



HAL
open science

Demand response for cold room: energy performance analysis using black box and physical modelling approaches

Mahdjouba Akerma

► **To cite this version:**

Mahdjouba Akerma. Demand response for cold room: energy performance analysis using black box and physical modelling approaches. Chemical and Process Engineering. Sorbonne université, 2019. English. NNT: . tel-04575061

HAL Id: tel-04575061

<https://hal.inrae.fr/tel-04575061>

Submitted on 14 May 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.

Sorbonne Université

Ecole doctorale n°391

Sciences mécanique, acoustique, électronique et robotique de Paris

Irstea FRISE

Impact énergétique de l'effacement dans un entrepôt frigorifique - Analyse des approches systémiques : boîte noire / boîte blanche

Par Mahdjouba AKERMA

Thèse de doctorat de génie des procédés

Dirigée par Anthony DELAHAYE

Présentée et soutenue publiquement le 04 février 2019

Devant un jury composé de :

Mme. Nathalie MAZET	Directeur de recherche CNRS	Rapporteur
Mme. Myriam LAMOLLE	Professeur IUT Montreuil	Rapporteur
M. Philippe GUIBERT	Professeur Sorbonne Université	Examineur
M. Denis LEDUCQ	Ingénieur de recherche IRSTEA	Examineur
Mme. Hong Minh HOANG	Chargée de recherche IRSTEA	Examinatrice
M. Anthony DELAHAYE	Directeur de recherche IRSTEA	Examineur
Mme Nedra MELLOULI-NAUWYNCK	Maitre de conférence Paris 8	Examinatrice

Irstea

Institut national de recherche en sciences et
technologie pour l'environnement et l'agriculture

Génie des procédés frigorifiques d'Antony

1, rue Pierre-Gilles de Gennes

CS 10030

92761 Antony cedex

Sorbonne Universités

Ecole doctorale SMAER (ED 391)

Sciences mécaniques acoustiques
électroniques et robotiques de Paris

4, place Jussieu

BC 270

75252 Paris cedex 05

Remerciements

Les travaux présentés dans cette thèse ont été réalisés au sein de l'unité « Génies des procédés frigorifiques » de l'Institut National de Recherche en Sciences et Technologies pour l'Environnement et l'Agriculture, situé sur le site d'Antony.

Je voudrais tout d'abord remercier grandement Madame Laurence FOURNAISON, ancienne directrice de l'unité FRISE, pour son accueil chaleureux, son soutien et ses orientations.

Mes sincères remerciements vont à mon directeur de thèse, Monsieur Anthony DELAHAYE, pour toute l'aide qu'il a su m'apporter au cours de ces trois dernières années. Je le remercie pour son soutien dans les épreuves difficiles, ses conseils judicieux mais aussi ses critiques constructives qui ont contribué à alimenter ma réflexion. Je te remercie pour tous.

Je voudrais témoigner toute ma gratitude à Madame Hong Minh HOANG, mon encadrante. Je tiens à exprimer ma reconnaissance pour son immense gentillesse, sa disponibilité et sa compréhension. Tous ses conseils m'ont énormément aidé à progresser. Je te remercie du fond du cœur.

À Monsieur Denis LEDUCQ, mon encadrant, je témoigne également ma profonde gratitude pour son aide, sa confiance et son soutien inestimables tout au long de cette thèse.

Mes chaleureux remerciements vont aussi à Madame Nedra MELLOULI-NAUWYCNK, qui m'a tant aidé, soutenu et appris. Je ne la remercierai jamais assez pour tout ce qu'elle m'a donné.

Je voudrais remercier Madame Nathalie MAZET, Directeur de recherche CNRS et Madame Myriam LAMOLLE, Professeur à l'IUT de Montreuil, pour l'honneur qu'ils m'ont fait d'avoir accepté de juger ce travail de thèse.

Je remercie également Monsieur Philippe GUIBERT, Professeur à Sorbonne Université, d'avoir bien voulu être membre de mon jury de thèse.

A toute l'équipe FRISE, je témoigne ma sympathie et mon amitié indéfectible. Merci pour la joie procurée, les instants de bonheur partagés, les pauses tarot où j'ai souvent gagné, les encouragements lorsque j'avais des coups de blues, les coups de main pour surveiller les manips et les conseils pour mener à bien cette thèse.

Merci à Maman Graciela ALVAREZ pour m'avoir accueilli au sein d'IRSTEA en stage. Merci de m'avoir encouragé à postuler à cette thèse et soutenu à chaque épreuve. Pour ta confiance et ta sincérité, du fond de mon cœur, merci !

Je souhaite rendre hommage à Monsieur Christophe JOUQUIN, qui nous a quitté trop tôt. On dit toujours, que les braves partent en premier. A l'homme investi que tu fus, par ta rigueur et ton engagement à faire fonctionner tout ce qui ne voulait plus marcher, pour le bonheur de nous tous, merci !

Merci à toute l'équipe de techniciens qui ne comptent pas leurs efforts et sans qui ce travail ne serait pas accompli. Merci à Alain DENIS, Jérôme GAHARTIAN, Romuald HUNLEDE, Sébastien SAAVEDRA, et Alain THOMAS pour votre aide.

Un remerciement particulier va à Elyamin DAHMANA pour son aide précieuse et son investissement dans la mise au point de mon dispositif expérimental et dans les expérimentations.

Une dédicace spéciale pour mes chers amis Doctorants : Ronia, Amokrane, Amira, Mona, Ana, Victor, Fatima, Oscar.

Un remerciement spécial va à Amira avec qui j'ai passé de très bons moments dans le bureau.

Un grand Merci à Steven DURET qui est toujours disponible à répondre à mes différentes questions. Merci également à Pascal CLAIN de m'avoir fait découvrir le domaine de l'enseignement.

Mes remerciements vont aussi à Véronique OSSWALD, Fatou-Toutie NDOYE avec lesquelles j'ai passé des moments de pur bonheur et aussi de m'avoir aidé à choisir mes talons pour la robe de mariée ☺.

Merci à Evelyne DERENS qui est pour moi une femme en or avec beaucoup d'humanisme. Merci à la meilleure secrétaire Sylvie CARLINI ☺ pour sa disponibilité. Enfin, je remercie Stéphanie LACOUR, ma voisine de bureau, avec laquelle j'ai partagé des petits moments de discussion.

Aux miens,

Je dédie cette thèse à **Ma chère et tendre grand-mère**, Source inépuisable de tendresse, de patience et de sacrifice. Aux nuits blanches que tu as passé à prendre soin de moi, à tes encouragements sans limite et à l'Amour que tu m'as donnée sans compter. Tu avais à cœur de me voir réussir, même si pour cela il fallait accepter la dure réalité de la séparation, de l'exil. Tu m'as montrée la voix, le bon chemin et grâce à toi, j'en suis là aujourd'hui. Que ta bénédiction m'accompagne encore et toujours, je t'aime Chichi.

