échelle du groupe. Les technologies basées sur

des analyses vidéo sont privilégiées dans les recherches récentes et dans cette thèse, notamment pour leur non-invasivité et leur fiabilité. C'est pourquoi, elles sont en plein développement et tendent de plus en plus vers une analyse à l'échelle individuelle (Chen *et al.*, 2021). Par exemple, l'approche développée dans le chapitre 4 en collaboration avec la start-up DILEPIX permet déjà de déterminer la position des truies (debout, couché, assise...) et leur localisation dans la case sans pour le moment les identifier. Les travaux en cours devraient permettre un suivi en temps réel de chaque truie (dit tracking), *via* une identification individuelle pour fin d'année 2024 (dans le cadre du projet CASDAR SOMOVE). La reconnaissance et l'identification individuelle des animaux à partir d'images, sont généralement réalisées selon deux stratégies principales : la reconnaissance du marquage sur le dos de l'animal (Chen *et al.*, 2020), ou de signes distinctifs, comme la reconnaissance faciale de l'individu (Marsot *et al.*, 2020). Ces deux stratégies n'ont pas été retenues dans ce projet SOMOVE. Il s'agira de relier les données d'identification produites par les automates lisant les identifications par RFID (automates d'alimentation et d'abreuvement) à l'image et la posture enregistrée par les caméras comme cela a été fait notamment chez la vache laitière (Lardy *et al.*, 2023).

Capteurs et bien-être. L'utilisation d'une caméra positionnée au-dessus de la case et d'une boucle RFID associée à une antenne disposée sur un automate d'alimentation et/ou d'abreuvement apparaît donc prometteuse pour suivre le comportement de chaque truie. Au cours de la thèse, compte tenu des objectifs de recherche et de la disponibilité des technologies, plusieurs capteurs ont été fixés sur les oreilles des truies afin d'acquérir les données nécessaires au développement des algorithmes de machine learning (chapitre 3). Il s'agissait de deux boucles RFID (pour l'alimentation et l'abreuvement), d'une boucle pour l'identification réglementaire, ainsi qu'un accéléromètre. La multitude de ces perçages pourrait sur le long terme induire des infections aux oreilles et dégrader le bien-être animal. Cela représente également un coût pour l'éleveur : coût des boucles et de leur remplacement (en cas de perte ou de destruction), temps de pose à répéter pour chaque truie. Une étude de Hayer *et al.* (2022) a d'ailleurs mis

en évidence la conséquence du perçage des oreilles pour les boucles d'identification chez le veau sur la réduction du bien-être (en lien avec des problèmes de santé). La réduction du nombre de capteurs placés sur l'animal est ainsi à privilégier dans le futur. On peut également imaginer un capteur unique permettant l'identification de l'animal (traçabilité réglementaire) et sa reconnaissance par tous les automates et capteurs (avec le même niveau d'onde RFID).

Capteurs et investissement. Les deux études de prédiction des besoins et de l'état de bien-être ont montré que tous les capteurs et automates n'avaient pas la même capacité de prédiction (chapitres 4 et 5). Les automates d'alimentation ont ainsi montré leur supériorité pour la prédiction tant des besoins nutritionnels que du bien-être. Les résultats obtenus ont également mis en évidence que combiner les données d'alimentation avec un autre capteur permet d'améliorer les performances et la précision de prédiction. Cependant, en augmentant le nombre de capteurs il y a un risque d'accroître l'investissement et le coût de fonctionnement de la solution envisagée. Il faut donc que les bénéfices liés à l'utilisation de ces capteurs compensent, en partie, le coût de l'investissement de ceux-ci. Par exemple, le prix estimé de la rénovation d'une place de truie en gestation en groupe avec un distributeur automatique d'aliment en système autobloquant est situé entre \$ 147-286 dollars canadiens (Turcotte *et al.*, 2015), ce qui représente environ 100-196 €. A raison d'une réduction du coût alimentaire de 3,4 € par gestation via l'utilisation d'une stratégie d'alimentation sur mesure fondée sur l'ajustement en énergie et lysine (Gaillard *et al.*, 2020), le retour sur investissement se situe entre 9 et 18 ans (Figure 6-1). Mais ce calcul ne tient pas compte des coûts de main d'œuvre, ni des effets positifs sur l'environnement ou le bien-être animal qui sont plus difficiles à évaluer. On estime ainsi qu'un problème de santé, tel que les boiteries, coûte entre 145 et 180 € par truie selon la sévérité, en tenant compte du traitement et des conséquences économiques (Le Floc'h *et al.*, 2021). Un système permettant également de détecter plus précocement des problèmes de mal-être, ou des maladies, permettrait alors de réduire le temps de retour sur investissement d'un automate d'alimentation servant à la fois pour la

nutrition et le bien-être. En effet, avec une incidence de 8 % des boiteries (comme lors des expérimentations de la thèse), le retour sur investissement est de 3 à 6 ans (Figure 6-1). Avec un investissement de 10 ans et une stratégie liant alimentation et bien-être, l'éleveur peut ainsi espérer un gain économique entre 4,9 et 12,8 € par truie présente et par an. Or, le gain d'un porc produit supplémentaire au niveau d'un élevage est équivalent à un gain économique de 50 € par truie présente par an. Pour ce type d'élevage, le gain de cette stratégie peut être équivalente à un gain de productivité entre 0,10 et 0,26 porcs produits par an (correspondant à l'amélioration annuelle de productivité des élevages, en raison du progrès génétique). Ainsi, le travail de cette thèse liant à la fois nutrition et bien-être semble prometteuse et avoir un avantage économique.




Figure 6-1 : Schéma d'un retour sur investissement de la démarche de la thèse pour un élevage type.

6.1.2. Comprendre les méthodes de fouille de données et de machine learning pour mieux les utiliser

Compréhension des algorithmes. Les techniques de fouille de données hétérogènes (images, chiffrées, *etc.*) et de machine learning offrent une multitude de possibilités de production de connaissances et d'applications. Elles étaient idéales au cours de la thèse pour analyser la quantité importante de données générées par les capteurs. Cependant, surnommées « boîtes noires », elles restent peu acceptées par une partie de la population, qui les juge peu interprétables (Bellon-Maurel *et al.*, 2022). Généralement, l'éleveur ne cherche pas à comprendre dans le détail le fonctionnement des modèles implémentés dans les équipements d'élevage. Il désire plutôt comprendre comment fonctionne globalement le système, ainsi que les bénéfices et les possibilités offertes par le logiciel (Thomas *et al.*, 2023). De plus, parmi les algorithmes existants, certains possèdent des règles de décisions compréhensibles pour les utilisateurs. Il s'agit, par exemple, des algorithmes basés sur des arbres de décisions, choix qui a été fait dans ce travail et reporté dans les chapitres 4 et 5. Dans ce cas, on peut expliquer à l'éleveur les principales règles (ou variables) qui conduisent au résultat obtenu par l'algorithme. Par exemple, comme décrit au chapitre 5, on peut expliquer qu'une truie est classée comme agressive car son nombre de visites à l'automate d'alimentation est supérieur à un seuil qui a été calculé au sein de son exploitation. Ainsi, l'utilisation des méthodes développées dans cette thèse permettent d'améliorer la compréhension et donc l'adoption des techniques de prédiction des besoins nutritionnels ou de l'état de bien-être.

Stockage des données. Dans les phases de développement ou de déploiement, un stockage des données est nécessaire et pose problème dans le contexte actuel de durabilité des modes de productions agricoles. Les jeux de données utilisées sont souvent conséquents et leur stockage peut être couteux. Au cours de la thèse, le suivi en continu de deux bandes de truies sur deux gestations a nécessité le stockage de plus de 8 téra-octets de données de vidéos et de capteurs. Pour un éleveur ayant des salles plus grandes nécessitant plus de

caméras, beaucoup plus de bandes de truies à suivre, et sur plusieurs années, le stockage des données serait bien plus important. Un serveur de stockage peut coûter entre 150 et 16 000 € selon le modèle et ses paramètres (capacité, puissance, *etc.*). Ce surcoût peut être intégré dans les abonnements avec l'entreprise qui distribue la solution logicielle ou des sociétés d'hébergement de serveurs (de type OVHcloud) qui assurent la sécurité, la confidentialité et la sauvegarde des données et offrent des capacités de calcul. Ce stockage peut être diminué en limitant le nombre de données transmises au serveur cloud (de l'entreprise) afin de limiter les dépenses énergétiques (Doulgerakis *et al.*, 2019). Toutefois cette problématique de stockage et de mise œuvre de flux de données importants, se pose principalement lors du développement et de la mise-à-jour des algorithmes (off line), ou lors d'un traitement a posteriori comme dans la thèse. L'utilisation en temps réel des algorithmes (on-line) permet de ne garder la vidéo (par exemple) que lors de l'analyse de celle-ci et de seulement stocker par la suite le résultat de l'analyse. Cependant, si la phase d'analyse est très rapide, elle peut nécessiter des capacités de calcul importantes, en particulier pour les images.

Temps d'analyse des données. La question du temps de calcul est ainsi également à prendre en compte dans le choix et la définition des conditions d'utilisation des algorithmes. Dans notre étude, les temps de calculs allaient de quelques secondes à une dizaine de minutes, selon le type et la précision de l'algorithme utilisé. Ce temps est ainsi relativement rapide et est en accord avec les contraintes de temps de réponse nécessaire pour une exploitation agricole et les délais d'intervention. Cependant, certains de ces algorithmes, comme le Gradient Tree Boosting ou le Support Vector Machine étaient demandeurs de beaucoup de ressources pour fonctionner (un ordinateur performant ou un serveur via le cloud), ce qui peut limiter leur utilisation en ferme commerciale. De plus, les algorithmes d'analyse d'images, comme les réseaux de neurones convolutifs (utilisés dans le chapitre 4), sont très consommateurs de ressources (données et puissance informatique) et en temps de calcul (Kamilaris et Prenafeta-Boldu, 2018 ; Li *et al.*, 2021). Ainsi, la question du temps réel se pose. Il faut ainsi trouver un compromis entre la fréquence d'analyse d'images (pour limiter l'utilisation des

ressources et donc le coût de calcul si on passe par un fournisseur de service), le temps de calcul de l'algorithme (en lien avec sa précision) et la précision de détection du comportement.

Nécessité d'une combinaison des données. Les différents résultats (obtenus dans les chapitres 4 et 5) ont montré que la combinaison de données variées issues de capteurs ensuite traitées par des algorithmes de machine learning est une voie intéressante et novatrice. Pour cela, il est nécessaire de pouvoir intégrer toutes les données pertinentes issues des différents capteurs disponibles dans l'élevage, afin de développer un logiciel unique permettant la prédiction des besoins alimentaires et du bien-être (à l'aide des algorithmes de ML). Dans la thèse, l'utilisation d'une base de données relationnelle était idéale et a facilité l'approche de machine learning a posteriori. Pour une approche en temps réel, il faudrait disposer d'outils capables de rassembler les données des différents capteurs existants sur le marché (souvent n'étant pas fabriqués par la même entreprise) dans une même base de données. Il peut s'agir de plusieurs plateformes avec des interfaces graphiques différentes et de divers types de fichiers de sortie (CSV, texte, JSON) et même de systèmes d'identification de l'animal sur des niveaux d'ondes RFID différentes. Un projet de recherche de l'université de Copenhague (IQinAbox) s'intéresse ainsi à la création d'un cloud unique regroupant des sorties de capteurs divers qui sont utilisés dans des modèles développés par des chercheurs (par exemple sur le gain de poids des porcs charcutiers) et qui aboutissent à une seule et unique interface pour les éleveurs et autres intervenants comme les abattoirs (Norton, 2023).

L'objectif (atteint) de la thèse était principalement d'évaluer la possibilité d'utiliser, à partir d'une base de données expérimentale, des algorithmes de machine learning associant la prédiction des besoins nutritionnels et de certaines composantes du bien-être. Il était nécessaire d'étudier l'ensemble des données pertinentes qui pouvaient être combinées assurant de bonnes performances pour ces prédictions. Si la combinaison de capteurs semble intéressante pour améliorer la précision de ces méthodes, l'utilisation de deux capteurs semble suffisante et adaptée à une utilisation sur le terrain. La mise en œuvre en temps réel de ces

algorithmes sur de nouvelles bandes de truies constitue la prochaine étape pour une validation temps réel des modules de prédiction développés.

6.2. Vers la conception d'un outil d'aide à la décision et d'actions correctrices intégrées pour l'alimentation et le bien-être

6.2.1. Ajustement de la prédiction des besoins nutritionnels

Détermination des besoins nutritionnels. Les bonnes performances de prédiction pour la lysine digestible et l'énergie métabolisable avec des algorithmes basés sur des arbres de décision (Random Forest et Gradient Tree boosting) et les données d'alimentation (MAPE < 1 % et $R^2 = 99$ %, Chapitre 4) incitent à tester cette méthode sur d'autres nutriments. C'est d'ailleurs le cas de l'étude de Basak *et al.* (2023), qui s'intéresse à prédire les besoins hydriques des porcs en croissance à l'aide de méthode de machine learning et de divers capteurs (balance connectée, automate d'alimentation, thermomètre d'ambiance, *etc.*). Ils montrent également que des algorithmes basés sur des arbres de décision (avec l'algorithme Random Forest) permettent des prédictions avec une précision de 80 %, contrairement à des modélisations linéaires. Contrairement à l'approche abordée dans cette thèse, Basak *et al.* (2023) ont utilisé toutes les données de capteurs sans différencier les capacités de prédiction de chacun d'entre eux. Cette limite peut freiner une utilisation sur le terrain avec une multitudes de capteurs coûteux. La contribution de cette thèse a permis de prédire de manière précise et individualisée les besoins nutritionnels journaliers des truies pour une application simplifiée de l'alimentation sur mesure avec un nombre limité de capteurs. L'utilisation combinée uniquement de deux capteurs permet ainsi de prédire les besoins à la place d'un modèle mécaniste complexe qui utilise l'estimation des performances reproductives et de production (à partir de données historiques de l'élevage). L'idée n'était pas de complexifier la prédiction en utilisant de nombreux capteurs mais de proposer une solution pouvant aisément être mise en pratique dans un cadre opérationnel à moyens raisonnés.

Prédiction d'autres nutriments. L'utilisation des capteurs et automates avec des algorithmes de ML, comme dans le chapitre 4, a montré des performances de prédiction équivalente, voire légèrement dégradées, pour le phosphore digestible, avec une erreur de prédiction minimale de 4 % (Figure 6-2). Plusieurs hypothèses peuvent être avancées pour expliquer cette légère baisse des performances. Les attributs issus des capteurs testés dans la thèse sont pertinents pour la lysine et l'énergie mais peut-être pas pour d'autres éléments. Par exemple, le temps entre deux visites alimentaires ou non alimentaires pourrait être étudié pour la prédiction d'autres nutriments. Une autre hypothèse est que le modèle nutritionnel mécaniste n'est pas assez précis sur la prédiction de certains éléments comme le phosphore et nécessite d'être amélioré. Ce travail fait d'ailleurs actuellement l'objet d'une thèse au sein de l'unité de recherche PEGASE de INRAE, dont le premier objectif est d'affiner les équations de prédiction des besoins en phosphore au cours de gestations consécutives. Il y a ainsi encore des recherches à faire avant d'étendre l'utilisation de cette nouvelle méthode prometteuse de prédiction à l'ensemble des nutriments nécessaire à la truie gestante.




Figure 6-2 : MAPE de prédiction du Phosphore digestible par les différentes techniques de ML selon les capteurs (avec les données sur les caractéristiques des truies).

Gamme et diversité d'activité physique. Les résultats permettent de prendre en compte l'influence de l'activité physique sur les besoins nutritionnels, de manière simple sur la base des données collectées par le dispositif d'alimentation et d'analyse vidéo automatique. Ceci constitue un progrès par rapport au modèle nutritionnel actuel qui ne prend pas en compte la variabilité de l'activité physique mais la moyenne à l'échelle du groupe. Comme présenté précédemment, les performances de la méthode dépendent du modèle nutritionnel mécaniste sur lequel est basé l'apprentissage. Le modèle développé par *Dourmad et al.* (2008) puis modifié par *Gaillard et al.* (2019) applique un coefficient de prise en compte de l'activité physique uniquement sur le temps debout. Il ne fait pas la différence entre temps debout immobile ou en mouvement, mais également il ne prend pas en compte le nombre de changements de position. Or, ces différentes positions se distinguent en termes de consommation d'énergie (*Labuissière et al.*, 2022). En effet, la production de chaleur est augmentée de 54 % entre couché et debout. Elle est également multipliée par deux entre la position « debout immobile » et « debout en mouvement » (pour une vitesse inférieure à 1,5 km/h) (*Labuissière, NP*). Si l'on applique ces coefficients dans le calcul des besoins lors de la première expérimentation (compétition alimentaire et émissions sonores), on peut voir que les besoins ont été largement sous-estimés (Figure 6-3). Il serait ainsi intéressant de recalculer les besoins totaux a posteriori avec l'ajout du temps en mouvement, et d'ainsi améliorer les performances de la nouvelle méthode de prédiction.