À mes parents, puisse Dieu vous accorder santé, bonheur et longue vie. A mes chers frères et leurs familles qui ont pu, malgré la distance, être toujours présent à mes côtés.

À Michati & Tonton qui ont cahin-caha supporté tous mes retards ☺. A leur soutien continu et leur motivation. Je leur suis très reconnaissante.

À tous mes cousins et cousines avec qui je partage des moments de joie.

À mes amis de toujours : Lamia, Said, Sarah, Lynda, Rabiha, Emilia, Fadhma, Amel, Tamiro, Mehdi, Chérif, Samia, Lilia.... avec qui je passe d'agréables moments.

À mon grand-père Vayi qui s'est toujours soucié de moi et n'a jamais cessé de me soutenir et de m'encourager.

A toi, ma moitié féminine Lolatti, qui sait toujours comment me rendre heureuse et au soutien que tu m'apportes à chaque fois.

Pour finir, Je tiens à remercier chaleureusement mon mari, Yacine, pour sa patience, sa protection, l'Amour pur et l'affection qu'il me porte. J'ai vraiment de la chance de t'avoir. Je t'aime énormément...Et tu le sais ☺

J'ai mis tout mon cœur dans ce que j'ai fait, j'ai mis tout mon amour dans tout ce que j'ai dit

Résumé

Les entrepôts frigorifiques et chambres froides forment, de par l'inertie thermique de la masse des produits, une source importante de stockage thermique rapidement accessible et fortement attractive pour répondre aux besoins d'effacement électrique. Cependant, le risque pour le produit lors des fluctuations de température liées aux périodes d'effacement et la crainte d'une surconsommation énergétique, limitent le recours aux effacements par les industriels et acteurs du froid alimentaire. Cette thèse vise à caractériser l'effacement électrique des entrepôts en apportant un éclairage sur le comportement thermique d'un système, en termes de fluctuation de température et de consommation électrique. Une étude expérimentale a été mise en œuvre afin d'étudier plusieurs scénarios d'effacement (durée, fréquence et conditions opératoires) et de développer de nouveaux indicateurs pour caractériser l'impact de l'effacement sur le comportement thermique et énergétique des systèmes frigorifiques. Cette étude a mis en avant, l'importance de l'état de chargement pour limiter la remontée de température de l'air, et réduire l'impact de l'effacement sur les produits entreposés. Par ailleurs, le potentiel d'application de l'effacement dans le cas d'un entrepôt frigorifique ou d'une chambre froide a été évalué, en s'appuyant sur le développement des deux approches de modélisation « boîte noire » (apprentissage automatique par des réseaux de neurones artificiels de type *Deep Learning*) et « boîte blanche » (physique). Une possibilité d'interaction entre ces deux approches a été proposée. Elle est fondée sur l'utilisation des modèles boîte noire pour la prédiction et l'emploi du modèle boîte blanche pour générer les données d'entrée et de sortie.

Mots-clés : Effacement, chambre froide, consommation électrique, indicateur, apprentissage automatique, *Deep Learning*, modèle physique

Abstract

Refrigerated warehouses and cold rooms, mainly used for food conservation, constitute available storage cells; they can be considered as a network of "thermal batteries" ready to be used and one of the best existing solutions to store and delay electricity consumption. However, the risk related to temperature fluctuations of products due to periods of *demand response - DR** and the risk of energy overconsumption limit the use of this strategy by industrials in food refrigeration. The present PhD thesis aims to characterize the electrical DR of warehouses and cold rooms by examining the thermal behavior of those systems, in terms of temperature fluctuation and electrical consumption. An experimental set-up was developed to study several DR scenarios (duration, frequency and operating conditions) and to propose new indicators to characterize the impact of DR periods on the thermal and energy behavior of refrigeration systems. This study has highlighted the importance of the presence of load to limit the temperature rise and thus to reduce the impact on stored products. The potential for DR application in the case of a cold store and a cold room was assessed, based on the development of two modeling approaches: "black box" (*Machine Learning* by artificial neural networks using *Deep Learning* models) and "white box" (physics). A possibility of interaction between these two approaches has been proposed, based on the use of black box models for prediction and the use of the white box model to generate input and output data.

*Demand response – DR (effacement): periods during which the power consumption of an electric utility customer is modified (mainly by reduction or even stopping) to better match its demand for power with the electricity supply's capacity.

Keywords: *Demand response*, cold room, electrical consumption, indicator, *Machine Learning*, *Deep Learning*, physical modelling

Sommaire

Nomenclature..... 19

Introduction 25

Chapitre I :Etat de l'art général

..... 31

I.1 Définition et rôle de l'effacement..... 33

I.2 Application de l'effacement dans le secteur du bâtiment..... 34

I.2.1 Application de l'effacement en hiver 34

I.2.2 Application de l'effacement en été..... 36

I.3 Application de l'effacement dans le secteur du froid 37

I.4 Evaluation de l'impact énergétique de l'effacement 40

I.5 Méthodes de modélisation 41

I.5.1 Approche boîte blanche..... 42

I.5.2 Approche boîte noire..... 46

I.6 Conclusion..... 67

Chapitre II :Etude expérimentale de l'effacement dans une chambre froide et dans un entrepôt frigorifique 69

II.1 Développement d'un dispositif expérimental – Chambre froide laboratoire 70

II.1.1 Chargement de la chambre 72

II.1.2 Instrumentation..... 73

II.1.3	Protocole expérimental.....	74
II.1.4	Configurations et paramètres étudiés	75
II.1.5	Développement des indicateurs pour caractériser les impacts de l’effacement .	77
II.2	Etude expérimentale dans un entrepôt frigorifique	82
II.2.1	Présentation de l’entrepôt.....	82
II.2.2	Protocole de mesure	83
Chapitre III :Modélisation boîte noire et boîte blanche		
.....		85
III.1	Approche boîte blanche	86
III.1.1	Pertes par transmission à travers les parois	89
III.1.2	Infiltration d’air par ouverture des portes	90
III.1.3	Chargement et déchargement des produits.....	91
III.1.4	Dégivrage	91
III.1.5	Eclairage.....	91
III.1.6	Ventilation.....	91
III.1.7	Machines diverses	91
III.1.8	Personnel	92
III.1.9	Echange de chaleur avec le produit.....	92
III.1.10	Bilan thermique sur l’air-liste des paramètres	93
III.2	Approche boîte noire.....	95
III.2.1	Modèles Deep Learning développés et leurs caractéristiques.....	96

III.2.2	Paramétrage des modèles	103
III.2.3	Séries de données pour l'apprentissage et la validation des modèles	103
III.2.4	Ensemble des variables d'entrée et de sortie.....	106
III.2.5	Analyse de corrélation (étude des indépendances des variables d'entrée et de sortie) 108	
III.2.6	Systèmes étudiés	109
III.2.7	Critères pour évaluer les performances des modèles	112
III.3	Interaction entre les deux approches –Boîte noire et Boîte blanche.....	113
III.3.1	Série de données pour l'apprentissage et la validation des modèles.....	114
III.3.2	Variables d'entrées et de sorties.....	115
III.4	Conclusion	116
Chapitre IV :Résultats		
et		
discussion		
.....		117
IV.1	Résultats expérimentaux	118
IV.1.1	Cas chambre froide laboratoire	118
IV.1.2	Cas d'un entrepôt frigorifique	136
IV.2	Conclusion sur les résultats expérimentaux.....	138
IV.3	Approche boîte blanche	139
IV.3.1	Validation du modèle dans le cas de la chambre froide laboratoire.....	139
IV.3.2	Validation du modèle le cas de l'entrepôt frigorifique	143
IV.4	Conclusion sur l'approche boîte blanche.....	144
IV.5	Approche boîte noire.....	145

IV.5.1	Comparaison des performances des modèles développés.....	145
IV.5.2	Effet de réduire le nombre des entrées et des sorties sur la prédiction - Effet de moyenner des données d'entrées et de sorties.....	153
IV.5.3	Influence des entrées sur la prédiction	158
IV.5.4	Influence du nombre de données des périodes d'effacement de la partie apprentissage sur la prédiction	162
IV.6	Conclusion sur l'approche boîte noire	166
IV.7	Interaction entre les deux approches de modélisation	167
IV.7.1	Phase d'apprentissage	168
IV.7.2	Prédiction sur la température de l'air	171
IV.7.3	Prédiction sur la puissance	172
IV.8	Conclusion	173
	Conclusion et perspectives.....	175
	Annexe	179
	ANNEXE 1 : Modèles auto-régressifs	180
	ANNEXE 2 : Performance de la machine frigorifique de la chambre froide	183
	Valorisation.....	184
	Bibliographie.....	185

Index des figures

Figure 1 : Variation de la consommation électrique nationale pendant une journée [18]	33
Figure 2 : Répartition mondiale de la consommation d'électricité pour la production de froid entre les utilisations résidentielles, tertiaires et industrielles IIF [30].....	38
Figure 3 : Représentation de l'effacement, période de report et période de rebond [41].....	41
Figure 4 : Schéma d'un système « boîte noire »	46
Figure 5 : Le positionnement des notations : intelligence artificielle, <i>Machine Learning</i> et <i>Deep Learning</i> [72].....	47
Figure 6 : Schéma d'un neurone artificiel A. Doncescu [84].....	52
Figure 7: Représentation graphique pour un réseau de neurones artificiel simple	54
Figure 8 : Comportement d'un modèle Convolutif [90]	58
Figure 9 : Structure de l'unité LSTM [92]	58
Figure 10 : Exemple de LSTM Stacked [97]	60
Figure 11 : Exemple d'un réseau LSTM Bidirectionnel [99]	61
Figure 12 : Exemple d'un modèle LSTM convolutif [102]	62
Figure 13 : Chambre froide avec 4 palettes (chacune chargée de 392 kg de quartzite).....	71
Figure 14 : Palette en bois utilisée pour le chargement.....	72
Figure 15 : Disposition de l'instrumentation du système.....	73
Figure 16 : Exemple de protocole expérimental pour les essais avec la chambre vide	75
Figure 17: Evolution de la température de l'air à la reprise au cours d'un effacement	78
Figure 18 : Evolution temporelle de la puissance du compresseur en régime établi	79
Figure 19: Evolution temporelle de la puissance du compresseur et du ratio du temps de fonctionnement au cours d'un effacement de 2 heures (scénario de référence)	80
Figure 20 : Vue de haut de l'entrepôt frigorifique	83
Figure 21 : Instrumentation des iButtons à la surface et au cœur de la palette.....	84
Figure 22 : Organisation des entrées et sorties de l'approche boîte blanche	87
Figure 23 : Transfert de chaleur à travers la paroi	89
Figure 24 : Schéma représentatif de l'approche boîte noire.....	96

Figure 25 : Architecture d'un modèle de réseau de neurones	97
Figure 26 : Architecture du modèle de réseau de neurones convolutif pour les 3 systèmes....	98
Figure 27 : Architecture du modèle de réseau récurrent à mémoire court et long terme (LSTM) pour les 3 systèmes.....	99
Figure 28 : Architecture du modèle de réseau LSTM Stacked pour les 3 systèmes	101
Figure 29 : Architecture du modèle de réseau LSTM Bidirectionnel pour les 3 systèmes....	102
Figure 30 : Architecture du modèle de réseau LSTM Convolutif pour les 3 systèmes	102
Figure 31 : Répartition entre l'apprentissage (en orange) et la validation (en bleu) des modèles <i>Deep Learning</i> , x-température extérieure : données d'entrée et y-température de reprise : données de sorties de la série E4.....	105
Figure 32 : Schéma représentatif de l'interaction entre les deux approches	113
Figure 33 : Série de données E6 avec x-température extérieure : données d'entrée et y-température de l'air : données de sorties.....	115
Figure 34 : Evolution de la température durant la phase du régime permanent.....	119
Figure 35 : Evolution de la température de l'air à l'intérieur de la chambre avec $T_{\text{consigne}}=-18^{\circ}\text{C}$ et $T_{\text{ext}}=30^{\circ}\text{C}$	121
Figure 36: Remontée de la température en fonction de la durée de l'effacement pour les différents scénarios.....	123
Figure 37 : Evolution de la température de l'air et du produit à la surface et au cœur des palettes	125
Figure 38: Relation entre $\Delta T_{\text{max_reprise}}$ et $\Delta T_{\text{max_surface}}$	126
Figure 39 : Influence de la durée de l'effacement sur la température du produit au cœur des palettes à $T_{\text{consigne}}=-18^{\circ}\text{C}$ et $T_{\text{ext}}=30^{\circ}\text{C}$	128
Figure 40 : Evolution de la température à cœur des produits dans le cas d'effacements à « haute fréquence » (1 / jour).....	129
Figure 41 : Température du produit au cœur des palettes autour un effacement d'1h.....	131
Figure 42 : Taux de rebond en fonction de la durée de l'effacement de différents scénarios	133
Figure 43 : Temps du retour au fonctionnement normal en fonction de la durée de l'effacement de différents scénarios	134
Figure 44 : Taux de rebond et temps de retour au fonctionnement normal	135
Figure 45 : Evolution de la température relative de l'air à l'intérieur d'un entrepôt frigorifique avec des effacements de 1 h, 2 h et 4 h	136