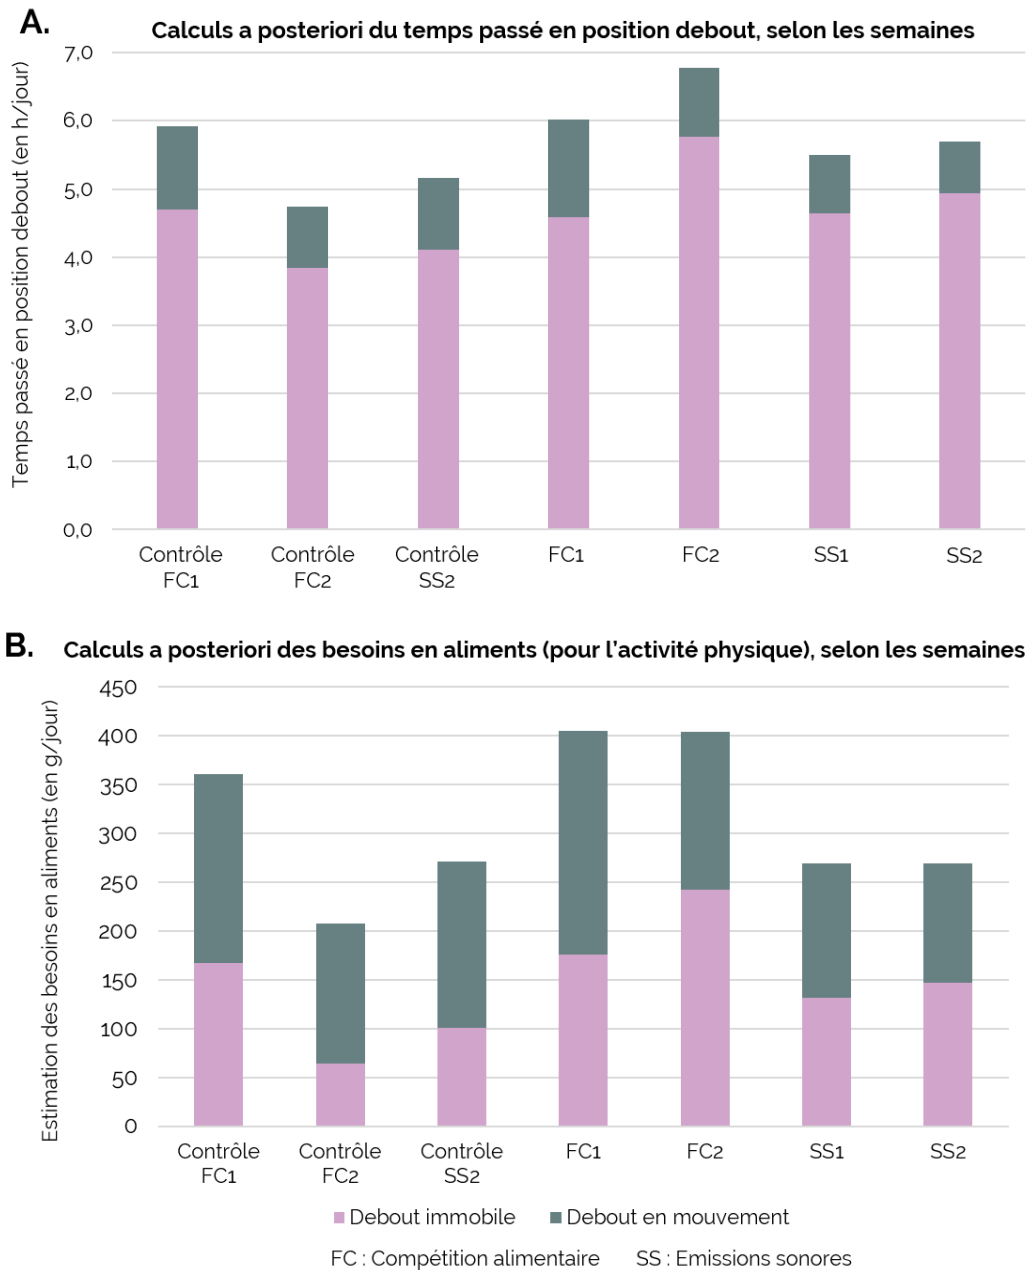


Figure 6-3 : Calculs a posteriori du temps debout (A.) et des besoins alimentaires (B.) avec la distinction du mouvement.

6.2.2. Développement d'un système d'aide à la décision pour l'alimentation et le bien-être

Intérêt d'un tel système. Notre étude a montré qu'il est nécessaire de prendre en compte de manière dynamique et individualisée les différents évènements qui peuvent se produire en élevage afin de prédire plus précisément les besoins alimentaires et d'évaluer l'état de bien-être individuel. Lors des expérimentations en France, les truies ont été plus fréquemment confrontées à l'occurrence

d'évènements particuliers par rapport à ce que l'on observe généralement en élevage. En effet, pendant les essais, les truies ont subi une dizaine d'évènements et pour certaines d'entre elles au cours de deux gestations consécutives. On peut faire l'hypothèse que ces nombreux évènements répétés ont pu créer un stress chronique. Cette hypothèse semble confortée par l'augmentation du nombre de truies « agressives » ou « bouc-émissaires » en fin de première gestation (notamment pour la bande A, Figure 6-4) ainsi que la proportion plus importante de truies agressives dès le début de leur seconde gestation (notamment dans la bande B). Cette hypothèse peut être confortée par les résultats contraires de l'expérimentation canadienne, où l'état de bien-être général s'améliorait au cours du temps (chapitre 5). Lors de l'expérimentation au Canada, aucun évènement (mis à part la vaccination) n'a été induit afin de modifier l'état de bien-être. Pourtant, quelques truies ont eu des problèmes de bien-être, ce qui montre l'intérêt de pouvoir évaluer cet état sur le terrain et à l'échelle individuelle. De plus, les conditions expérimentales présentaient quelques différences par rapport à une ferme commerciale, et peuvent avoir affecté l'état de bien-être des truies. En effet, en raison d'une mauvaise visibilité de nuit des caméras infrarouges, la lumière était allumée en continu (nuit et jour) pendant les expérimentations en France. Or, des études ont montré que l'augmentation de la photopériode (de 8h à 14h de lumière) entraînait la réduction du temps d'exploration du sol (Martelli *et al.*, 2005) et risquait d'augmenter les comportements agonistiques comme de la caudophagie (Van Putten, 1969). De plus, les truies s'alimentaient principalement durant la nuit, ce qui peut s'expliquer par le démarrage d'une nouvelle journée d'alimentation à minuit et faciliter le travail des animaliers en rendant les truies plus calmes (Gasa et Casanovas, 2019 ; Manu *et al.*, 2019). Ces changements dans l'environnement des truies peuvent influencer le comportement naturel et notamment les variations diurnes. Cependant, il y a un manque d'études sur ces points dans la littérature (Ma *et al.*, 2023).

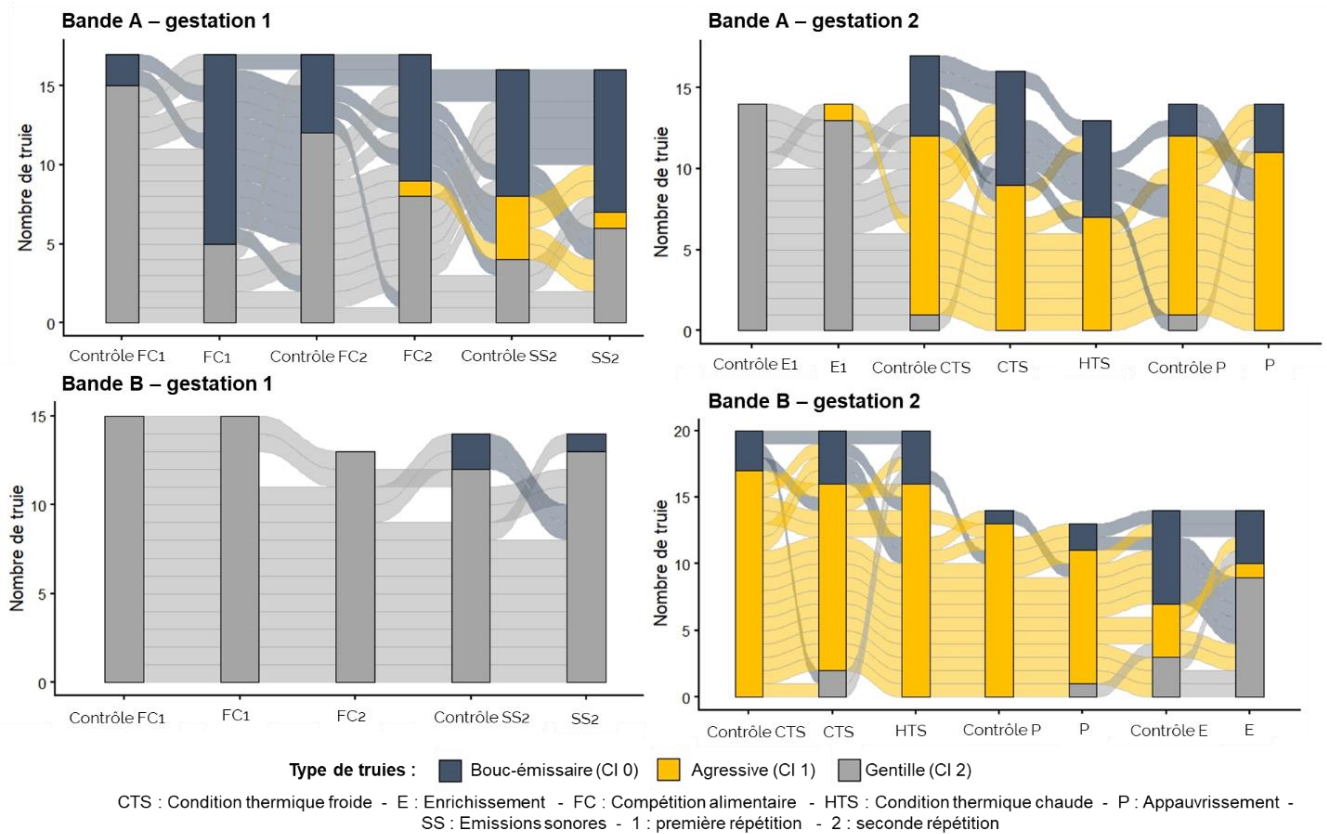


Figure 6-4 : Evolution entre les semaines observées des truies entre les trois clusters de bien-être, selon les quatre bandes.

Visualisation des informations. Un système d'aide à la décision basé sur les sorties des deux modules (nutrition et bien-être) pourrait être imaginé (Figure 6-5). Il s'agirait de créer un outil support pour l'éleveur, lui permettant de raisonner ces deux aspects de la gestion de l'élevage. En effet, la prédiction des besoins nutritionnels et de l'état de bien-être pourrait être intégrée dans une même solution logicielle, grâce à une remontée d'information unique des données (via un cloud, par exemple). La visualisation des données et des informations du système d'aide à la décision est essentielle pour une meilleure adoption par les éleveurs. Elle permet une interaction directe avec les utilisateurs en synthétisant les nombreuses données produites (Bellon-Maurel *et al.*, 2022). Par exemple, on pourrait résumer l'ensemble de l'activité des truies sur la journée avec un label bien-être spécifique (activité normale, ou anormale – signalement boiterie potentielle) ce qui permettrait une vérification rapide et aisée pour l'éleveur. L'interactivité et le temps de réponse de ces outils pourraient cependant poser problème dans certaines zones rurales avec des difficultés de télécommunications

(Neethirajan, 2020) et dans ce cadre des solutions locales seraient sans doute plus adaptées.




Figure 6-5 : Schéma de l'outil imaginé en aide à la décision, avec des alertes et des actions correctrices.

Système d'alertes. On pourrait imaginer sur la base du système d'aide à la décision, le développement d'un système d'alertes et de notifications pour l'éleveur (Figure 6-5), intégrant également des actions correctrices automatiques (point développé ci-après). Il pourrait, par exemple, indiquer qu'il faut diminuer ou augmenter l'apport alimentaire pour une truie spécifique et qu'il est possible qu'elle rencontre un problème de mal-être, en lien avec un changement comportemental. Cependant, cette question des alertes/notifications est un point de vigilance pour une application en élevage. En effet, de même que dans la vie quotidienne, nous supportons de moins en moins des notifications trop fréquentes, les éleveurs ne veulent pas être submergés par celles-ci. Une notification doit en effet indiquer quelque chose de sûr pour gagner la confiance de l'éleveur et éviter l'abandon de l'outil. Les fausses alertes sont coûteuses en temps mais peuvent aussi créer une pression psychologique sur les utilisateurs. De même, les faux négatifs doivent être réduits afin d'éviter de pas identifier une truie malade (Dominiak, 2017 ; Li *et al.*, 2020). Les performances de classification de l'état de

bien-être des truies obtenues dans le cadre de notre travail sont à améliorer (notamment pour les truies 'bouc-émissaires', 60 % de précision et 85 % de rappel) avant un déploiement terrain. Améliorer la précision au-delà des 95 % (comme pour les truies labélisées 'gentilles') permettrait d'obtenir des alertes pertinentes et fiables, comme dans les études relatives à la détection des comportements agressifs (Chen *et al.* 2019), des boiteries (Briene *et al.*, 2021) ou de maladies respiratoires (Yin *et al.*, 2020). L'amélioration de la prédiction pourrait passer par l'ajout d'informations sur la truie ou son historique de comportement.

Fenêtre temporelle pour l'analyse. La question du pas de temps, ou fenêtre temporelle idéale, pour la prédiction des besoins ou de l'état de bien-être est également à préciser. L'ajustement alimentaire quotidien est possible, mais il serait intéressant de mesurer son intérêt. En effet, il est connu que le métabolisme et les réserves corporelles de la truie peuvent faire preuve de plasticité, notamment lors de l'alternance lactation et gestation. Il convient alors de se questionner sur la fenêtre temporelle à considérer sans risquer de compromettre les performances de reproduction et de mise bas. Il serait intéressant de tester sur différentes périodes (de une journée à une semaine) l'ajustement de la ration d'une truie à la suite d'une période d'activité supérieure à celle couverte par ses apports alimentaires, et d'évaluer les effets sur la condition corporelle et les performances de mise-bas et de lactation. Pour la prédiction de l'état de bien-être, le pas de temps d'analyse pourrait être plus fin que celui de la journée, si l'historique est pris en compte pour la prédiction. En effet, dans notre étude nous avons considéré une analyse sur deux jours, à cause de la plus faible fréquence d'analyse manuelle des vidéos. En imaginant un logiciel comme celui développé dans le projet SOMOVE, capable d'enregistrer le comportement de chaque truie toutes les 30 minutes (Durand *et al.*, 2022), l'analyse du bien-être pourrait être faite sur ce même pas de temps. En effet, un pas de temps réduit permettrait de détecter le plus précocement des problèmes mais risquerait d'être moins fiable et d'augmenter le nombre de fausses alertes (dus à des variations ponctuelles et rapides). Les études de Chen *et al.* (2019) se sont basées sur un pas de temps de 3 secondes pour détecter des agressions, tandis que Thomas *et al.* (2021) a utilisé une échelle

journalière pour la détection de diarrhée. Un pas de temps de 30 minutes pourrait ainsi être envisagé mais en intégrant une information sur le moment de la journée (matin, après-midi, nuit).