Figure 46 : Evolution de la température relative du produit à la surface et au cœur des palettes à l'intérieur d'un entrepôt frigorifique avec des effacements de 1 h, 2 h et 4 h.....	137
Figure 47 : Effacement 1h, température de l'air avec la prédiction de la boîte blanche et la référence expérimentale dans le cas de la chambre vide $T_{int}=-18^{\circ}\text{C}$ et $T_{ext}=17^{\circ}\text{C}$	140
Figure 48 : Effacement 1h, température de l'air avec la prédiction de la boîte blanche et la référence expérimentale dans le cas de la chambre chargée $T_{int}=-18^{\circ}\text{C}$ et $T_{ext}=30^{\circ}$ (scénario 4)	141
Figure 49 : Effacement 1 h, température du produit à la surface et au cœur avec la prédiction de la boîte blanche et la référence expérimentale dans le cas de la chambre chargée ; $T_{int}=-18^{\circ}\text{C}$ et $T_{ext}=30^{\circ}\text{C}$ °(scénario 4)	142
Figure 50 : Effacement 1 h, température de l'air avec la prédiction de la boîte blanche et la référence expérimentale dans le cas d'un entrepôt le 14 février 2019	143
Figure 51 : Effacement 1 h, température du produit à la surface et au cœur avec la prédiction de la boîte blanche et la référence expérimentale dans le cas d'un entrepôt le 14 février 2019. 144	
Figure 52 : l'apprentissage de la température de reprise de la série E4 avec le modèle LSTM à 10 entrées et 4 sorties	146
Figure 53 : Puissance du compresseur de la série E4 pendant la période d'apprentissage avec le modèle LSTM à 10 entrées et 4 sorties	147
Figure 54 : Prévision de température de reprise de la série E4 avec les 5 modèles (système à 10 entrées et 4 sorties).....	149
Figure 55 : Prévision de la puissance du compresseur avec les 5 modèles (série E4, système 10 entrées 4 sorties).....	150
Figure 56 : Température extérieure mesurée pendant la phase d'apprentissage.....	153
Figure 57: Prévision de la température de reprise avec le modèle LSTM dans les deux systèmes : a) 10 entrées et 4 sorties, b) 6 entrées et 2 sorties	155
Figure 58 : Prévision de la puissance du compresseur avec le modèle LSTM dans les deux cas:	157
Figure 59 : Température de soufflage et température de reprise pendant la période d'apprentissage.....	158
Figure 60 : Prévision de la température de reprise moyennée avec le modèle LSTM (7 entrées et 2 sorties)	160
Figure 61 : Prévision de la puissance du compresseur avec le modèle LSTM simple (7 entrées et 2 sorties)	161
Figure 62 : Prévision de la température de reprise avec le modèle LSTM – Stacked avec un système à 10 entrées et 4 sorties pour deux séries de données (Série E4 (5s) et Série E5 (20s))	163

Figure 63 : Prévion de la puissance du compresseur avec le modèle LSTM dans les deux séries de données, série E4 (5s) et série E5 (20s),.....	164
Figure 64 : température extérieure pendant la phase d'apprentissage.....	168
Figure 65 : l'apprentissage de la température de l'air avec le modèle LSTM-Convolutif (6 entrées et 2 sorties) série E6.....	169
Figure 66 : l'apprentissage de la puissance du compresseur avec le modèle LSTM-Convolutif (6 entrées et 2 sorties) série E6.....	170
Figure 67 : Prévion de la température de l'air avec le modèle LSTM-Convolutif (6 entrées et 2 sorties) série E6.....	171
Figure 68 : Prévion de la puissance du compresseur avec le modèle LSTM-Convolutif (6 entrées et 2 sorties) série E6.....	172

Index des tableaux

Tableau 1 : Récapitulatif des différents articles sur la modélisation des bâtiments avec les modèles boîte noire.	64
Tableau 2 : Propriétés thermo-physiques du quartzite et de la carotte.....	72
Tableau 3 : Liste des capteurs	74
Tableau 4 : Scénarios étudiés	77
Tableau 5 : liste des indicateurs développés dans le cadre de cette thèse	82
Tableau 6 : Paramètres de la simulation « boîte blanche »	93
Tableau 7 : Durée d'apprentissage et de validation (horizon de prédiction)	106
Tableau 8 : L'ensemble des entrées et des sorties des modèles boîte noire.....	106
Tableau 9 : Corrélation entre les données d'entrée et de sortie (série E5).....	109
Tableau 10 : Système 1 avec 10 entrées et 4 sorties	110
Tableau 11 : Système 2 avec 6 entrées et 2 sorties	110
Tableau 12 : Système 3 avec 7 entrées et 2 sorties	111
Tableau 13 : Les variables d'entrées et de sorties des modèles <i>Deep Learning</i> avec des données du modèle boîte blanche.....	116
Tableau 14 : Comparaison de la durée du cycle, du nombre de cycle par heure, de la température moyenne de l'air et de la consommation d'énergie pendant 1 h en régime permanent	120
Tableau 15 : $\Delta T_{\max_reprise}$ –Température de l'air maximale atteinte après application d'un effacement à l'intérieur de la chambre froide	122
Tableau 16 : Evolution de la température de surface pour les scénarios 1, 2 et 3 et le scénario de référence	124
Tableau 17 : Paramètres et indicateurs d'impact de l'effacement sur le fonctionnement de la machine frigorifique.....	132
Tableau 18 : Réduction de la consommation d'énergie due à l'application de l'effacement.	135
Tableau 19 : Température de l'air maximale atteinte après application d'un effacement de 1 h et 2 h dans le cas d'une chambre froide et dans le cas d'un entrepôt frigorifique	138
Tableau 20 : Performance des modèles par rapport à l'apprentissage de la température de reprise et de la puissance du compresseur dans la série E4 avec un système à 10 entrées et 4 sorties	148

Tableau 21 : Performance des modèles par rapport à la prédiction de la température de reprise et de la puissance du compresseur dans la série E4 avec un système à 10 entrées et 4 sorties	152
Tableau 22 : Réduction du nombre d'entrées et de sorties du modèle LSTM.....	154
Tableau 23 : Entrées et sorties des deux systèmes :	159
Tableau 24 : Performance du modèle LSTM par rapport à la prédiction de la température de reprise et de la puissance du compresseur dans la série E4 pour les 3 systèmes	161
Tableau 25 : Performance du modèle LSTM par rapport à la prédiction de la température et de la puissance du compresseur avec les deux séries 4 et 5.....	165
Tableau 26 : Critères de performance de prédiction pendant l'apprentissage - partie interaction	170
Tableau 27 : Performance des modèles par rapport à la prédiction de la température de l'air, et de la consommation du compresseur dans la série E6 (système à 6 entrées et 2 sorties) avec l'utilisation des données d'entrées et sorties issues du modèle physique	173