6.2.3. Actions correctrices automatiques pour l'amélioration du bien-être

Enrichissement et nouveauté. En plus d'un support d'aide à la décision, l'outil pourrait également proposer des actions correctrices afin de répondre le plus précocement possible à un problème de bien-être (Figure 6-4). Dans la thèse, on peut voir, que lors des semaines événements, le comportement social et notamment les interactions agonistiques, sont le plus impactées par celles-ci. Il s'agirait ainsi de générer des actions visant à réduire l'agressivité au sein du groupe. Parmi ces actions, on pourrait imaginer l'ajout d'enrichissement dans le milieu, comme des jets de paille automatiques par exemple. Mais il faut cependant tenir compte du fait que les truies sont souvent plus attirées par la nouveauté que par la quantité (Mkwanazi *et al.*, 2019). Dans cette idée d'attractivité, on pourrait imaginer une zone supplémentaire de l'enclos accessible par un portail s'ouvrant lorsque qu'une augmentation de la proportion de truies 'agressives' est détectée. L'idée serait de créer un nouvel espace permettant à la fois un plus grand espace de fuite (Verdon et Rault, 2018) mais aussi de l'attractivité avec des enrichissements, lié au caractère temporaire de l'accès à cet espace. L'accessibilité de cet espace devra être limitée dans le temps (inférieure à la journée) car certaines études ont montré que l'augmentation de l'espace peut également créer plus d'agressivité, en lien avec la taille du groupe de truies (Bench *et al.*, 2013). La fermeture de cette zone pourrait être conditionnée par une diminution importante du nombre de truies 'agressives', afin de retrouver un niveau basal.

Enrichissement olfactif. Afin de diminuer l'agressivité au sein d'un groupe de porcs, on peut influencer les sens très développés du porc comme l'odorat ou l'ouïe. Ces sens influencent son analyse d'une situation et donc ses émotions et son comportement réponse. Une action pourrait être de diffuser des odeurs

« calmantes », ou contenant des composés semiochimiques, dans la salle. Par exemple, une phéromone maternelle-néonatale (appelée phéromone d'apaisement des porcs) produite pendant la lactation, réduit les agressions chez les porcelets en post-sevrage. Cependant, son effet bénéfique reste limité en conditions commerciales, à cause d'autres odeurs présentes en élevage. Il y a également un manque d'études pour savoir si cette phéromone est uniquement produite pendant la lactation (Mc Glone *et al.*, 2022). D'autres pistes sont également explorées pour réduire les agressions, comme celles de l'androsténone et du scatol (extrait des fèces de truies), lors de regroupements de porcelets, mais peu étudié chez les truies gestantes en groupe (Sankarganesh *et al.*, 2021). L'application d'odeurs « nouvelles », comme par exemple la diffusion par spray d'odeur d'anis dans la salle de gestation afin de réduire les relations agonistiques (Clouard *et al.*, NP) est également une piste à étudier.

Enrichissement sonore. La diffusion de sons dans la salle peut également être une solution envisagée afin de réduire l'agressivité des truies. En effet, l'étude de Cardona *et al.* (2022) a montré que selon la musique diffusée (en fonction de la structure harmonique), les porcs en croissance expriment une large variété d'émotions (positives ou négatives) reliées à des valences affectives différentes. La musique peut également réduire les blessures liées aux agressions et le taux de cortisol, relié au stress de l'animal (Olczak *et al.*, 2023). Comme la plupart des agressions ont lieu autour de l'automate d'alimentation, on peut également imaginer un système d'appel alimentaire individuel pouvant limiter les combats à proximité de celui-ci. Cela permettrait de réduire les agressions en cas de dysfonctionnement d'un des automates d'alimentation, comme cela est rapporté dans le chapitre 3 de la thèse. Ainsi, Manteuffel *et al.* (2022) ont testé un conditionnement des truies à un signal alimentaire avec des résultats prometteurs en conditions commerciales. Un autre projet de recherche au sein de l'unité (Blanc *et al.*, NP) a également mis en évidence la faisabilité de l'apprentissage d'un signal alimentaire pour accéder à l'automate d'alimentation, entraînant la réduction de 27 % des interactions négatives chez les truies gestantes.

Température de la salle. Une dernière action pourrait être d'augmenter ou de diminuer la température de la salle de gestation afin de jouer sur l'activité des truies. En effet lors des situations de conditions thermiques chaudes, les truies ont diminué leur activité et leur proximité, réduisant ainsi le nombre d'interactions négatives (chapitre 3). Cependant, les conditions thermiques chaudes extrêmes peuvent avoir des conséquences délétères sur la reproduction, l'ingestion et le bien-être des truies gestantes (Oh *et al.*, 2022). Ainsi, ces actions correctrices doivent être réfléchies en intégrant plusieurs composantes : économique, temps de travail et bien-être. En effet, on a pu voir dans le chapitre 3 que le retrait de paille (événement d'appauvrissement du milieu de vie) a provoqué une tendance à la baisse de l'activité générale des truies, ce qui pourrait réduire également les besoins nutritionnels de la truie. Si cette action peut être vue comme un avantage économique (réduction du coût alimentaire), elle n'est pas optimale pour le bien-être des truies (enrichissement réglementaire et obligatoire). Il faut donc réfléchir de manière systémique à la solution envisagée. Dans le cas de combats trop intenses entre congénères, ajouter de la paille peut ajouter un surcoût économique qui peut être contrebalancé par une prévention de blessures et donc de soins à apporter aux truies, également coûteux. Il faudrait alors pouvoir tester chacune des actions listées afin de mesurer l'ensemble des bénéfices et des inconvénients pour une application sur le terrain.

6.3. Références bibliographiques

Basak J.K., Paudel B., Shahriar S.A., Deb N.C., Kang D.Y., Kim H.T., 2023. Prediction of drinking water requirements by applying statistical and machine learning models in growing-finishing stage of pigs. *Comput. Electron. Agric.*, 210, 107934.

Bellon-Maurel V., Brossard L., Garcia F., Mitton N., Termier A., 2022. Agriculture et numérique. Tirer le meilleur du numérique pour contribuer à la transition vers des agricultures et des systèmes alimentaires durables. Livre blanc INRIA INRAE.

Bench C.J., Rioja-Lang F.C., Hayne S.M., Gonyou H.W., 2013. Group gestation sow housing with individual feeding II: How space allowance, group size and composition and flooring affect sow welfare. *Livest. Sci.*, 152, p.218-227.

Blanc A., Deroiné C., Clouard C., Gaillard C., NP. Effets d'une alimentation par appel sonore chez les truies gestantes sur leur comportement et bien-être. Accepté comme poster aux 56èmes JRP en 2024.

Briene P., Szczodry O., De Geest P., Van Weyenberg S., Van Nuffel A., Vangeyte J., Millet S., Ampe B., Tuytens F.A.M., Maselyne J., 2021. Testing the potential of the Sow Stance Information System (SowSIS) based on a force plate system built into an electronic sow feeder for on-farm automatic lameness detection in breeding sows. *Biosyst. Eng.*, 204, p.270-282.

Cardona J.Z., Ceballos M.C., Morales A.M.T., Jaramillo E.D., Rodriguez B.J., 2022. Music modulates emotional responses in growing pigs. *Sci. Rep.*, 12, 3382.

Chen C., Zhu W., Liu D., Steibel J., Siegford J., Wurtz K., Han J., Norton T., 2019. Detection of aggressive behaviours in pigs using a RealSense depth sensor. *Comput. Electron. Agric.*, 166, 105003.

Chen C., Zhu W., Steibel J., Siegford J., Han J., Norton T., 2020. Recognition of feeding behaviour of pigs and determination of feeding time of each pig by a video-based deep learning method. *Comput. Electron. Agric.*, 176, 105642.

Chen C., Zhu W., Norton T., 2021. Behaviour recognition of pigs and cattle: Journey from computer vision to deep learning. *Comput. Electron. Agric.*, 187, 106255.

Dominiak K.N., 2017. Spatial modelling of drinking patterns as a tool for reducing alarms in pig production. Thèse de doctorat, Faculty of health and medical sciences, University of Copenhagen, 167p.

Doulgerakis V., Kalyvas D., Bocaj E., Giannousis C., Feidakis M., Laliotis G.P., Patrikakis C., Bizelis I., 2019. An animal welfare platform for extensive livestock production systems. In : CEUR Workshop Proceedings, vol. 2492.

Dourmad J.Y., Etienne M., Valancogne A., Dubois S., van Milgen J., Noblet J., 2008. InraPorc: A model and decision support tool for the nutrition of sows. *Anim. Feed. Sci. Technol.*, 143, p.372-386.

- Durand M., Simon M., Foisil J., Dourmad J.Y., Largouët C., Gaillard, C., 2022. Evaluation of the physical activity of a group of gestating sows using an artificial neural network. In : EAAP scientific committee (Ed.), Book of abstracts, EAAP – 73rd Annual Meeting, p. 455, Porto, Portugal.
- Gaillard C., Quiniou N., Gauthier R., Cloutier L., Dourmad J.Y., 2020. Evaluation of a decision support system for a precision feeding of gestating sows. *J. Anim. Sci.*, 98, p.1-12.
- Gasa J., Casanovas J., 2019. Alimentation en gestation : l'heure est-elle importante ? 3trois3.com, Conduite. Consulté le 9 août 2023. url: https://www.3trois3.com/articles/alimentation-en-gestation-lheure-est-elle-importante_14107/
- Kamilaris A., Prenafeta-Boldú F.X., 2018. A review of the use of convolutional neural networks in agriculture. *J. Agric. Sci.*, 156, p.312–322.
- Labuissiere E., Dubois S., Esnault J., van Milgen J., 2022. Energy cost of physical activity (standing and walking) in finishing pigs and sows. *Anim. Sci. P.*, 13, p.325–326.
- Lardy R., Ruin Q., Veissier I., 2023. Discriminating pathological, reproductive or stress conditions in cows using machine learning on sensor-based activity data. *Comput. Electron. Agric.*, 204, 107556.
- Le Floc'h N., Boudon A., Montagne L., Gilbert H., Gondret F., Lebret B., Lefaucheur L., Louveau I., Merlot E., Père M.C., Meunier-Salaün M.C., Prunier A., Quesnel H., 2021. Santé et bien-être de la truie gestante et du porc en croissance. *INRAE Prod. Anim.*, 34, p.48-79.
- Li H., Yin J., Tan B., Chen J., Zhang H., Li Z., Ma X., 2019. Physiological function and application of dietary fiber in pig nutrition: A review. *Animal Nutrition*, 7, p.259-267.
- Li G., Huang Y., Chen Z., Chesser G.D.Jr., Purswell J.L., Linhoss J., Zhao Y., 2021. Practices and Applications of Convolutional Neural Network-Based Computer Vision Systems in Animal Farming: A Review. *Sensors*, 21, 1492.
- Ma H., Xie Y., Li A., Zhang T., Liu Y., Luo X., 2023. A review on the effect of light–thermal– humidity environment in sow houses on sow reproduction and welfare. *Reprod. Domest. Anim.*, p.1–23.
- Manu H., Lee S.H., Ren P., Pangen D., Yang X., Baidoo S.K., 2019. Effects of time of feeding during gestation on sow's performance. *J. Anim. Sci.*, 97, p.1234–1241
- Marsot M., Mei J., Shan X., Ye L., Feng P., Yan X., Li C., Zhao Y., 2020. An adaptive pig face recognition approach using Convolutional Neural Networks. *Comput. Electron. Agric.*, 173, 105386
- Martelli G., Scalabrin M., Scipioni R., Sardi L., 2005. The effects of the duration of the artificial photoperiod on the growth parameters and behaviour of heavy pigs. *Vet. Res. Commun.*, 29, p.367-369.
- McGlone J.J., Archer C., Henderson M., 2022. Interpretive review: Semiochemicals in domestic pigs and dogs. *Front. Vet. Sci.*, 9, 967980.

- Manteuffel C., Puppe B., Hartwig T., Wirthgen E., 2022. Learning, health and productivity of group-housed sows conditioned to signal-feeding under realistic husbandry conditions. *Livest. Sci.*, 266, 1051111.
- Mkwanazi M.V., Ncobela C.N., Kanengoni A.T., Chimonyo M., 2019. Effects of environmental enrichment on behaviour, physiology and performance of pigs — A review. *Asian-Australas J. Anim. Sci.*, 32, p.1-13.
- Neethirajan S., 2020. The role of sensors, big data and machine learning in modern animal farming. *Sens. Bio-Sens. Res.*, 29, 100367.
- Neethirajan S., Kemp, B., 2021. Digital Livestock Farming. *Sens. Bio-Sens. Res.*, 32, 100408.
- Norton T., 2023. A practical approach on innovative tools to improve pig production. In : 14th ESPHM 2023, Thessaloniki, Grèce.
- Oh S., Hosseindoust A., Ha S., Moturi J., Mun J., Tajudeen H., Kim J., 2022. Metabolic Responses of Dietary Fiber during Heat Stress: Effects on Reproductive Performance and Stress Level of Gestating Sows. *Metabolites*, 12, 280.
- Olczak K., Penar W., Nowicki J., Magiera A., Klocek C., 2023. The Role of Sound in Livestock Farming—Selected Aspects. *Animals*, 13, 2307.
- Van Putten G., 1969. An investigation into tail-biting among fattening pigs. *British Vet. J.*, 125, 511.
- Sankarganesh D., Kirkwood R., Angayarkanni J., Achiraman S., Archunan G., 2021. Pig pheromones and behaviors: A review. *Theriogenology*, 175, p.1-6.
- Thomas J., Rousselière Y., Marcon M., Hémonic A., 2021. Early detection of diarrhea in weaned piglets from individual feed, water and weighing data. *Front. Anim. Sci.*, 2, 688902.
- Thomas R.J., O'Hare G., Coyle D., 2023. Understanding technology acceptance in smart agriculture: A systematic review of empirical research in crop production. *Technol. Forecast. Soc. Change*, 189, 122374.
- Turcotte S., 2015. Truies en groupe : l'expérience québécoise. *Porc Québec*, p.26-38. url : <https://www.cdpq.ca/cdpq.ca/files/65/652e0ea3-fca1-454a-9be6-de95645b0451.pdf>
- Verdon M., Rault J.L., 2018. Aggression in group housed sows and fattening pigs. In : M. Spinka (Ed.), *Advances in pig welfare*, Woodhead Publishing Series in Food Science, Technology and Nutrition, Duxford, Royaume-Uni, p.235-260.
- Yin Y., Tu D., Shen W., Bao J., 2020. Recognition of sick pig cough sounds based on convolutional neural network in field situations. *Inf. Process. Agric.*, 8, p.369-379.

Conclusion générale

Les différents résultats de cette thèse ont montré que les données comportementales et environnementales permettaient d'améliorer l'estimation des besoins nutritionnels et de l'état de bien-être des truies gestantes. En effet, la thèse a permis de mettre en évidence que les truies confrontées à divers événements pendant leur gestation, modifient leur comportement et par conséquent leurs besoins nutritionnels journaliers. Ces modifications peuvent être enregistrées grâce à des capteurs et des automates : du comportement social, d'alimentation, d'abreuvement et de l'activité physique de l'animal. Ils peuvent enregistrer des variations dans le milieu de vie avec la mesure de l'ambiance (température, humidité, niveau sonore) de la salle de gestation. L'utilisation des algorithmes de machine learning (gradient tree boosting et random forest, notamment) sur ces données comportementales et environnementales a permis une prédiction précise des besoins nutritionnels journaliers en lysine digestible et en énergie métabolisable. Elle a également permis l'estimation de l'état de bien-être des truies gestantes à l'échelle individuelle, et interprétable à l'aide d'un arbre de décision. La thèse a contribué à montrer qu'un nombre limité de capteurs permet d'obtenir des bons résultats de prédiction. Les prédictions utilisant les données produites par l'automate d'alimentation (comportement alimentaire) et les enregistrements vidéos (comportement social, activité physique) ont produit les meilleures performances de prédiction des besoins nutritionnels et de l'état de bien-être. Cette thèse ouvre ainsi la possibilité de créer un nouvel outil d'aide à la décision permettant d'ajuster quotidiennement les apports alimentaires des truies gestantes et d'améliorer leur bien-être, de façon non-invasive, automatique, et à l'échelle individuelle.

Annexes

Annexe A : Congrès de l'EAAP, 2021 (2 communications).....	237
Annexe B : Congrès de l'EAAP, 2022 (2 communications).....	238
Annexe C : Congrès de l'ISEP, 2022	239
Annexe D : Congrès de l'ESPHM, 2023.....	240
Annexe E : Congrès des JRP, 2023 (2 communications).....	242
Annexe F : Congrès des JRP, 2022	251

Annexe A : Congrès de l'EAAP, 2021 (2 communications)**Session 42****Theatre 3****Effect of feed competition on activity and social behaviour of gestating sows***M. Durand, A. Julienne, J.Y. Dourmad and C. Gaillard**INRAE, Institut Agro, PEGASE, Le Clos, 35590 Saint Gilles, France; maeva.durand@inrae.fr*

Since 2013, in EU, gestating sows are housed in groups. Even with automatic feeders, depending on individuals (i.e. age, hierarchy, weight) or groups (i.e. number of sows per feeder) characteristics, sows spend time and energy accessing feed which might modify their nutrient requirements, due to changes in their physical activity. The aim of this study was to evaluate the impact of an induced feed competition on the activity and social behaviour of gestating sows. A feed competition was set up by closing during 5 days (test period) one of the two feeders available in a pen housing 15 sows on average, doubling the number of sows per feeder. The previous week with the two feeders opened served as control (basal period). A total of 31 sows were included in the experiment. Skin lesions were visually recorded every week. Feeding behaviour was automatically recorded by the feeders. Videos recordings allowed to manually identify different behaviours: position, occupation, location in the room, and social interactions. The influence of the period (basal vs test) and parity (primiparous vs multiparous) on these measurements was analysed on R applying a linear mixed-effects model taking into account the random effect of the sows. The behaviour of the sows was impacted by the feed competition. During the first 36-h of test period, the number of visits to the feeder without receiving feed decreased compared to the basal period (2.3 vs 4.7 visits/d, $P < 0.01$) while the number of visits with feed was not affected by period (1.1 visit/d). During the test period, the sows were waiting more in front of the feeder than during basal period (98.5 vs 40.1 min/d, $P < 0.01$). Despite the increased number of negative social interactions during the test period (i.e. head shots, bites, $P < 0.01$), there were no significant effect on the number of skin lesions. These results show that sows were more active and express more negative social interactions during a feed competition test. It can be calculated that this resulted in about 5% increase of their energy requirement. The number of sows per feeder is thus an important parameter to consider for improving gestating sows' welfare and calculating their energy requirements.

Session 44**Theatre 5****Use of infrared thermography and rectal thermometer to measure body temperature of gestating sows***M. Durand, D. Renaudeau and C. Gaillard**INRAE, Institut Agro, PEGASE, Le Clos, 35590 Saint Gilles, France; maeva.durand@inrae.fr*

Body core temperature is generally used as a proxy to detect health or thermoregulations problems. In summer, sows can face thermal stress, with negative impacts on their welfare and performances. In practice, body core temperature is evaluated by using rectal thermometer but this method may be stressful for the animal, with possible subsequent effects on the measurement quality. Thermal imaging camera represents a non-invasive alternative for measuring animal temperature. The purpose of this study was to compare gestating sows' body temperatures measured with a rectal thermometer and with a thermal imaging camera in different ambient situations (14 to 32 °C). Individual temperatures were taken on 40 sows (8 primiparous), housed in two rooms, every morning (8am) during 12 days with a rectal thermometer and with a thermal imaging camera (model FLIR, E60; extracting software FLIRTOOL) on a shaved dorsal cutaneous area (2×12 cm²). The fixed effects of parity (primiparous vs multiparous), room (1 or 2), sow's posture during measurement (lying vs standing) on body temperatures (rectal and cutaneous) were analysed on R applying a linear mixed-effects model taking into account the random effect of the sows. Correlation coefficients between the sows temperatures from one side and the room temperature, live body weight, backfat thickness on the other side were calculated using Pearson correlation tests. Primiparous sows had higher rectal temperature than multiparous sows (38.3 vs 37.9±0.61 °C, $P = 0.007$). Rectal temperature was also correlated positively with room temperature ($R^2 = 0.34$, $P < 0.001$) and negatively with sow body weight ($R^2 = 0.38$, $P < 0.001$). The sows lying down had higher cutaneous temperature than the sows standing (35.3 vs 31.8±3.19 °C, $P < 0.001$). Cutaneous temperature was positively correlated with the room temperature ($R^2 = 0.77$, $P < 0.001$) and rectal temperatures ($R^2 = 0.48$, $P < 0.001$). To conclude, there is a relationship to explore between sow's rectal and cutaneous body temperatures. Few factors seem to influence these temperatures and therefore, they should be taken into account in the next step of this work aiming to develop a model predicting rectal temperature with infrared temperature and other non-invasive measurements.

Annexe B : Congrès de l'EAAP, 2022 (2 communications)

Session 21

Theatre 3

Effect of various short-term events on behaviours of gestating sows*M. Durand, J. Abarnou, A. Julienne, C. Orsini and C. Gaillard**PEGASE, INRAE, Institut Agro, Le Clos, 35590 St-Gilles, France; maeva.durand@inrae.fr*

Environmental conditions and technical disturbances may affect gestating sows' behaviour and performance, and their nutritional requirements. The aim of this study was to evaluate the effects of induced short-term events on gestating sows drinking, feeding, and social behaviours. Different events were induced on two groups of 20 gestating sows during a week for each event (test week), always preceded by a control week: a 'hot' and a 'cold' thermic stress (i.e. rooms on average at 32 and 15 °C for each stress), a pen enrichment event (providing ropes, bags), and a feeding competition (i.e. in each room one automated feeder closed over two). Automats recorded individual feeding and drinking behaviours. Individual social behaviours classified as negative (head butts, bites) or positive were extracted manually by video analysis during the first 36h of the feeding competition, and during two periods of 5h for the other events (13.30-18.30h, 23.00-04.00h). The effects of the week (test vs control) on behaviours were analysed using a linear mixed-effect model, including the random effect of the sow. During the feeding competition and the enrichment weeks, the number of nutritive visits to the feeder was not affected. Compared to the control week, the sows did less non-nutritive visits (NNV) during the feeding competition, (4.7 vs 2.3 NNV/d/sow, $P < 0.001$) and more during the enrichment week (4.6 vs 5.3 NNV/d/sow, $P < 0.01$). During the 'hot' week, the sows visited more the water trough than during the control or 'cold' weeks (15.3 vs 13.4 or 12.9 visits/d/sow, $P < 0.05$). Except during the enrichment, the number of negative behaviours (NB) increased during test weeks compared to control weeks (22.3 vs 6.9 NB/sow over 36h for the feeding competition $P < 0.001$; and 1.9 vs 1.3 NB/sow over 10h for the cold stress, NS). During the enrichment period, the number of NB decreased compared to control week (7.3 vs 5.3 NB/sow over 10h, $P < 0.05$). These preliminary results suggest that various short-term events during gestation modify differently the sows feeding, drinking, and social behaviours and that these behaviours could represent relevant indicators of welfare.

Session 41

Theatre 1

Evaluation of the physical activity of a group of gestating sows using an artificial neural network*M. Durand¹, M. Simon², J. Foisil², J.Y. Dourmad¹, C. Largouët³ and C. Gaillard¹**¹PEGASE, INRAE, Institut Agro, Le Clos, 35590 St-Gilles, France, ²DILEPLX, 3 avenue G. Tillion, 35136 St-Jacques-de-la-Lande, France, ³Institut Agro Rennes-Angers, Univ Rennes, Inria, IRISA, 35000, Rennes, France; maeva.durand@inrae.fr*

Physical activity influences the energy requirements of group-housed gestating sows, and changes in their activity or behaviour patterns may be signs of welfare or health disorders. Ear tag accelerometers usually used for assessing the activity are fragile, costly, and invasive sensors. Instead, cameras can record videos of the group of sows but require countless hours to manually analyse the different activities of the sows. In the present work, the performances of a deep-learning algorithm developed to automatically detect the different activities of the gestating sows on images are evaluated. Two groups of 18 sows, housed in two pens, were included in the experiment and followed during two consecutive gestations. Two cameras recorded each pen continuously. Six activities (lying ventrally and laterally, sitting, standing, eating and drinking) were manually annotated by animal behaviour experts, on the 1,331 images extracted from the videos. This annotated set of images was used to train the algorithm, an object detection model that uses convolutional neural networks to detect and classify objects in an image. Another set of 403 images was used to validate the performance of the algorithm which proved to be reliable. The classification accuracy of sows lying ventrally and eating were respectively 82% and 87%. The lowest accuracies were generated by sitting (47%) and drinking (53%) activities, probably partly due to the lack of images including these activities in the training dataset. Indeed, sitting represented 3% of the activities labelled on the training dataset, and drinking only 1%. On a daily basis, the sows spent 75% of their time lying laterally (53%) or ventrally (22%). They were more active (i.e. standing) between 00:30 and 09:00, due to the start of the new feeding day at 00:00. Variation in the physical activity appeared between the two sows' groups and the different gestation weeks. To improve this algorithm, new data will be collected and a tracking module will be integrated to be able to detect the walking activity and also to work at the individual level.

Annexe C : Congrès de l'ISEP, 2022

O163 Effect of short-term events on the activity of gestating sows and their nutritional requirements

M. Durand, J. Abarnou, A. Julienne, C. Orisini, J.Y. Dourmad, C. Gaillard
PEGASE, INRAE, Institut Agro Rennes-Angers, Le Clos, 35590 Saint-Gilles, France

Keywords: Precision feeding; Sow; Energy; Nutrition; Stress

Introduction

Various events, like a heatwave or a feeder dysfunction, can induce behavioural and physiological adaptations in gestating sows. Most often, these adaptations require energy and may deteriorate production performance (litter development and growth, sow body condition) if this extra energy is not provided. Previous studies mainly explored the effects of lasting events, while in practice most of the time these

events occur only during few hours or few days. The aim of this study was therefore to evaluate the impact of various short-term events on the physical activity and the nutritional requirements of gestating sows.

Material and Methods

Two groups of approximately 18 sows each were continuously video recorded during two consecutive gestations. Individual behaviour (standing, lying, or in movement) was analysed manually from these videos as well as the number of posture changes. Different periods were considered regarding the event induced. Each test week, during which a specific event was induced, was always preceded by a control week without any induced event. A feeding competition event was induced by closing one of the two automated feeders available in each room. For this event, the behaviour of 31 sows was analysed during the first 36 hours of each week (test and control). Thermic stress events, cold and hot, were induced through fans and heaters, to reach a room temperature of 15°C and 32°C, respectively. For these thermic events, the behaviour of 37 sows was analysed during two periods (PM: 13:30 - 18:30 h for the resting period, and Night: 23:00 - 04:00 h for the feeding period). The effect of a pen enrichment (providing rope, bags and brush) on the behaviour of the 28 multiparous was also evaluated during the resting and feeding periods.

The statistical analysis was done using R studio software (version 4.0.3). A linear mixed-effects model was applied on the variable of interest integrating the period (PM, Night), week (test vs control), and their interactions as fixed factors, as well as the random effect of the sow. The daily individual energy requirement was calculated using the equations of Dourmad et al. (2008) including the effects of physical activity and ambient temperature.

Results and Discussion

During PM, the sows were on average more active during the cold week compared to hot week (103 vs 83 min standing/5 h, $P < 0.001$), and they spent less time lying laterally (125 vs 174 min/5 h, $P < 0.001$). Due to these changes in activity and thermoregulation, metabolisable energy (ME) requirement increased by 2.5% during the cold week ($P < 0.001$) and decreased by 3% during the hot week (Figure 1). The coefficient of variation between sows of this change in ME requirement was 57% for cold and 51% for hot stress. The effect of temperature on the time spent lying laterally is a strategy to reduce or increase the thermic losses depending on temperature (Canaday et al., 2013). The pen enrichment did not affect the time spent lying ($P = 0.80$), standing ($P = 0.68$), or in movement ($P = 0.83$), and thus did not affect the nutritional requirements (Figure 1). This result may be related to the presence of straw in the pen during the control and test weeks. During the feeding competition, sows decreased their time spent lying by 97.7 min/36 h ($P < 0.001$) and increased their time spent waiting in front the feeder (147.3 vs 60.2 min/36 h, $P < 0.001$) which increased their energy requirements by 1% (Figure 1). The coefficient of variation between sows of the change in ME requirement was 70%. This increase of activity could be linked to the need of building a new hierarchy in the group to access the unique feeder.

Conclusion and Implications

The thermic stresses and the feeding competition significantly affected the sow's physical activity and thermoregulation, leading to a modification in ME requirement for maintenance. The enrichment setup was not stimulating enough to affect the physical activity or ME requirement, probably because the straw was also available in the control condition. This study indicates that the various short-term events tested impact differently the physical activity and the nutritional requirements. Integrating this data in real-time, into the nutri-




Figure 1. Effect of the various short-term events (cold and hot thermic stress, feed competition, and enrichment period) on the median and quantiles of metabolisable energy requirement (A) and the corresponding amount of feed (at 12.67 MJ/kg and 0.86 DM content kg/kg; B) for gestating sows.

tional model could be important for a better adjustment of the feed supply to the requirements of the sows all over their gestation period. Furthermore, the large variability of individual responses shows that an individual adjustment of the diet would be necessary to enhance the precision feeding model.

Funding

This work was supported by the French National Research Agency under the Investments for the Future Program, referred as ANR-16-CONV-0004.

References

D.C.Canaday, J.L.Salak-johnson, A.M.Visconti, X.Wang, K.Bhalerao, R.V.Knox, 2013. Effect of variability in lighting and temperature environments for mature gilts housed in gestation crates on measures of reproduction and animal well-being. *Journal of Animal Science* 91, 1225-1236.
J.Y.Dourmad, M.Etienne, A.Valancogne, S.Dubois, J.van Milgen, J.Noblet, 2008. InraPorc: A model and decision support tool for the nutrition of sows. *Animal Feed Science Technology* 143, 372-386.

doi: 10.1016/j.anscip.2022.07.173

Annexe D : Congrès de l'ESPHM, 2023

ESPHM 2023

WELFARE AND NUTRITION

AWN-PP-07

PREDICTION OF DAILY NUTRITIONAL REQUIREMENTS OF GESTATING SOWS BASED ON THEIR BEHAVIOUR AND MACHINE LEARNING METHODS

M. Durand¹, C. Largouët², L. Bonneau², J. Dourmad¹, C. Gaillard¹¹PEGASE, INRAE, Institut Agro, 35590, Saint Gilles, France²Institut Agro, Univ Rennes1, CNRS, INRIA, IRISA, 35000, Rennes, France

Background and Objectives

Precision feeding aims to define the right feeding strategy according to individual's nutrient requirements, in order to improve health and reduce feed cost. Usually, the nutrient requirements of gestating sows are provided by a mechanistic nutritional model requiring input data such as age and body status. This paper propose to predict the daily nutritional requirements, with only the data measured by sensors. According to various digital farm configurations, we explore and evaluate Machine Learning (ML) methods to predict nutrient requirements of gestating sows.

Material and Methods

Behavioural data of gestating sows are extracted from sensors data collected on 73 sows from parities 1 to 9. Their nutrient requirements concerned metabolisable energy (ME, in MJ/d) and standard ileal digestible lysine (SID Lys, in g/d). Various digital farm configurations are proposed, from low-cost to more expensive equipments (electronic feeder and drinker, connected weight scale, accelerometers and video analysis software), producing various data at different levels of detail on sow behavior. Nine ML algorithms were trained on these 23 scenarios to predict daily energy and lysine for each sow. Results proposed by the ML algorithms are compared with outputs given by the nutritional model InraPorc.

Results

Using a Random Forest algorithm, the RMSE were lower with data feeder alone (1.22 MJ/d for ME and 0.53 g/d for SID Lys, 2.4 and 4.02% of mean absolute error respectively) compared those obtained with combined data from feeders and accelerometers (1.01 MJ/d and 0.29 g/d, 1.9 and 2.1%). The inclusion of the sows' characteristics reduced the RMSE, on average, by 20% for ME and by 35% for Lys.

Discussion and Conclusion

This study highlights that daily requirements of gestating sows can be predicted accurately thanks to behavioural data provided by sensors. It paves the way to propose simpler solutions for the application of precision feeding on farms.



maeva.durand@inrae.fr



Prediction of daily nutritional requirements of gestating sows based on their behaviour and machine learning methods

M. DURAND, C. LARGOUËT, L. BONNEAU, J.Y. DOURMAD, C. GAILLARD


BACKGROUND & OBJECTIVE

- **Precision Feeding** aims to define the right feeding strategy according to **individual's nutrient requirements**, to reduce feed cost and environmental losses.
- Usually, the nutrient requirements of gestating sows are calculated by a **mechanistic nutritional model** requiring input data such as sows and herd characteristics.
- **Aim of this study: Prediction of nutritional requirements using machine learning methods and sensor data.**

CONCLUSION

- **Machine learning methods using sensor data and behavioural data can accurately predict** the sows daily requirements (error under 7 % for energy and 12% for lysine) which could **simplify the application** of precision feeding on farms.
- **Sow's activity, feeding behaviour, and body weight** are the best predictors. **Adding sow and housing characteristics** significantly improves the results.
- **Gradient Tree Boosting** is the most accurate ML algorithm.