Nomenclature

Alphabet latin

<i>A</i>	Surface d'échange	[m ²]
<i>C_p</i>	Chaleur spécifique	[J.kg ⁻¹ .K ⁻¹]
<i>H</i>	Coefficient d'échange convectif	[W.m ⁻² .K ⁻¹]
<i>L</i>	Longueur	[m]
<i>M</i>	Masse	[kg]
<i>ṁ</i>	Débit massique	[kg.s ⁻¹]
<i>q̇</i>	Quantité de chaleur	[J]
<i>P</i>	Puissance	[W]
<i>E</i>	Energie	[J]
<i>T</i>	Température	[K] ou [°C]
<i>T</i>	Temps	[s] ou [mn] ou [h]
<i>S</i>	Surface	[m ²]
<i>U</i>	Coefficient de transfert global	[m ² .K.W ⁻¹]
<i>V</i>	Vitesse	[m.s ⁻¹]
<i>X</i>	Epaisseur	[m]

Alphabet grec

Λ	Conductivité thermique	$[\text{W.m}^{-1}.\text{K}^{-1}]$
P	Densité (Masse volumique)	$[\text{Kg.m}^{-3}]$
Φ	Flux de chaleur	$[\text{W}]$
Σ	Fonction d'activation (logistique)	-
Δ	Variation	-

Indice et exposant

<i>a</i>	Air
<i>b</i>	Biais
<i>c</i>	Convection
<i>cond</i>	Conduction
<i>cov</i>	Covariance
<i>e</i>	Energie
<i>eff</i>	Effacement
<i>ext</i>	Extérieur
<i>f</i>	Forget
<i>fonc</i>	Fonctionnement
<i>frig</i>	Frigorifique
<i>i</i>	Input
<i>int</i>	Intérieur
<i>lum</i>	Lumière
<i>m</i>	Moyenne
<i>max</i>	Maximale
<i>N</i>	Nombre de personne
<i>o</i>	Output
<i>p</i>	<i>Pic</i>
<i>souf</i>	Soufflage
<i>tan</i>	Tangente

<i>ven</i>	Ventilation
<i>w</i>	Matrice des poids
<i>y</i>	Valeur de référence
\hat{y}	Valeur prédite
*	Multiplicateur élément par élément
+	Addition élément par élément

Abréviations

ANN	Artificial neural network
AR	Autoregressive
ARIMA	Autoregressive integrated moving
ARMA	Autoregressive moving average
ARMAX	Autoregressive moving average exogenous
ARX	Autoregressive exogenous
BJ	Box Jenkins
BP	Back propagation
BPNN	Back propagation neural network
CFD	Computational Fluid Dynamics
CNN	Convolutional neural network
Comp	Compresseur
COP	Coefficient de performance
CV	Coefficient de variation
Deg	Dégivrage
DL	<i>Deep Learning</i>
DR	<i>Demand response</i>
DSM	Demand-side management
FIR	Finite impulse response
FIT	Fitting

GRNN	General regression neural network
HVAC	Heating, ventilation and air-conditioning
IA	Intelligence artificielle
IIF	Institut international du froid
LSTM	Long short-term memory
MAE	Mean absolute error
ML	Machine Learning
MLP	Multilayer perceptron
MSE	Mean-square error
NARX	Nonlinear autoregressive exogenous
OE	Output error
PCM	Phase change material
RBFNN	Radial basis function neural network
RMSE	Root-mean-square error
RNN	Recurrent neural network
RTE	Réseau de transport d'électricité
SEC	Specific energy consumption

Introduction

L'énergie électrique est l'une des plus consommées dans notre vie quotidienne. Elle représente une part importante de la consommation finale à l'échelle mondiale (environ 20%). La production d'électricité constitue ainsi un enjeu fondamental de développement mais doit aussi faire face aux nouveaux challenges environnementaux. Dans ce contexte, et compte tenu des moyens humains et matériels importants mis en jeu, l'industrie électrique doit proposer des solutions pour optimiser la gestion énergétique des réseaux afin d'assurer un équilibre permanent entre production et consommation. Pour ce faire, les fournisseurs d'énergie doivent pouvoir disposer d'outils de flexibilité permettant d'ajuster la production aux besoins du réseau. Un autre enjeu de la gestion énergétique, est le développement des énergies renouvelables qui permettent de réduire le coût énergétique et les émissions de gaz à effet de serre. Dans ce contexte, l'Union Européenne s'est fixée pour objectif d'augmenter la part de ces énergies dans la consommation énergétique à 27% à l'horizon 2030 [1]. Cependant, l'intermittence de ces nouveaux moyens de production, dont le rendement varie en fonction de l'heure, de la saison ou du climat, nécessite une reconsidération de la gestion du réseau pour permettre plus de flexibilité.

L'une des approches qui répond à l'équilibre entre la consommation et la production d'électricité est l'application de l'effacement électrique. En France, les objectifs de développement des capacités d'effacement électrique de tout type sont fixés à 5 GW pour 2018 et à 6 GW pour 2023 [2].

Cette action vise à baisser temporairement le niveau de soutirage effectif sur le réseau en arrêtant la consommation d'électricité pendant les périodes de pics de demande, ou en décalant la consommation à une période ultérieure. En France, le potentiel de flexibilité lié à l'effacement pour les industriels, estimé par RTE, a augmenté de 2,5 GW entre 2012 et 2017 [3]. L'effacement permet aussi de réduire la consommation globale, et par conséquent, une baisse de la facture d'électricité. Cela représente donc une opportunité de diversification des revenus pour les industriels de grosse consommation électrique (d'après la perspective de la loi « Brottes ») [4].

La production de froid représente quant à elle une part importante de la consommation électrique mondiale, soit 17%, et correspond à 10 % des émissions de gaz à effet de serre [5]. En Europe, il existe 1,7 millions de chambres froides et d'entrepôts frigorifiques qui

représentent la part principale du secteur du froid industriel. Ces équipements et infrastructures ont une capacité de 60 à 70 millions de m³ de volume de stockage avec notamment une consommation d'énergie spécifique (SEC) entre 6 et 240 kWh.m⁻³.année⁻¹ pour le stockage des produits surgelés [6]. Ainsi, grâce à l'inertie thermique des produits qu'ils contiennent, ces entrepôts et chambres froides peuvent constituer un segment de stockage d'énergie sous forme thermique, rapide et accessible, ce qui présente l'intérêt de limiter les remontées de température en cas de périodes d'arrêts des machines frigorifiques [7], c'est-à-dire en cas d'effacement. Par rapport au stockage d'énergie électrique utilisant des batteries, le stockage thermique présente de nombreux avantages. En effet, il a une durée de vie plus longue, un coût de revient moins important et surtout très peu d'impact néfaste sur l'environnement. Ces qualités font aujourd'hui du stockage thermique l'une des meilleures solutions pour le stockage d'énergie et d'électricité [8].