MATERIAL AND METHODS



RESULTS

SID Lys: Standard ileal digestible lysine; ME: Metabolisable energy; RMSE: Root Mean Square Error; MAPE: Mean Absolute Percentage Error; R²: coefficient of determination

Integration of sow and housing characteristics (scenarios SP.) reduced the RMSE by 20% for energy and 35% for lysine.



Lower MAPE obtained using scenarios SP with **automatic weighting system + feeder** for lysine (5.31%) and with **feeder + activity sensors** for energy (3.88%).

R² values were higher with **Gradient Tree Boosting** (0.95 for energy and 0.99 for lysine) compared to those obtained with **linear regression** (0.52 and 0.83).



Annexe E : Congrès des JRP, 2023 (2 communications)

2023. Journées Recherche Porcine, 55, 371-376.

Publication sous Licence Creative Commons 

Prédiction de la température corporelle de truies gestantes à l'aide d'une caméra thermique

Maëva DURAND (1), Patrick GAGNON (2), Laetitia CLOUTIER (2), Gabrielle DUMAS (2), Frédéric GUAY (3),
Jean-Yves DOURMAD (1), Charlotte GAILLARD (1)

(1) PEGASE, INRAE, Institut Agro, Le Clos, 35590 Saint-Gilles, France

(2) Centre de développement du porc du Québec inc. (CDPQ), 2590 bd Laurier, Québec, G1V 4M6, Canada

(3) Université Laval, Département des sciences animales, 2325 rue de l'Université, G1V 0A6, Québec, Canada

maeva.durand@inrae.fr

Avec la collaboration technique de Yannick Surel, Daniel Boutin de l'UE3P (France) et d'Éloïse Talbot-Pouliot, Allison Garand et Nancy Gendron du CDPQ (Canada)

Prédiction de la température corporelle de truies gestantes à l'aide d'une caméra thermique

La température corporelle est utilisée en élevage porcin afin de détecter des problèmes de santé, de bien-être ou des problèmes de thermorégulations. En pratique, elle est mesurée par un thermomètre rectal mais cette méthode est invasive pour l'animal et chronophage pour le manipulateur. La thermographie infrarouge présente de nombreux avantages et est en plein développement. Le but de cette étude était de prédire la température corporelle des truies au cours de leur gestation à l'aide d'une caméra thermique. L'étude comportait deux séries de mesures : une première réalisée en France sur 37 truies et une deuxième réalisée au Canada sur 109 truies. Les températures cutanées des truies ont été relevées à l'aide d'une caméra thermique mobile sur six zones : le globe oculaire, la base de l'oreille, le dos (rasé et non rasé), la vulve et entre les mamelles inguinales. Ces mesures ont été comparées à la température relevée à l'aide d'un thermomètre rectal, comme référence. De plus, la température et l'humidité relative de l'air ont été enregistrées à différents endroits des salles de gestation afin de calculer un index de température – humidité (THI). Les résultats ont montré une corrélation positive ($r = 0,31-0,32$, $P < 0,001$) entre les températures rectale et cutanée (toutes zones confondues), avec un effet du THI et des caractéristiques des truies (poids, condition corporelle, rang de portée). Les meilleurs modèles linéaires de prédictions ont pris en compte les températures de vulve, du dos rasé et de l'oreille avec des R^2 entre 0,41 et 0,63 et des RMSE inférieur à 0,5°C. Ces premiers résultats offrent des perspectives intéressantes pour prédire la température corporelle de la truie de manière non invasive.

Prediction of body temperature of gestating sows using a thermal camera

Body temperature is used on pig farms to detect health, welfare and thermoregulation problems. In practice, it is measured with a rectal thermometer, but this method is invasive for the animal and time consuming for the handler. Infrared thermography has many advantages and is currently being developed. The aim of this study was to predict the body temperature of sows during pregnancy using a thermal camera. The study consisted of two series of measurements: the first was carried out in France on 40 sows and the second in Canada on 109 sows. Skin temperature of the sows was taken using a mobile thermal camera on six areas: the eyeball, the base of the ear, the back (shaved and unshaven), the vulva and between the inguinal udders. These measurements were compared to the temperature taken with a rectal thermometer as a reference. In addition, temperature and relative humidity were recorded at different locations in the gestation rooms to calculate the temperature humidity index (THI). The results showed a positive correlation ($R = 0.31-0.32$, $P < 0.001$) between the rectal and skin temperatures (all areas combined), with an effect of the THI and sow characteristics. The best linear prediction models included the temperatures of the vulva, the shaved back and the base of ear, areas with R^2 between 0.41 and 0.63 and RMSE below 0.5°C. These initial results offer interesting prospects for predicting sow body temperature in a non-invasive and repeatable manner.

INTRODUCTION

La température corporelle des truies est un paramètre physiologique important, pouvant refléter une infection, une dérégulation thermique ou des événements physiologiques, tels que l'œstrus ou la parturition. La fièvre ou l'augmentation rapide de la température corporelle est un des principaux signes cliniques lors d'une inflammation ou d'une infection par un agent pathogène (Sorensen et Pedersen, 2015). Il est ainsi important de disposer des outils de suivi de la température corporelle des truies afin de surveiller leur état de santé. La mesure par caméra thermique est une méthode en développement, complémentaire au thermomètre rectal. Cette dernière est une mesure de référence chronophage qui peut augmenter le risque de propagation de pathogènes et aussi être stressante pour l'animal et l'observateur du fait de la manipulation et l'éventuelle contention du porc (Schmidt *et al.*, 2013).

La caméra thermique évalue la température cutanée à partir des émissions infrarouges du corps de l'animal, caractérisant les échanges de chaleur et la circulation sanguine, afin de déterminer la température corporelle. En effet, le porc ne transpire pas et il régule sa circulation sanguine périphérique afin de moduler les échanges thermiques avec l'air notamment sur certaines zones appelées « fenêtres thermiques » (Sorensen et Pedersen, 2015). Chez le porcelet nouveau-né, du fait de l'absence d'isolation, le corps entier constitue une fenêtre thermique et la température cutanée est entièrement homogène (Nielsen, 1997). Contrairement à la thermométrie infrarouge, la thermographie infrarouge (avec une caméra mobile, par exemple) présente l'avantage de détecter des anomalies et des différences de températures sur une surface et ainsi de pouvoir sélectionner des zones d'intérêts. La thermographie infrarouge est utilisée pour détecter des infections par des agents pathogènes (Islam *et al.*, 2015), de la fièvre (Cook *et al.*, 2015) ou des troubles digestifs (Wilcox, 2007). Toutefois, les études disponibles dans la bibliographie indiquent que la sensibilité des résultats varie selon les zones de mesures choisies et les conditions environnementales.

Le but de cette étude était de développer une méthode de prédiction de la température corporelle des truies gestantes à l'aide d'une caméra thermique (basée sur le principe de la thermographie infrarouge), en comparant différents zones corporelles de mesures et en prenant en compte différents facteurs de variation. A la suite d'une étude préliminaire mesurant la température cutanée au niveau du dos, le choix a été fait de tester d'autres zones identifiées comme des fenêtres thermiques : le globe oculaire, la base de l'oreille, la vulve et la mamelle.

1. MATERIEL ET METHODES

1.1. Dispositif expérimental

L'étude comportait deux séries d'expérimentations : une première réalisée en France (expérimentation A) et une deuxième réalisée au Canada (expérimentation B ; Tableau 1).

1.1.1. Expérimentation A

L'étude portait sur 37 truies gestantes, croisées Large White x Landrace, issues de deux bandes de l'unité Expérimentale Physiologie et Phénotypage des Porcs (UE3P, INRAE, Rennes, France, doi : 10.15454/1.5573932732039927E12). Elles étaient logées en groupes de 17-20 animaux, à partir de 3 jours de

gestation, sur aire bétonnée partiellement paillée avec 3,1 m²/truie. Les truies étaient alimentées selon une stratégie d'alimentation de précision selon la méthode décrite par Gaillard *et al.* (2019) avec un mélange de deux aliments (un riche et un pauvre en nutriments).

La température de la salle de gestation a été modulée sur 4 semaines (à partir de 15 et 43 j de gestation selon la bande), avec une semaine « froide » en moyenne à 14 °C, une semaine « chaude » à 32 °C et deux semaines contrôles à 20 °C précèdent les semaines « froide » et « chaude ». La période thermique froide a été obtenue en augmentant le niveau de ventilation minimal de 30 à 50 % et en ouvrant les fenêtres afin d'assurer une arrivée d'air froid dans la salle. La période thermique chaude a été obtenue à l'aide de deux chauffages additionnels et en abaissant le niveau maximal de ventilation de 100 à 80 %.

1.1.2. Expérimentation B

L'étude a porté sur 109 truies gestantes, croisées Large White x Landrace, issue de la maternité de recherche et de formation du CDPQ (Armagh, Québec, Canada). Elles étaient logées en groupe à partir de 35 j de gestation, dans deux parcs avec 2,45 m²/truie, sur caillebotis béton. Les truies étaient réparties de manière aléatoire entre cinq stratégies alimentaires (A, B, C, D et HT) décrites dans Galot *et al.* (2023). La température de la salle de gestation n'a pas été modulée dans cet essai (en moyenne à 22,1°C) et est resté dans la zone de thermoneutralité de la truie.

Tableau 1 – Description des deux expérimentations (A et B).

	A	B
Périodes	02/2021	08/2021-10/2021
Nombre de truies	37	109
Nombre de bandes	2	1
Races	Large White x Landrace	
Température min, °C	13,1	18,5
Température max, °C	32,8	26,5
Humidité min, %	50,6	59,6
Humidité max, %	84,5	80,3
THI ¹ min	55,8	64,0
THI ¹ max	84,2	76,6
% Primipares	20	17
% Multipares	80	83
Poids truies moyen, kg	235,9	204,3

¹Index de température humidité, $THI = [1,8 \times T + 32] - [(0,55 - 0,0055 \times HR) \times (1,8 \times T - 26)]$, où T est la température de l'air en °C et HR l'humidité relative de l'air en % (Weigner *et al.*, 2016).

1.2. Mesures expérimentales

1.2.1. Expérimentation A

Les truies ont été pesées à l'aide d'une bascule électronique (Schippers, Pays-Bas, précision à ± 0,5 kg) au début de chacune des périodes thermiques. Les températures cutanées des truies ont été mesurées journalièrement à l'aide d'une caméra thermique mobile (Teledyne FLIR, E60, Oregon, Etats-Unis) sur une zone du dos (au niveau de la colonne vertébrale, perpendiculairement à la dernière côte) préalablement rasée. Les photos étaient toujours prises à un mètre de distance. Ces mesures ont été comparées à la température relevée au même moment sur la truie à l'aide d'un thermomètre rectal (après désinfection), utilisée comme référence. La posture de la truie lors de la mesure (debout ou couchée) a été enregistrée.

1.2.2. Expérimentation B

Les truies ont été pesées à l'aide d'une bascule (Pennsylvania Scale Company, États-Unis, précision à ± 0,2 kg) lors de la mise

2023. Journées Recherche Porcine, 55, 373-376.

en groupe et à 90 j de gestation. Les mesures de températures cutanées (caméra thermique Teledyne FLIR, E86, Oregon, Etats-Unis) étaient relevées hebdomadairement sur cinq zones corporelles non rasées : le globe oculaire, la base à l'arrière de l'oreille, le dos (au niveau de la colonne vertébrale, perpendiculairement à la dernière côte), au milieu de la vulve et entre les mamelles inguinales (Figure 1). Les photos étaient toujours prises à un mètre de distance. Ces mesures ont été comparées à la température rectale comme dans l'expérimentation A et la posture de la truie a été également enregistrée. Des mesures ont été répétées 10 fois sur 11 truies sur une même journée afin de déterminer la répétabilité des mesures.




Figure 1 – Représentation schématique des zones où la température cutanée a été relevée par caméra thermique infrarouge (ir) : 1 : ir_oeil, 2 : ir_oreille, 3 : ir_dos, 4 : ir_vulve et 5 : ir_mamelle

1.2.3. Mesures environnementales

La température et l'humidité relative de l'air ont été enregistrées grâce à des capteurs (Lascar Electronics, Royaume-Uni, précision à $\pm 0,01$ °C) à différents endroits des salles de gestation, à 180 cm au-dessus du sol.

1.3. Extraction des données et analyses statistiques

Un total de 1447 images pour l'expérimentation A et 5733 pour la B ont été prises et analysées à l'aide du logiciel FLIR THERMAL STUDIO (Teledyne FLIR, Oregon, Etats-Unis) par le même observateur. L'émissivité de la peau, qui décrit sa capacité à émettre de l'énergie par radiation, était fixée à 0,97, comme déterminé dans l'étude de Sorensen *et al.* (2014). La température de l'air a été corrigée par celle enregistrée par les sondes au même moment. L'index THI (Temperature-Humidity Index) a été calculé à partir de l'équation suivante, déterminée par Wegner *et al.* (2016), où T est la température de l'air en °C et HR l'humidité relative de l'air en % :

$$THI = [(1,8 \times T) + 32] - [(0,55 \times \frac{HR}{100}) \times [(1,8 \times T) + 32] - 58]$$

Les analyses statistiques ont été réalisées sur le logiciel R studio (Version 4.1.2, R Core Team, 2022). Une première étape de présélection des variables d'intérêt pour le modèle de prédiction a été réalisée comme suit. Des corrélations de Pearson ont été calculées entre les températures corporelles et les variables explicatives continues (poids, température et humidité de la salle de gestation). Des ANOVA ont été utilisées pour prédire l'effet des variables posture, rang de parité et de la zone de mesure sur les températures corporelles.

Puis, des modèles linéaires mixtes ont été construits afin de prédire la température rectale à partir de la température cutanée, séparément pour les truies primipares et multipares et pour chacune des zones de mesures cutanées. Ils prenaient en compte l'effet aléatoire de la truie et les effets fixes de THI (en

°C), du poids vif (en kg), de l'épaisseur de gras P2 (en mm), et de la posture de la truie (debout ou couchée). Trois modèles ont été construits pour prédire la température (rectale) de la truie avec les mesures de la caméra thermique : (A) l'un ne comprenant que les effets fixes, (B) un autre avec les effets fixes et interactions (avec la température cutanée), et le dernier (C) avec uniquement les effets et interactions significatives. Le meilleur modèle a été choisi à partir du package « performance » (Lüdecke *et al.*, 2021), en fonction de multiples indices de qualité et de prédiction (carré du coefficient de corrélation (R^2), écart quadratique moyen - RMSE, coefficient de corrélation intra-classe).

2. RESULTATS ET DISCUSSION

2.1. Corrélations entre températures corporelles

Les températures rectales avaient une gamme de variation entre 36,4 et 40,2 °C tandis que celle des températures cutanées étaient de 22,6 à 39,9 °C (Tableau 2). La zone de mesures cutanées influençait la température relevée ($P < 0,001$). Toutes les températures cutanées se distinguaient les unes des autres, sauf le dos non-rasé et le dos rasé ($P = 0,30$), ainsi que la mamelle et l'oreille ($P = 0,82$).

Tableau 2 – Moyenne, écart type et gamme de variation des températures corporelles des deux séries de mesures (expérimentation A et B).

	Expérimentation	Moyenne \pm Ecart-type	Gamme [Min ; Max]
T_rectale, °C	A et B	38,0 \pm 0,51	[36,4 ; 40,2]
Ir_oeil, °C	B	32,7 \pm 1,48	[28,2 ; 37,7]
Ir_oreille, °C	B	34,3 \pm 1,12	[30,7 ; 37,9]
Ir_dos, °C	B	31,7 \pm 1,83	[25,2 ; 39,9]
Ir_dos rasé, °C	A	31,9 \pm 3,23	[22,6 ; 31,9]
Ir_vulve, °C	B	34,7 \pm 1,10	[30,3 ; 37,9]
Ir_mamelle, °C	B	34,2 \pm 1,18	[30,5 ; 38,2]

En moyenne la température rectale est comparable aux valeurs mesurées dans la bibliographie (Sorensen et Pedersen, 2015). Toutefois la gamme des températures mesurées montre une certaine variabilité avec ponctuellement des valeurs supérieures à 39 °C symptomatiques de fièvre. Le minimum (36,4 °C) est un peu faible et pourrait provenir d'erreurs de mesure (faible pénétration du thermomètre). La variabilité des mesures de température cutanée est plus élevée que pour la température rectale, les variations les plus importantes étant observées pour la mesure au niveau de dos après rasage des soies.




Figure 2 – Matrice des corrélations de Pearson ($P < 0,001$) pour les truies primipares entre les différentes températures corporelles des deux expérimentations (A et B).

2023. Journées Recherche Porcine, 55, 374-376.

La température rectale est positivement corrélée avec la température cutanée aussi bien chez les primipares ($r = 0,31, P < 0,001$, Figure 2) que les multipares ($r = 0,32, P < 0,001$, Figure 3). Les corrélations les plus élevées avec la température rectale sont observées pour la vulve et l'oreille, suivies de la mamelle. Concernant la mesure au niveau du dos la corrélation est plus élevée lorsqu'il est rasé. Les corrélations obtenues pour la mamelle et le globe oculaire sont moins élevées que celles obtenues par Traulsen *et al.* (2010) et Malmkvist *et al.* (2012). D'autres études se sont intéressées au coin interne de l'œil (*inner canthus*) chez le porc et l'homme, avec de bonnes corrélations et une facilité d'accès contrairement au globe oculaire. Mais il s'agit d'une zone, à l'inverse de la cornée, qui peut être sale (en particulier avec la présence de larmes brunes) et qui nécessite une caméra avec une haute résolution spatiale et une forte précision (Soerensen et Pedersen, 2015). La base de l'oreille et la vulve semblent être les zones les plus prometteuses, avec des corrélations plus élevées que celles des études de Zinn *et al.* (1985) et Traulsen *et al.* (2010). La présence de poils lors de la mesure au niveau du dos réduit la qualité de la prédiction. De plus, toutes les truies n'ont pas le même degré de pilosité qui varie notamment selon l'âge, ce qui peut également impacter la mesure.




Figure 3 – Matrice des corrélations de Pearson pour les multipares entre les différentes températures corporelles. Toutes les corrélations sont significatives ($P < 0,001$).

2.2. Influence de facteurs externes et internes à la truie (pré-sélection des variables)

2.2.1. Température et humidité de la salle de gestation

Les températures rectales ($r = 0,23, P < 0,001$) et cutanées ($r = 0,40, P < 0,001$) étaient corrélées positivement avec la température de la salle, avec une plus forte corrélation pour les mesures sur le dos rasé ($r = 0,77, P < 0,001$). Les mesures de température au niveau de l'oreille et du dos étaient les plus fortement corrélées avec la température de la salle (respectivement, $r = 0,34$ et $0,42, P < 0,001$).

La température rectale était peu corrélée avec l'humidité relative ($r = 0,08, P = 0,002$), contrairement aux températures cutanées ($P = 0,14$). Le THI était corrélé positivement avec la température rectale ($r = 0,23, P < 0,001$) et les températures cutanées ($r = 0,40, P < 0,001$, Figure 4).

La température de la salle semble donc influencer modérément à fortement la température rectale et les températures cutanées, avec un très faible effet de l'humidité relative. De même, Jia *et al.* (2020) observaient une influence modérée de la température et de l'humidité relative de la salle sur les températures cutanées relevées à l'oreille, au dos et à l'œil.

D'autres paramètres environnementaux devraient être également explorés, comme la vitesse de l'air (Ramirez, 2017).

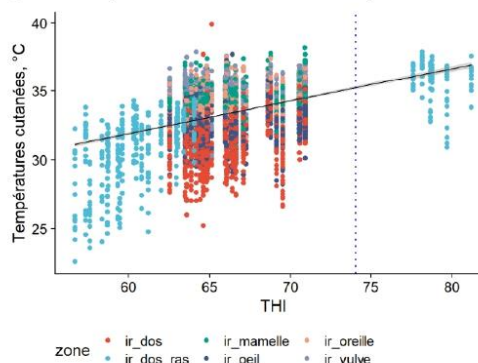


Figure 4 – Évolution de la température cutanée en fonction du THI (Wegner *et al.*, 2016) et des zones de mesures. La ligne pointillée bleue correspond à la limite d'un stress thermique (supérieure à un THI de 74) pour les porcs.

2.2.2. Poids et condition corporelle de la truie

La température rectale était corrélée négativement avec le poids des truies ($r = -0,21, P < 0,001$), mais pas avec l'épaisseur de gras dorsal ($P = 0,30$). La température cutanée était également corrélée négativement avec le poids des truies ($r = -0,08, P < 0,001$) et avec l'épaisseur de gras dorsal ($r = -0,07, P < 0,001$).

Le poids, ou plus exactement le ratio volume/poids est un paramètre à prendre en compte pour calculer les échanges thermiques entre le porc et l'environnement (Ramirez, 2017). Ainsi, le poids peut influencer la température cutanée, en impactant la production de chaleur comme montré chez le porc à l'engraissement en relation avec l'ingestion alimentaire (van Milgen *et al.*, 1998).

2.2.3. Rang de portée

Les primipares avaient une température rectale plus élevée que les multipares ($38,2$ vs. $37,9 \pm 0,45$ °C, $P < 0,001$) tandis qu'elles présentaient une température cutanée (toute zone confondue) inférieure ($33,2$ vs. $33,4 \pm 1,52$ °C, $P < 0,001$). Cheng (2020) a montré que la mesure de température cutanée à la vulve était significativement plus élevée chez les truies primipares et de rang 2 que chez les truies plus âgées. Il est probable qu'une partie de cet effet rang de portée soit liée à l'évolution pondérale des truies.

2.2.4. Stratégie alimentaire

La stratégie alimentaire testée dans l'essai B chez les multipares n'a eu pas d'effet significatif sur la température rectale ($P = 0,47$), alors qu'elle influençait la température cutanée ($P < 0,001$).

Pour mieux caractériser cet effet, d'autres paramètres pourraient également être explorés tels que la consommation d'aliment ou d'eau pour chaque truie, ou le temps écoulé entre la mesure de température et le dernier repas. En effet, Cheng (2020) a montré que le comportement alimentaire et ses variations diurnes impactent les mesures de température cutanée sur le milieu du dos, des mamelles, de la base des oreilles et de la vulve chez des truies après sevrage. De même, la consommation d'aliment, les phénomènes digestifs et le métabolisme produisent de l'extra chaleur (van Milgen *et al.*, 1998) qui pourrait influencer la température cutanée. De plus,

2023. Journées Recherche Porcine, 55, 375-376.

l'apport de sang vers le tractus digestif peut réduire la quantité de sang vers la surface.

2.2.5. Posture

Les truies en position couchée présentaient une température cutanée plus élevée que celles en position debout ($33,8\text{ °C}$ vs. $33,1 \pm 1,50\text{ °C}$, $P < 0,001$), tandis que leur température rectale était moindre ($37,9$ vs. $38,0 \pm 0,45\text{ °C}$, $P = 0,02$).

L'influence de la posture de l'animal lors de la mesure de température cutanée a déjà été montrée par Traulsen *et al.* (2010) mais sans explication physiologique. Ces résultats peuvent être liés également à la position du porc avant la mesure (contact avec une surface froide, par ex.) ou le comportement des truies à être préférentiellement en position couchée lors de température élevée.

2.3. Répétabilité des mesures corporelles

L'écart-type intra-truie et intra-observateur était de $0,39\text{ °C}$ pour la mesure de température rectale. Les écarts types pour les températures cutanées étaient de $1,64\text{ °C}$ pour l'œil, de $1,12\text{ °C}$ pour l'oreille, de $1,70\text{ °C}$ pour le dos non rasé, de $0,93\text{ °C}$ pour la vulve et de $1,20\text{ °C}$ pour la mamelle. Aucun effet de l'ordre des mesures sur les températures rectales ou cutanées n'a été démontré.

La répétabilité des mesures est globalement bonne (variation inférieure à 5 %) et doit être également reliée avec la praticité des mesures. En effet, la prise de clichés de l'œil est particulièrement compliquée pour les truies en liberté élevées en groupe. De même, selon la posture de la truie et la propreté de la salle, les zones vulve et mamelle sont plus au moins accessibles et propres. De plus, il serait intéressant pour la suite de tester la cohérence des résultats entre différents observateurs pour la phase de collecte et d'extraction à partir des clichés de la température corporelle. Cela n'a pas été possible dans cet essai puisque toutes les images étaient traitées par le même observateur.

2.4. Prédiction de la température rectale à partir de la température cutanée

2.4.1. Pour les truies primipares




Figure 5 – Température rectale prédite par le modèle C, avec uniquement les effets et interactions significatives, en fonction de la température observée pour les truies primipares

Les résultats des différents modèles de prédiction de la température rectale en fonction de la température cutanée sont rapportés dans le tableau 3. Les meilleurs modèles de

prédiction sont obtenus pour une mesure de température cutanée sur la vulve ($R^2 = 0,63$ et $RMSE = 0,23\text{ °C}$), le dos rasé ($R^2 = 0,53$ et $RMSE = 0,28\text{ °C}$), et l'oreille ($R^2 = 0,45$ et $RMSE = 0,29\text{ °C}$, Tableau 3). Comme on peut le voir sur la figure 5, les valeurs sont moins bien prédites pour des valeurs extrêmes observées (en-dessous de $37,5\text{ °C}$ et au-dessus de $38,7\text{ °C}$). Cette moindre précision peut être liée à des erreurs de prise de température rectale pour les températures basses et au fait que très peu de truies ont présenté de la fièvre pour les températures élevées.

2.4.2. Pour les truies multipares

De même que pour les truies primipares, les meilleurs modèles de prédiction de la température rectale sont obtenus pour une mesure de température cutanée sur la vulve ($R^2 = 0,55$ et $RMSE = 0,30\text{ °C}$), le dos rasé ($R^2 = 0,47$ et $RMSE = 0,43\text{ °C}$) et l'oreille ($R^2 = 0,43$ et $RMSE = 0,35\text{ °C}$, Tableau 3). Toutefois, les prédictions sont un peu moins bonnes (R^2 plus faibles et $RMSE$ plus élevées) que chez les primipares. Le manque de précision sur les valeurs extrêmes est également présent (Figure 6).

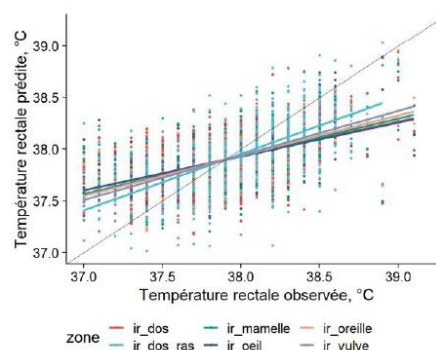


Figure 6 – Température rectale prédite par le modèle C, avec uniquement les effets et interactions significatives, en fonction de celle observée pour les truies multipares.

CONCLUSION

Cette étude montre que l'utilisation d'une caméra thermique pour prédire la température corporelle de la truie au cours de la gestation semble prometteuse, notamment à partir des mesures au niveau de la vulve ou de la base de l'oreille ou encore au niveau du dos préalable rasé. En effet, il existe des corrélations plus ou moins fortes entre les différentes zones testées au cours de l'étude et la température rectale, avec de bonnes répétabilité. Afin d'améliorer la prédiction, des modèles non linéaires pourraient être testés afin de mettre en évidence des liens plus complexes entre la température corporelle, les caractéristiques de la truie (poids, condition corporelle, parité) et les facteurs abiotiques (température et taux d'humidité de l'air), et ainsi pouvoir automatiser la mesure.

REMERCIEMENTS

Ce travail a bénéficié de bourses de mobilité sortantes de l'école doctorale EGAAL, de Rennes Métropole et de l'État gérée par l'ANR au titre du programme d'Investissements d'avenir portant la référence ANR-16-CONV-0004 (#Digitag) ; ainsi que l'aide de David RENAudeau, de Jean-Gabriel TURGEON.

2023. Journées Recherche Porcine, 55, 376-376.

Tableau 3 – Qualité de la prédiction de la température rectale de truies primipares et des multipares à partir de températures cutanées mesurées avec une caméra thermique

			P-values						R ²	RMSE
	Mod ¹		IR	THI	Pds	Pos	G	Int.		
<i>Primipares</i>										
lr_oeil	A	T = (34,6 0,1) + 0,1 IR + 0,0004 THI + 0,001 Pds + 0,3 Pos - 0,005 G	***	ns	ns	***	ns	-	0,22	0,34
lr_oreille	A	T = (32,2 0,01) + 0,2 IR - 0,02 THI - 0,001 Pds + 0,2 Pos + 0,01 G	***	**	ns	**	ns	-	0,45	0,29
lr_dos	C	-	ns	-	-	*	ns	Pos	0,29	0,32
lr_dos rasé	C	T = (38,9 0,12) - 0,1 IR - 0,0004 THI - 0,02 Pds + 0,04 G	***	ns	**	-	ns	-	0,53	0,28
lr_vulve	A	T = (27,7 0,04) + 0,3 IR - 0,001 THI - 0,001 Pds + 0,03 Pos + 0,01 G	***	ns	ns	ns	ns	-	0,63	0,23
lr_mamelle	A	T = (33,2 0,1) + 0,1 IR - 0,001 THI - 0,001 Pds + 0,21 Pos - 0,001 G	***	ns	ns	***	ns	-	0,30	0,32
Toutes zones confondues ²	A	T = (32,7 0,2) + 0,1 IR - 0,01 THI - 0,001 Pds + 0,2 Pos + 0,0001 G	***	***	ns	***	ns	-	0,33	0,30
<i>Multipares</i>										
lr_oeil	A	T = (34,1 0,2) + 0,1 IR + 0,01 THI - 0,0001 Pds + 0,1 Pos + 0,01 G	***	ns	ns	**	ns	-	0,22	0,41
lr_oreille	C	T = (19,5 0,1) + 0,5 IR + 0,6 G - 0,02 IRxG	***	-	-	-	**	G	0,41	0,35
lr_dos	A	T = (35,1 0,2) + 0,1 IR + 0,002 THI - 0,00003 Pds + 0,02 Pos + 0,02 G	***	ns	ns	ns	ns	-	0,22	0,41
lr_dos rasé	C	T = (43,3 0,2) - 0,1 IR - 0,04 Pds + 0,2 G + 0,001 IRxPds - 0,01 IRxG	0,06	-	***	-	*	Pds G	0,47	0,43
lr_vulve	C	T = (14,7 0,1) + 0,7 IR - 0,06 Pds - 0,001 IRxPds	***	-	*	-	-	Pds	0,54	0,31
lr_mamelle	A	T = (30,8 0,2) + 0,2 IR + 0,01 THI - 0,0003 Pds + 0,1 Pos + 0,02 G	***	ns	ns	**	ns	-	0,30	0,39
Toutes zones confondues ²	A	T = (34,8 0,2) + 0,1 IR - 0,005 THI - 0,001 Pds + 0,01 Pos - 0,01 G	***	*	ns	ns	ns	-	0,37	0,37

IR = température cutanée infrarouge ; Pds = Poids vifs de la truie ; Pos = posture de la truie ; G = épaisseur de gras dorsal ; Int = Interactions significatives ; THI = Temperature humidity index = $[(1,8 \times T) + 32] - \{[0,55 \times (HR/100)] \times [(1,8 \times T) + 32] - 58\}$, où T est la température de l'air en °C et HR l'humidité relative de l'air en %. R² = carré du coefficient de corrélation (plus il est élevé, plus la performance de prédiction est bonne). RMSE = écart quadratique moyen (plus il est élevé, plus les erreurs de prédiction sont grandes). ¹Modèle choisi (A, B et C) parmi les modèles linéaires mixtes (avec effet aléatoire de la truie). Les «-» correspondent aux effets non présents dans le modèle. P-values > 0,05 : ns ; < 0,05 : * ; < 0,01 : ** ; < 0,001 : *** - ²La zone étant ajoutée comme effet fixe (P < 0,001)

REFERENCES BIBLIOGRAPHIQUES

- Cook N.J., Chabit B., Lui T., Bench C.J., Schaefer A.L., 2015. Infrared thermography detects febrile and behavioural responses to vaccination of weaned piglets. *Animal*, 9, 339-346.
- Cheng R.C., 2020. Variations in the body surface temperature of sows during the post weaning period and its relation to subsequent reproductive performance. *Asian-australas. J. Anim. Sci.*, 33, 1138-1147.
- Galiot L., Cloutier L., Guay F., Dumas G., Gaillard C., Dourmad J.Y., Simongiovanni, A., Gagnon P., 2023. Impact de l'alimentation de précision et d'un surplus d'aliment en fin de gestation sur les performances et l'état corporel de truies suivies pendant leurs deux premiers cycles de gestation et lactation. *Journées Rech. Porcine*, 55, 183-188.
- Islam M.M., Ahmed S.T., Mun H.S., Bostami A.B.M.R., Kim Y.J., Yang C.J., 2015. Use of thermal imaging for the early detection of signs of disease in pigs challenged orally with *Salmonella typhimurium* and *Escherichia coli*. *Afr. J. Microbiol. Res.*, 9, 1667-1674.
- Lüdecke D., Ben-Shachar M.S., Patil I., Waggoner P., Makowski D. 2021. performance: An R Package for Assessment, Comparison and Testing of Statistical Models. *J. Open Source Softw.* 6:60, 3139.
- Malmkvist J., Pedersen L.J., Kammergaard T.S., Jorgensen E., 2012. Influence of thermal environment on sows around farrowing and during the lactation period. *J. Anim. Sci.*, 90, 3186-3199.
- Nielsen K.S., 1997. *Animal physiology – adaptation and environment*. New York Cambridge University Press.
- Ramirez B.C., 2017. A novel approach to measure, understand, and assess the thermal environment in grow-finish swine facilities. Thèse de doctorat. Iowa State Univ., United States, 198p.
- Soerensen D.D., Clausen S., Mercer J.B., Pedersen L.J., 2014. Determining the emissivity of pig skin for accurate infrared thermography. *Comput. Electron. Agric.*, 109, 52-58.
- Soerensen D.D., Pedersen L.J., 2015. Infrared skin temperature measurements for monitoring health in pigs: a review. *Acta Vet. Scand.*, 57, p
- Traulsen I., Naunin K., Müller K., Krieter J., 2010. Untersuchungen zum einatz der infrarothermographie zur messung der körpertemperatur bei sauen. *Zuchtungskunde*. 82, 437-446.
- Van Milgen J., Bernier J.F., Lecozler Y., Dubois S., Noblet J., 1998. Major determinants of fasting heat production and energetic cost of activity in growing pigs of different body weight and breed/castration combination. *Br. J. Nutr.*, 79, 509-517.
- Wegner K., Lambert C., Das G., Reiner G., Gaulty M., 2016. Effects of temperature and temperature-humidity index on the reproductive performance of sows during summer months under a temperate climate. *Anim. Sci. J.*, 87, 1334-1339.
- Wilcox S., 2007. Thermographic evaluation of metabolic changes in swine. *Thermology int.*, 17, 133-136.