Néanmoins, malgré les avantages que présentent les entrepôts frigorifiques et les chambres froides pour le stockage d'énergie thermique et l'application de l'effacement, des contraintes existent, rendant souvent difficile sa mise en œuvre, en raison d'une demande de délestage ou de consommation imprévue. Il convient alors d'avoir une bonne connaissance du comportement du système, en termes de fluctuation de température et de consommation électrique, afin de permettre le déploiement de l'effacement.

La maîtrise de ces éléments physiques (température, puissance, énergie...) permet en particulier de cerner les incertitudes liées aux performances énergétiques engendrées par les effets « rebond / report ». L'effet « rebond » peut apparaître à la suite d'un effacement et se traduit par un appel de puissance important au redémarrage de la machine, tandis que l'effet « report » se traduit par une surconsommation électrique liée au « rattrapage » du niveau de température pour retrouver l'état précédent l'effacement. Mettre en place une approche de modélisation systémique est alors indispensable pour prédire de manière fiable le comportement attendu d'un système global (exemple d'une chambre froide avec stockage thermique) lors d'un effacement électrique. Toutefois, se pose la question du type de modèle prédictif à considérer selon les données de terrain et les caractéristiques physiques disponibles, mais aussi selon la précision souhaitée, le temps de calcul ou encore les scénarios envisagés. On peut ainsi distinguer deux types de modèles de nature très différente, les approches « boîte noire » et « boîte-blanche ».

L'approche de modélisation de type « boîte noire » ou « data-driven » ignore la constitution physique du système et ne considère que le comportement de ses entrées et sorties. Ce sont des

modèles qui cherchent des corrélations, ou des relations entre les données. Tandis que le modèle boîte blanche est un modèle qui tient compte des caractéristiques physiques intrinsèques des données. Ce sont deux modèles qui se complètent.

Les opérateurs d'effacement (agrégateurs) utilisent souvent l'approche « boîte noire » pour prédire le comportement du système sans avoir à le modéliser physiquement. Cette approche est généralement caractérisée par un apprentissage automatique. Différents travaux se sont intéressés à la prédiction du comportement des systèmes frigorifiques dynamiques avec une variation temporelle, en utilisant de nombreux algorithmes d'apprentissage automatique ou de réseaux de neurones artificiels [9-11]. Cela dit, peu de travaux se sont intéressés à la prédiction de la température et de la consommation électrique par l'apprentissage profond « *Deep Learning* » [12, 13]. Cependant, la différence d'architecture des réseaux, des paramètres d'entrée et de la durée d'apprentissage qui peut varier de 2 jours à 2 ans [14], rend difficile le choix du type de réseau adapté à l'étude.

L'approche de modélisation « boîte-blanche » ou « physique » est dite approche du génie des procédés. Elle s'appuie sur des équations décrivant les phénomènes physiques qui se produisent dans les systèmes étudiés. Cette approche est fondée sur le bilan thermique et tient compte des différentes charges thermiques telles que : les pertes thermiques à travers les parois, la quantité d'énergie thermique stockée et la puissance frigorifique apportée, etc [15]. Elle présente l'avantage de décrire l'influence des différents composants du système sur le comportement thermique de la chambre ou de l'entrepôt, et autorise donc les scénarios selon différentes charges thermiques, sans nécessité des jeux de données importants en entrée. Néanmoins, l'utilisation de cette approche « adaptative » nécessite des connaissances précises sur le fonctionnement de la machine frigorifique et des échanges thermiques à l'intérieur de l'entrepôt / chambre froide. Par ailleurs, la modélisation physique dite « boîte blanche » peut être utilisée pour générer un nombre important de données, et ainsi alimenter un modèle « boîte noire » par exemple dans le cas d'un manque de données expérimentales. Ainsi, les approches boîtes blanches et boîtes noires peuvent être couplées afin de bénéficier des avantages des deux méthodes et minimiser les erreurs de prévision.

Cette thèse fait partie du projet ADEME Flexifroid (Effacement des entrepôts frigorifiques de surgelés : évaluation de l'impact énergétique et du risque produit, 2014 – 2019). Elle vise à caractériser l'impact des applications de l'effacement électrique dans des entrepôts frigorifiques et chambres froides, en apportant un éclairage sur le comportement thermique de ces systèmes, en termes de fluctuation de température et de consommation électrique.

L'objectif est, d'une part, de tester différents scénarios d'effacement (chargement, température de consigne, température extérieure) afin de pouvoir mesurer et évaluer leur impact sur l'installation frigorifique et la qualité des produits, et d'autre part, d'évaluer le potentiel d'application de l'effacement dans le cas d'un entrepôt frigorifique ou d'une chambre froide, en s'appuyant sur le développement des deux approches de modélisation « boîte noire » et « boîte-blanche ».

La visée méthodologique de cette thèse est de proposer une analyse de ces deux approches afin d'évaluer leur pertinence relative pour la prédiction du comportement thermique du système, mais aussi l'intérêt du couplage des deux méthodes. Une piste d'étude consiste ainsi à utiliser la boîte blanche, un modèle physique qui mime le comportement dynamique des entrepôts, pour générer un grand nombre de données en laboratoire dans des conditions réalistes, variées et extrêmes qui permettent de minimiser le bruit de mesure. Ensuite, ce jeu de données sera utilisé pour alimenter la boîte noire (phases d'apprentissage et de validation).

L'approche boîte noire sera évaluée pour répondre au mieux aux questions suivantes :

- 1) quel(s) modèle(s) d'apprentissage en profondeur sont les plus adaptés à représenter nos données spécifiques ?
- 2) quelle est l'influence du nombre d'entrées et de sorties sur les résultats de la prédiction des sorties souhaitées ?
- 3) quelle est l'influence du pas de temps sur la prédiction des sorties ?

L'objectif final de la thèse est ainsi d'appliquer ces différentes méthodes (seules ou couplées) afin d'optimiser la capacité de prédiction des conditions thermiques des entrepôts frigorifiques pendant les scénarios d'effacement.