Prédiction de l'activité journalière de truies gestantes à partir de créneaux ponctuels d'analyse vidéo manuelle

Maëva DURAND, Jean-Yves DOURMAD, Charlotte GAILLARD

PEGASE, INRAE, Institut Agro, 35590 Saint-Gilles, France

maeva.durand@inrae.fr

Prediction of daily activity of gestating sows from manual video analysis periods

Measuring sows' physical activity is important for predicting their nutritional requirements and can be performed using accelerometers or manual video analysis. However, accelerometers are expensive, invasive, and do not last long, while video analysis is time-consuming and cannot be done continuously. Therefore, the aims of this project were 1) to study the correlation between the activity measured continuously by accelerometers and the one estimated by video analysis over short periods, and 2) to determine whether 24 h of activity could be predicted from these video data. The data set contained individual activity measurements, from accelerometers (recorded continuously) and video analysis (two periods of 5 h per day), taken over 24 days from 38 group-housed gestating sows. Statistical analyses were performed using a generalized linear model considering the observer of the videos (5), the sow's group (4), and the hierarchical rank. Prediction of accelerometer activity using data from the video analysis explained 23-64% of the variability for the two 5 h periods per day, and 39-46% for a combined period of 10 h ($P < 0.001$). For the prediction of 24 h of activity, the explained variability ranged from 26-44%, depending on the data set used. These results indicate that the prediction of 24 h of activity is possible but needs to be improved by reducing the observer effect and perhaps by extending the duration of the video analysis.

INTRODUCTION

La mesure de l'activité physique des truies au cours de leur gestation permet de mieux prendre en compte leurs besoins énergétiques lors du calcul des rations, mais aussi de surveiller leur état de santé ou physiologique (Escalante *et al.*, 2013). Les accéléromètres sont des outils pertinents pour notamment mesurer l'activité des animaux, mais peu robustes, coûteux et difficiles à mettre en œuvre en élevage porcin (Chapa *et al.*, 2020). L'analyse vidéo manuelle permet également de mesurer l'activité mais elle est extrêmement chronophage. Cette étude a pour but de prédire le temps journalier (24h) passé debout, comme mesuré par les accéléromètres, à partir d'analyses vidéo manuelles réalisées sur des créneaux de 5 heures.

1. MATERIEL ET METHODES

1.1. Données expérimentales

L'étude a porté sur 38 truies gestantes, croisées Large White x Landrace, issues de quatre bandes et logées en groupe à l'Unité Expérimentale Physiologie et Phénotypage des Porcs (UE3P, INRAE, 35 ; <https://doi.org/10.15454/1.5573932732039927E12>). Les truies étaient équipées chacune d'un accéléromètre fixé à l'oreille (RF-Track, Rennes, France) et filmées en continu par des caméras (Ro-main Inc., Québec, Canada). Ces vidéos ont été analysées par cinq expérimentatrices entraînées, sur deux créneaux de 5 heures (PM : de 13h30 à 18h30, niveau d'activité élevé ; Nuit : de 23h00 à 4h00, niveau d'activité plus faible) sur 24 jours. Les jours analysés intègrent des périodes sans et avec

des « évènements » (10 jours « témoins » vs 14 jours « évènements ») susceptibles d'affecter l'activité physique des truies : conditions thermiques chaudes et froides, compétition alimentaire, émissions aléatoires de sons.

1.2. Analyses statistiques

Les analyses statistiques ont été réalisées sur les 250 individus statistiques (couple « truies x jour ») à l'aide du logiciel R studio (version 4.1.2., R Core Team, 2022). Le jeu de données a été divisé en deux parties : les jours témoins (37 %) et les jours évènements (63 %). Les analyses ont été réalisées sur les deux jeux de données séparés et combinés. Initialement un modèle linéaire généralisé a été utilisé afin de prédire le temps passé debout mesuré par les accéléromètres à partir de l'activité mesurée par les vidéos, en prenant en compte l'observateur (cinq modalités), la bande de truies (quatre modalités) et le rang hiérarchique (calculé à partir de l'ordre de passage au DAC selon Lanthony *et al.*, 2022), ainsi que leurs interactions avec le temps debout issu des vidéos. Trois modèles ont été construits : (A) ne comprenant que les effets fixes, (B) avec les effets fixes et interactions, et (C) avec uniquement les effets et interactions significatifs. Le meilleur modèle a été choisi à partir du package « performance » (Lüdtke *et al.*, 2021), en fonction de multiples indices de qualité et de prédiction (coefficient de détermination - R^2 , écart quadratique moyen - RMSE, coefficient de corrélation intra-classe).

2. RESULTATS

2.1. Prédiction de l'activité sur des créneaux de 5 heures

2023. Journées Recherche Porcine, 55, 74-74.

2.1.1. A partir du jeu de données témoin

Sur les créneaux Nuit et PM, le meilleur modèle de prédiction des 5 h d'activité mesurées par les accéléromètres à partir des analyses vidéo du jeu de données témoin est le B ($R^2 = 64$ et 35 % respectivement, $P < 0,001$; Tableau 1) en prenant comme effets fixes l'observateur ($P = 0,67$ et $0,01$ respectivement pour Nuit et PM), la bande ($P = 0,13$ et $0,008$), le rang hiérarchique ($P < 0,01$) et leurs interactions avec l'analyse vidéo ($P > 0,05$).

Tableau 1 – Coefficient de détermination (R^2), effets fixes et interactions intégrés dans les meilleurs modèles de prédiction à partir des créneaux d'analyses vidéo ($P < 0,001$)

Créneau horaire	Jeu de données	R^2 (%)	Effets fixes	Interactions
5 h Nuit	Témoin	64	O, B, H	AxO + AxB + AxH
5 h Nuit	Évènement	47	O, H	-
5 h PM	Témoin	35	O, B, H	AxO + AxB + AxH
5 h PM	Évènement	23	O, B, H	AxO
10 h (Nuit + PM)	Témoin	46	B, H	AxH
10 h (Nuit + PM)	Évènement	39	O, B, H	AxH
24 h	Témoin	44	H	-
24 h	Évènement	26	O, B, H	AxO + AxB + AxH

O : Observateur, B : Bande et H : rang hiérarchique. PM : 13h30-18h30. A : Temps passé en position debout issu des analyses vidéo.

2.1.2. A partir du jeu de données évènement

Sur le créneau Nuit, le meilleur modèle de prédiction des 5 h d'activité mesurées par les accéléromètres à partir des analyses vidéo du jeu de données évènement est le C ($R^2 = 47\%$, $P < 0,001$) en prenant comme effets fixes l'observateur ($P = 0,002$) et le rang hiérarchique ($P < 0,001$). Sur le créneau PM, le meilleur modèle de prédiction est le B ($R^2 = 23\%$, $P < 0,001$) en prenant comme effets fixes l'observateur ($P = 0,69$), la bande ($P < 0,001$), le rang hiérarchique ($P = 0,001$) et l'interaction de l'analyse vidéo avec l'observateur ($P = 0,01$).

2.2. Prédiction de l'activité sur des créneaux de 10 heures

Sur les jeux de données témoin et évènement, le meilleur modèle de prédiction des 10 h d'activité mesurées par les accéléromètres à partir des analyses vidéo sur les créneaux Nuit et PM est le C ($R^2 = 46$ et 39% , $P < 0,001$). Avec le jeu de données témoin, le modèle comprend comme effets fixes la bande ($P = 0,002$), le rang hiérarchique ($P = 0,05$), et leur interaction

($P = 0,002$). Avec le jeu de données évènement, le modèle comprend en effets fixes l'observateur ($P = 0,001$), la bande ($P = 0,02$), le rang hiérarchique ($P < 0,001$) et l'interaction de l'analyse vidéo avec le rang hiérarchique ($P = 0,07$). Sur les jeux de données témoin et évènement, l'effet de l'observateur sur le temps passé en position debout sur 10 h est significatif ($P = 0,01$), avec une différence significative seulement entre les observateurs 1 (17 % du jeu de données) et 5 (60 % du jeu de données, $P = 0,04$).

2.3. Prédiction de l'activité sur une journée

Sur les jeux de données témoin et évènement, le meilleur modèle de prédiction des 24 h d'activité mesurées par les accéléromètres à partir des analyses vidéo sur les créneaux Nuit et PM regroupés est le C ($R^2 = 44$ et 26% respectivement, $P < 0,001$) en prenant comme effets fixes le rang hiérarchique ($P < 0,05$). Le modèle pour le jeu de données témoin prend aussi en compte l'interaction de l'analyse vidéo avec le rang ($P < 0,001$) et celui pour le jeu de données évènement tous les effets fixes et leurs interactions ($P < 0,05$).

3. DISCUSSION ET CONCLUSION

Les performances des modèles de prédiction du temps passé debout (mesuré par les accéléromètres) à partir d'analyses de vidéo sont globalement satisfaisantes que ce soit sur des créneaux similaires (de 5 ou 10 h), ou pour prédire des créneaux plus vastes (24 h) que ceux observés via les vidéos. Cependant, elles sont meilleures dans le jeu de données témoin par rapport au jeu de données évènement qui intègre plus de variabilité entre les truies. L'effet observateur semble être un facteur de biais sur la répétabilité des analyses vidéo (Volkman *et al.*, 2021). Il faudrait automatiser l'analyse des vidéos à l'échelle individuelle, un projet en cours qui a pour l'instant de bons résultats à l'échelle du groupe (Durand *et al.*, 2022). De plus, une étude de Marcon *et al.* (2017) a montré que la spécificité et la sensibilité des accéléromètres n'étaient respectivement que de 76 et 68 %. Ces deux méthodes sont donc perfectibles. L'utilisation d'une méthode automatique d'analyse de vidéos permettrait également l'analyse de créneaux plus longs voire en continu de l'activité individuelle.

REMERCIEMENTS

Ce travail a bénéficié d'une aide financière de l'État gérée par l'ANR au titre du programme d'Investissements d'avenir portant la référence ANR-16-CONV-0004

REFERENCES BIBLIOGRAPHIQUES

- Chapa J.M., Maschat K., Iwersen M., Baumgartner J., Drillich M., 2020. Accelerometer systems as tools for health and welfare assessment in cattle and pigs – A review. *Behav. Processes*, 181, 104262.
- Durand M., Simon M., Foisil J., Dourmad J.Y., Largouët C., Gaillard C., 2022. Evaluation of the physical activity of a group of gestating sows using an artificial neural network. *Book of Abstracts of the 73rd Annual Meeting of the European Federation of Animal Science*, Porto, Portugal, pp. 455.
- Escalante H.J., Rodriguez S.V., Cordero J., Kristensen A.R., Cornou C., 2013. Sow-activity classification from acceleration patterns: a machine learning approach. *Comput. Electron. Agric.*, 93, 17-26.
- Lüdecke D., Ben-Shachar M.S., Patil I., Waggoner P., Makowski D., 2021. performance: an R package for assessment, comparison and testing of statistical models. *J. Open Source Softw.*, 6(60), 3139.
- Lanthon M., Durand M., Guerin C., Gaillard C., Tallet C., 2022. Hiérarchie dans les groupes de truies gestantes : méthodes de calcul, caractéristiques et lien avec les données d'alimentation. *Journées Rech. Porcine*, 54, 257-262.
- Marcon M., Meunier-Salaün M.C., Le Mer M., Rousselière Y., 2017. Accelerometer technology to perform precision feeding of pregnant sows and follow their health status. *Proc. of the 8th European Conference on Precision Livestock Farming*. Nantes, France. pp. 666-673.
- R Core Team, 2022. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria.
- Volkman N., Brünger J., Zelenka C., Stracke J., Koch P., Kemper N., Spindler B., 2021. 'It's a long way until they STOP' – development of a software to annotate pecking injuries in turkeys. *Book of Abstracts of the 72nd Annual Meeting of the European Federation of Animal Science*, Davos, Switzerland, pp. 388.



RÉPUBLIQUE FRANÇAISE

Liberté
Égalité
Fraternité



M. DURAND,
J.Y. DOURMAD, C. GAILLARD
PEGASE, INRAE, Institut Agro,
35590 Saint Gilles, France
maeva.durand@inrae.fr



➤ Prédiction de l'activité journalière de truies gestantes à partir de créneaux ponctuels d'analyse vidéo manuelle

➤ CONTEXTE ET OBJECTIF

- Importance de la prise en compte de l'activité pour :
 - Estimer les besoins énergétiques pour calculer les rations
 - Surveiller l'état de santé ou physiologique

→ Nécessité d'outils précis et robustes

Objectif : Prédire le temps passé debout sur 24h (initialement mesuré par les accéléromètres) à partir d'analyses vidéo manuelles réalisées sur des créneaux de 5 heures.

➤ CONCLUSION

- Performances de prédiction relativement satisfaisantes
 - Meilleurs résultats sur les jours témoins par rapport aux évènements
 - Biais observateur lors analyse vidéo
- automatisation nécessaire



➤ MATÉRIELS ET MÉTHODES

Mesures d'activité via :




Jeux de données :
250 individus statistiques (couple « truie x jour »)

37 % Jours **témoin** 63 % Jours **évènements***

* Susceptibles d'affecter l'activité physique (chaud, froid, compétition alimentaire, émissions de sons).

Modèles linéaires généralisés :





Effets fixes
Observateur (O)
Bande (B),
Rang hiérarchique (H)

Interactions
(doubles)
Entre chaque effet fixe (Ax...)

Choix du modèle
meilleur R², RMSE,
coefficient de corrélation intra-classe

➤ RÉSULTATS



- La prédiction sur le **créneau de 5h Nuit** montre de meilleurs résultats que le créneau PM (R² supérieur de 29 et 24 points sur respectivement le témoin et l'évènement).
 - Sur la **journée**, le R² est de respectivement 44 et 26 % pour le témoin et l'évènement.
 - L'effet fixe **Rang hiérarchique (H)** est présent et significatif dans tous les meilleurs modèles (P < 0,05).

Effets fixes et interactions présentes dans les modèles de prédiction pour les créneaux de 5h, 10h et 24h.