Le manuscrit de thèse est organisé de la façon suivante :

Le premier chapitre présente une synthèse bibliographique sur les différents travaux réalisés en rapport avec le sujet. Cette partie se compose principalement de trois sections :

- les méthodes d'application de l'effacement dans différents secteurs,
- l'évaluation de l'impact énergétique de l'effacement dans les entrepôts frigorifiques et chambres froides,
- les méthodes de modélisation (boîte blanche, boîte noire et leur interaction) pour prédire le comportement thermique d'un système (entrepôt frigorifique / chambre froide).

Le deuxième chapitre traite l'étude expérimentale du comportement thermique et énergétique de la chambre froide et d'un entrepôt frigorifique lors de l'application de l'effacement. Deux dispositifs, une chambre froide laboratoire et un entrepôt frigorifique industriel, ont été mis en place. Les protocoles d'expérimentation, les scénarios et paramètres étudiés sont présentés. Des indicateurs caractérisant l'impact de l'effacement sur la température de l'air et du produit et sur le comportement de la machine frigorifique ont été proposés.

Les approches de modélisation - boîte noire et boîte blanche ainsi que leur couplage ont fait l'objet du troisième chapitre. Dans un premier temps, le modèle boîte blanche (développé dans le projet Flexifroid) a été présenté. Ensuite, la construction des modèles boîte noire (de type *Deep Learning*) et l'ensemble de leurs variables d'entrée et de sortie sont présentées. Enfin, une possibilité d'interaction entre ces deux approches a été étudiée.

Le dernier chapitre regroupe l'ensemble des résultats obtenus par les différentes parties (expérimentale, boîte noire, boîte blanche et interaction boîte noire et boîte blanche). Dans un premier temps, les résultats expérimentaux à l'échelle laboratoire (chambre froide) et industrielle (entrepôt frigorifique) sont analysés afin d'identifier les effets de l'effacement sur le comportement thermique et énergétique à travers différents indicateurs. Des résultats montrant la validation du modèle boîte blanche (chambre froide et entrepôt) sont ensuite présentés. Puis, des résultats concernant la prédiction du comportement de la chambre froide lors de l'effacement obtenus avec les modèles boîte noire sont également étudiés. Enfin, ce chapitre se conclut par les résultats concernant l'interaction entre les deux approches.

Ce manuscrit se termine par une conclusion et des perspectives de recherche.

Chapitre I : Etat de l'art général

Ce chapitre présente un état de l'art portant sur l'étude de l'effacement et les méthodes de modélisation. Dans cette section, les méthodes d'application de l'effacement dans différents secteurs, l'évaluation de l'impact énergétique de l'effacement et le comportement thermique dans les entrepôts frigorifiques et chambres froides seront détaillés. Ensuite, les principales méthodes de modélisation – boîte blanche et boîte noire - seront abordées. Une interaction entre les deux approches de modélisation sera présentée.

Introduction

En France, en raison de l'augmentation importante de la part du nucléaire dans le mix énergétique, la production d'électricité a plus que doublé en quarante ans. Depuis une quinzaine d'année toutefois, la production d'électricité s'est stabilisée mais reste à un niveau élevé et subit régulièrement des augmentations. L'année 2018 a par exemple été marquée par une nette hausse de production d'électricité (548,6 TWh en 2018 soit une hausse de 3,7% par rapport à 2017) [16]. La distribution de cette énergie électrique, d'origine diverse (nucléaire, fossile, hydro-électrique, renouvelable), est assurée par un ensemble d'infrastructures énergétiques nommé « Réseau électrique ». Néanmoins, en raison des variabilités à la fois géographiques et temporelles, ce réseau électrique doit être optimisé afin de mieux mettre en relation l'offre et la demande. Depuis quelques années, on parle ainsi de *Smart grid*, qui désigne le réseau électrique intelligent qui assure cet équilibre entre la production et la consommation, cela en optimisant la circulation de l'électricité dans les deux sens : des producteurs aux consommateurs et des consommateurs aux producteurs.

Dans ce cadre, la mise en place des effacements constitue un levier important pour l'optimisation du réseau électrique puisqu'elle permet d'inciter les « gros » consommateurs à réduire leur consommation électrique d'une part et ce qui permet d'autre part de soulager le réseau et de faciliter la distribution de l'électricité. Ainsi, l'effacement représente non seulement un intérêt économique pour les industriels, mais il apporte également de la flexibilité au réseau.

Parmi les différents secteurs d'intérêt pour la mise en œuvre de l'effacement électrique, l'industrie agro-alimentaire, et en particulier l'industrie du froid pour la transformation et la conservation des aliments, représente un fort potentiel d'application. En effet, environ 24 millions de tonnes de denrées alimentaires sont transformées chaque année en utilisant le froid et 40% du bol alimentaire, soit 370 kg / personne, nécessite l'application du froid [17]. Par ailleurs, en raison de l'expansion du besoin en réfrigération, en partie due au réchauffement climatique, ces chiffres risquent d'augmenter dans les années à venir. L'application de l'effacement dans le secteur du froid semble donc prometteuse, à condition de disposer d'outils permettant de proposer des conditions d'utilisation à la fois efficace d'un point de vue énergétique et garantissant une sécurité des procédés frigorifiques de transformation et de conservation des aliments.

I.1 Définition et rôle de l'effacement

En France, l'énergie électrique est produite en fonction des prévisions de consommation car il existe peu de dispositifs capables de la stocker. La consommation d'électricité est, elle-même, influencée par différents paramètres qui la font varier en fonction de l'heure de la journée (Cf. figure 1). Afin d'avoir une bonne maîtrise de la gestion de la demande en énergie, il est possible d'appliquer des scénarios d'effacement électrique.