	5h Nuit		5h PM		10h (Nuit + PM)		24h	
	Témoin	Evénements	Témoin	Evénements	Témoin	Evénements	Témoin	Evénements
Effets fixes	O + B + H	O + H	O + B + H	O + B + H	B + H	O + B + H	H	O + B + H
Interactions	AxO + AxB + AxH	-	AxO + AxB + AxH	AxO	AxH	AxH	-	AxO + AxB + AxH



Annexe F : Congrès des JRP, 2022

2022. Journées Recherche Porcine, 54, 151-152.

Comportement de truies gestantes en situation de compétition alimentaire

Maëva DURAND et Charlotte GAILLARD

PEGASE, INRAE, Institut Agro, 35590 Saint-Gilles, France

charlotte.gaillard@inrae.fr

Behaviour of gestating sows in a competitive situation for feed

Aggressive behaviours and adaptations of sows to sudden events during gestation could influence their nutritional requirements. The purpose of this study was to evaluate the impact of induced feed competition on the activity and social behaviour of gestating sows. The experiment included 31 sows, observed during the first 36 h of a “baseline” period (i.e. two feeders available in the pen) and a “test” period, in the following week, with induced feed competition (i.e. closing one of the two feeders). Skin lesions were visually recorded every week. Feeding behaviour was automatically recorded by the feeders. Video recordings allowed observers to manually identify continuously each sow’s position, occupation, and social interactions. The influence of the period (baseline vs test) and parity (primiparous vs multiparous) on these measurements was analysed using RStudio by applying a linear mixed-effects model that considered sows as a random effect. The number of non-feeding visits to the feeder was lower during the test period than during the baseline period (2.3 vs 4.7 visits/d, respectively; $P < 0.01$), while the number of feeding visits did not differ between periods (1.1 visit/d). Sows stood in front of the feeder longer during the test period than during the baseline period (98.5 vs 40.1 min/d, respectively; $P < 0.01$). Despite more negative social interactions during the test period (i.e. head butts and bites, $P < 0.01$), the number of skin lesions did not differ between periods. To conclude, the physical activity, and feeding and social behaviours were influenced by feed competition and led to a mean increase of 5% in energy requirements of gestating sows.

INTRODUCTION

En Europe, depuis 2013, les truies doivent être logées en groupe au cours d’une période de leur gestation. Cela permet l’expression de comportements sociaux naturels comme la mise en place d’une hiérarchie qui régit fortement l’accès aux ressources du logement tels que l’espace et l’alimentation. Ainsi, lorsque les truies sont logées en groupe, elles dépensent de l’énergie et du temps pour accéder à l’aliment et à l’espace disponible (Spoolder et Vermeer, 2015). Le niveau d’agressivité des truies entre elles devient ainsi un paramètre important à surveiller. S’il est trop élevé, il peut avoir un effet négatif sur les performances de reproduction, le bien-être et la santé des truies (Brajon *et al.*, 2019). L’utilisation de distributeurs automatisés d’aliments (DAC) permet de délivrer une ration de manière individualisée, rendant possible la régulation des apports d’aliments aux besoins nutritionnels individuels (Gaillard *et al.*, 2021), et aussi l’observation du comportement alimentaire des truies. L’objectif de ce travail était d’évaluer l’impact d’un test de compétition alimentaire sur l’activité physique et le comportement de truies gestantes, dans la perspective d’ajuster par la suite les calculs des besoins nutritionnels.

1. MATERIEL ET METHODES

1.1. Dispositif expérimental

L’expérimentation a inclus 31 truies gestantes croisées Large White x Landrace entre la 3^{ème} et la 6^{ème} semaine de gestation,

dont 23 multipares, issues de deux bandes de truies de la station expérimentale UE3P Saint-Gilles (INRAE, France). Chaque bande était logée dans une salle de 7,2 m par 8,2 m, au sol plein béton légèrement paillé, équipée de deux DAC Gestal® (Jyga Technologies Inc., Québec, Canada) et deux abreuvoirs connectés (Asserva, Lamballe, France). Les besoins nutritionnels ont été calculés pour chaque truie à partir du modèle développé par Gaillard *et al.* (2019). La ration était composée d’un mélange journalier et individuel de deux aliments aux teneurs en lysine digestible différentes (3,3 vs 8,5 g/kg) pour une valeur énergétique métabolisable de 13,1 MJ/kg. La quantité distribuée était ajustée pour chaque truie mais fixe au cours de la gestation. La compétition alimentaire a été induite en fermant l’accès à l’un des deux DAC de chaque salle pendant 5 jours (période test). La semaine précédente dite « basale » a servi de période de référence (sans modification de l’environnement d’élevage).

1.2. Mesures expérimentales

Deux caméras (conception Ro-Main Inc., Québec, Canada) par salle ont enregistré en continu des vidéos des truies des deux bandes. Des analyses manuelles à l’aide du logiciel Observer (Noldus, Wageningen, Pays-Bas) ont été réalisées sur les 36 premières heures de chaque période par deux examinateurs formés. Pour chaque truie, sa posture (couchée, assise, debout, marche), son occupation (boit, observe, explore), sa localisation dans la salle et ses interactions sociales (positives ou négatives) ont été relevées. La sévérité et le nombre de lésions cutanées ont également été dénombrés à l’issue de chaque période. Les

2022. *Journées Recherche Porcine*, 54, 152-152.

données enregistrées par les DAC au moment d'une visite ont permis le calcul du temps passé dans ceux-ci, du nombre de visites et de la quantité d'aliment consommée.

1.3. Analyses statistiques et calculs

Les analyses statistiques ont été réalisées à l'aide du logiciel RStudio (version 4.0.3). Un modèle linéaire mixte a été utilisé avec la période (basale vs test), la parité (primipare vs multipare) et la bande en effets fixes et en incluant l'effet aléatoire de la truie. Les besoins en énergie métabolisable (EM) liés à l'activité ont été estimés à partir de la référence établie pour la posture debout à 0,30 kJ EM.kg^{-0,75}.min⁻¹ (Noblet *et al.*, 1993 ; Dourmad *et al.*, 2008).

2. RESULTATS ET DISCUSSION

2.1. Comportement alimentaire

Au niveau collectif, pendant la période test les truies ont prolongé leur période d'alimentation (débutant à 00h00) comparé à la période basale (fin vers 11h vs. 05h respectivement, $P < 0,01$). Au niveau individuel, le nombre de visites alimentaires n'a pas été affecté par la période (en moyenne 1,1 visite/jour, $P = 0,50$) ce qui est probablement lié au rationnement des truies qui consomment généralement leur ration en une seule fois (Gaillard *et al.*, 2021). Le nombre de visites non-alimentaires (sans consommation d'aliment) a été divisé par deux lors de la période test comparé à la période basale (2,3 vs 4,7 visites/jour/truie, $P < 0,01$). Cette réduction est directement en lien avec l'augmentation du nombre de truies par DAC (passage de 7-8 à 15-16 truies par DAC selon la bande). Cependant ce ratio en semaine test reste acceptable par rapport aux recommandations de Ramonet *et al.* (2009) qui est d'une cinquantaine de truies par DAC.

Les multipares ont effectué plus de visites non-alimentaires que les primipares (4,6 vs 2,8 visites/jour/truie, $P = 0,03$). Ce résultat va à l'encontre de ceux trouvés dans la littérature, faisant état d'une plus grande curiosité des primipares (Ramonet *et al.*, 2009). Il peut cependant s'expliquer par le rang hiérarchique des multipares, généralement plus élevé que les primipares, qui conditionne la facilité d'accès à la ressource alimentaire ici le DAC (Spoolder et Vermeer, 2015).

2.2. Activité physique et les besoins nutritionnels

La parité n'a pas eu d'effet sur la durée des activités. Le temps passé assis ou en marche n'a pas été affecté par la période. En période test, le temps passé en position couchée a diminué lors de la période d'alimentation comparé à la période basale. En moyenne, chaque truie a réduit d'environ 55 min/j son temps

passé en position couchée ($P < 0,01$) et augmenté son temps d'attente debout devant le DAC en période test comparé à la période basale (98,5 vs 40,1 min/jour/truie, $P < 0,01$). Cette augmentation du temps passé debout se traduit par un besoin journalier accru de 1132 kJ EM pour une truie de 250 kg, soit 5% des besoins énergétiques d'entretien calculés pour un temps moyen debout de 4 h par jour (Dourmad *et al.*, 2008). Pour couvrir les besoins énergétiques associés à presque 1 heure supplémentaire de position debout, il faudrait un apport supplémentaire de 87 g pour un aliment formulé à 13 MJ EM/kg. Cependant, ce résultat est à mettre au regard de la précision du DAC, ici à 50 g.

2.3. Comportements sociaux

La parité n'a pas eu d'effet sur le nombre de comportements sociaux négatifs. La sévérité et le nombre de lésions cutanées n'ont pas été affectés par la période ($P = 0,23$). Étonnamment, le nombre d'interactions négatives entre les truies a augmenté en période test par rapport à la période basale (22,3 vs 6,9 interactions négatives/truie, $P < 0,01$) notamment autour du DAC : incluant les coups de têtes (7,8 vs 3,0, $P < 0,01$), les bousculades (5,6 vs 2,2, $P < 0,01$) et les comportements de fuite (4,9 vs 2,1, $P < 0,01$). Il semblerait ainsi que les truies ont exercé plus de comportements d'intimidation ou de fuite que d'agressions. L'augmentation d'une tension sociale due à l'accessibilité à la ressource alimentaire est fréquemment observée dans les études (Spoolder et Vermeer, 2015).

CONCLUSION

L'induction d'une compétition alimentaire au sein d'un groupe de truies gestantes peut entraîner un temps passé en position debout accru et des interactions sociales négatives exacerbées, induisant une augmentation moyenne des besoins énergétiques de 5% sur les 36 premières heures de la compétition. Ainsi, même s'il est dans la gamme des recommandations, le nombre de truies par alimentateur reste un paramètre important à prendre en compte, au regard du niveau d'agressivité des truies et de la gestion de l'élevage. La prochaine étape de ce travail est de poursuivre l'analyse vidéo sur les jours suivants et au cours d'une répétition quelques semaines plus tard afin de vérifier si l'augmentation des besoins énergétiques reste stable à 5%.

REMERCIEMENTS

Ce travail a bénéficié d'une aide de l'État gérée par l'ANR au titre du programme d'Investissements d'avenir portant la référence ANR-16-CONV-0004 et du département PHASE d'INRAE.

REFERENCES BIBLIOGRAPHIQUES

- Brajon S., Ahloy-Dallaire J., Devillers N., Guay F., 2021. Social status and previous experience in the group as predictors of welfare of sows housed in large semi-static groups. *PLoS ONE*, 16.
- Dourmad J.Y., Etienne M., Valancogne A., Dubois S., van Milgen J., Noblet J., 2008. InraPorc: A model and decision support tool for the nutrition of sows. *Anim. Feed Sci. Technol.*, 143, 372-386.
- Gaillard C., Gauthier R., Cloutier L., Dourmad J.-Y., 2019. Exploration of individual variability to better predict the nutrient requirements of gestating sows. *J. Anim. Sci.*, 97, 4934-4945.
- Noblet J., Shi X.S., Dubois S., 1993. Energy cost of standing activity in sows. *Livest. Prod. Sci.*, 34, 127-136.
- Ramonet Y., Chopin E., Caille M.E., Dubois A., 2009. Loger les truies en groupes au DAC : Différencier les zones de vie pour un aménagement réussi. *TechniPorc*, 32(6), 3-8.
- Spoolder H.A.M., Vermeer H.M., 2015. Gestation group housing of sows. In: Farmer C. (Ed), *The gestating and lactating sow*, 47-72. Wageningen Academic Publishers, The Netherlands.

Comportement de truies gestantes en situation de compétition alimentaire

CONTEXTE ET OBJECTIF

Les comportements agressifs et les adaptations aux évènements soudains des truies au cours de la gestation peuvent influencer leurs besoins nutritionnels. **L'objectif** est donc d'évaluer l'impact d'un test de compétition alimentaire sur l'activité physique et le comportement de truies gestantes.



MATÉRIELS ET MÉTHODES



Modèle linéaire mixte

- Effets fixes (Période, rang, bande)
- Effet aléatoire de la truie


$$y_{ij} = \mu + \alpha_i + \beta_j + \gamma_k + \epsilon_{ijk}$$

Calcul des besoins d'énergie métabolique liés à l'activité :
0,30 kJ EM. Kg^{-0,75}.min⁻¹



RÉSULTATS

Variabilité du temps passé en position couchée sur 36h



Effet de la période sur l'activité physique :

- Augmentation du temps en position debout (P < 0,01)
- Diminution du temps en position couchée (P < 0,01)

Par jour	Période		P-value	Rang		P-value
	Basale	Test		1	≥ 2	
Nb de visites alimentaires	1,1	1,1	0,27	1,0	1,2	0,50
Nb de visites non alimentaires	4,7	2,3	<0,01	2,8	4,6	0,03
Temps visites alimentaires (min/j)	33,3	38,3	0,11	29,6	38,0	0,37
Temps visites non alimentaires (min/j)	30,3	17,0	0,04	23,0	25,4	0,65


Effet de la période sur le comportement alimentaire :

- Diminution du nombre de visites non alimentaire (+ effet du rang de portée)
- Extension de la période d'alimentation (P < 0,01)

Activité (min/jour)	Période		P-value
	Basale	Test	
Investiguer le DAC (debout)	40,1	98,5	<0,01
Investiguer le sol	109,9	124,4	0,59
Observer	188,47	176,9	0,50
Dormir	1044,9	985,1	0,07
Interaction (nb/jour)			
Interactions positives	33,8	31,6	0,42
Interactions négatives	6,9	22,3	<0,01
Coups de tête	3,0	7,8	<0,01
Bousculades	2,1	4,9	<0,01
Comportement de fuite	2,2	5,6	<0,01

Effet de la période sur le comportement social :

- Augmentation de l'investigation du DAC
- Augmentation des tensions sociales
- Absence d'effet sur les lésions cutanées (P = 0,23)



Effet de la période sur les besoins nutritionnels :

- + 55 min/j en position debout lors compétition alimentaire
- + 5% de besoins énergétiques d'entretien

CONCLUSION

- ✓ Augmentation moyenne des **besoins énergétiques** de 5% sur les 36^{ères} heures
- ✓ Exacerbation des **interactions sociales** agonistiques
- ✓ Nombre de truies par alimentateur : paramètre important à prendre en compte
- ✓ Prochaine étape : étude de l'adaptation des truies lors d'une **répétition**

Titre : Alimentation sur mesure et estimation du bien-être des truies gestantes à partir de données hétérogènes

Mots clés : comportement, apprentissage automatique, capteurs, automate d'alimentation, variabilité individuelle

Résumé : Les nouvelles technologies se développent en élevage porcin, afin d'aider le travail des agriculteurs. Elles permettent la distribution d'une alimentation sur mesure pour des truies gestantes et une meilleure surveillance du comportement des animaux. La problématique de cette thèse est d'améliorer l'estimation des besoins nutritionnels journaliers et d'identifier l'état de bien-être individuel des truies gestantes, à l'aide de données comportementales et environnementales. Le premier objectif s'est intéressé à l'évaluation des effets des perturbations environnementales sur le comportement et les besoins nutritionnels. Pour cela, deux bandes de truies ont été suivies lors de deux gestations consécutives durant lesquelles différents événements ont été

provoqués. Les résultats ont permis de mettre en évidence l'influence des conditions environnementales sur le comportement et les besoins nutritionnels des truies au cours de leur gestation, et ont permis d'identifier une forte variabilité individuelle. Dans une deuxième partie, il s'agissait d'estimer individuellement les besoins journaliers et le bien-être, à partir des données comportementales et environnementales enregistrées par des capteurs. Les résultats ont montré que cette estimation peut être réalisée de façon précise grâce à différents algorithmes de machine learning sur des données produites par l'automate d'alimentation. Cette thèse propose donc des méthodes innovantes pour la conception d'un outil d'aide à la décision visant à améliorer l'alimentation sur mesure et le bien-être des truies gestantes.

Title: Precision feeding and welfare estimation of gestating sows based on heterogeneous data.

Keywords: behaviour, machine learning, sensors, feeding automatons, individual variability

Abstract: New technologies are developing increasingly in pig farming, to help farmers in their labour tasks. They allow the distribution of tailored diets for gestating sows and better animal behaviour monitoring. The issue of this thesis is to improve the estimation of daily nutritional requirements and estimate the individual welfare status of gestating sows using behavioural and environmental data collected automatically. The first aim was to evaluate experimentally the effects of environmental disturbances on behaviour and nutritional requirements. To achieve this, two groups of sows were followed during two consecutive gestations during which several events were induced. A database containing a variety of

sows' behavioural data was built from these experiments. The results of the thesis highlighted the influence of environmental conditions on the behaviour and nutritional requirements of sows during gestation, as well as an important individual variability. The second part involved estimating individual daily requirements and welfare based on behavioural and environmental data recorded by sensors. The individual estimation of nutritional requirements and state of welfare can be carried out accurately using machine learning algorithms and data produced by the automatic feeder. Using these innovative methods, this thesis opens potential for the design of a decision-support tool aiming at adjusting feeding and improving the welfare of gestating sows.