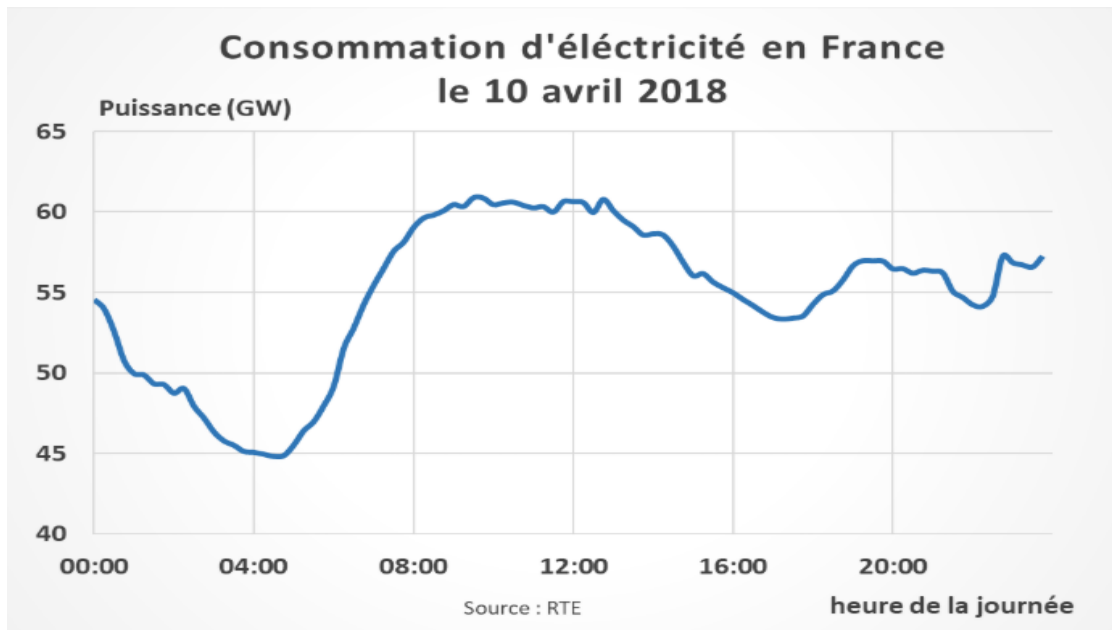


Figure 1 : Variation de la consommation électrique nationale pendant une journée [18]

D'un point de vue industriel, l'effacement (*demand response en anglais*) se définit comme l'action, décidée par un ou plusieurs consommateurs, visant à arrêter totalement ou partiellement leur consommation en électricité pendant des périodes de pics de demande afin d'apporter davantage de flexibilité « offre-demande » au réseau électrique. De plus, suivant ces différentes périodes, les tarifs d'électricité varient aussi en fonction de l'heure de la journée. En effet, les heures pleines sont caractérisées par une forte demande des consommateurs en électricité. De ce fait, ces heures sont associées à un prix élevé du kWh d'électricité. A l'inverse, les heures creuses sont souvent concentrées à des moments où la demande en électricité est faible, ce qui entraîne un faible prix d'électricité. D'un point de vue économique, l'effacement de la consommation électrique avec un potentiel estimé à 10% de la puissance disponible, peut donc se révéler être une stratégie économique réalisable et rentable. L'effacement représente ainsi, pour les gros consommateurs d'électricité, une opportunité de diversification des revenus,

sachant que le potentiel de flexibilité lié à l'effacement pour les industriels en France, estimé par RTE en 2017, a augmenté de 2,5 GW entre 2012 et 2017 [3].

Par ailleurs, du point de vue de la gestion du réseau, l'objectif pour les opérateurs d'effacement ou les fournisseurs d'électricité est d'équilibrer la production et la demande électrique. Pour ce faire, les consommateurs finaux, comme les industriels, sont régulièrement sollicités afin de réduire leur consommation d'électricité pendant les périodes de pics de demande ou la décaler à des périodes ultérieures, en particulier aux heures creuses. En contrepartie, les gestionnaires du réseau proposent des rémunérations aux utilisateurs. Au final, l'effacement électrique permet de baisser temporairement le niveau de soutirage effectif sur le réseau et donc de soulager le réseau électrique. De plus, cette action vise à éviter d'utiliser des sources de production supplémentaire, à intégrer les énergies renouvelables lors d'application de l'effacement et à maîtriser les consommations énergétiques, ce qui permet d'un point de vue environnemental de réduire les émissions de gaz à effet de serre.

I.2 Application de l'effacement dans le secteur du bâtiment

Après avoir défini l'effacement et identifié son rôle pour les industriels et les gestionnaires du réseau, il est important de s'intéresser aux méthodes de caractérisation et d'application de l'effacement et à ses impacts. Dans le domaine du chauffage ou de la climatisation, les méthodes d'application de l'effacement doivent être adaptées aux bâtiments intégrant les systèmes HVAC (*Heating, Ventilation and Air-Conditioning*), car ils s'appuient entre autres sur l'utilisation de l'inertie thermique du bâtiment pour maintenir un certain confort thermique des occupants lors d'application de l'effacement. Dans cette section, sont présentés les travaux menés sur l'application de l'effacement en fonction des périodes d'hiver et d'été.

I.2.1 Application de l'effacement en hiver

Plusieurs études se sont intéressées aux méthodes d'application de l'effacement basées sur l'utilisation de l'inertie thermique du bâtiment en hiver. L'objectif était de diminuer la consommation en chauffage lors d'application de l'effacement. Plusieurs méthodes ont été choisies : un préchauffage du bâtiment avant effacement, un décalage du fonctionnement du chauffage aux heures creuses, une diminution de la température de consigne pendant l'effacement, l'arrêt de la ventilation, ou l'utilisation de différents systèmes de stockage de chaleur tel que le stockage dans un ballon d'eau chaude.

Kelly *et al.* [19] ont concentré leur étude sur la détermination du temps maximal d'effacement dans une maison typique du Royaume-Uni, chauffée par une pompe à chaleur, en tenant compte de l'influence de la météo, de l'isolation, et de l'occupation. Pour cela, ils ont examiné différentes configurations de stockage de l'énergie : l'inertie du bâtiment, l'utilisation d'un ballon tampon de stockage ou l'augmentation de la température de consigne avant l'effacement (préchauffage). Les résultats ont montré qu'il est possible de couper la pompe à chaleur pendant une heure sans effet significatif sur le confort de l'occupant et cela en utilisant seulement l'inertie thermique. L'augmentation de la température de consigne de 2°C permet un effacement de 1,5 h, mais entraîne une augmentation de 10 % de la consommation énergétique de la pompe à chaleur. Enfin, l'utilisation d'un ballon de stockage de 300 l entre la pompe à chaleur et le réseau de distribution permet également un effacement de 1,5 h contre 2 h pour un ballon de 500 l, avec une légère diminution de la consommation d'énergie par rapport au cas de base.

Wyse [20] a étudié la réponse de bâtiments à un effacement au cours d'une période hivernale et cela, en décalant le fonctionnement du chauffage dans deux bâtiments aux conditions d'isolation suivantes : une maison passive avec une très faible consommation d'énergie (haut niveau d'isolation) et un bâtiment avec un niveau d'isolation moyen (enveloppe standard). De plus, l'auteur a émis l'hypothèse qu'un taux d'inconfort d'un maximum de 9 % du temps pendant lequel la température est en-dessous de 18°C était défini comme acceptable. Les résultats montrent que pour un effacement de 6 h d'une maison passive, le taux d'inconfort était de 0,9 % ; alors que pour une maison moyennement isolée avec un effacement acceptable d'une heure, le taux d'inconfort était de 6,4 %.

Favre et Peuportier [21] ont étudié la possibilité de décaler une partie de la consommation en chauffage d'un bâtiment grâce à son inertie thermique, en utilisant un chauffage « commandé » pour permettre d'effacer sa consommation électrique pendant les périodes de pointe. Pour cela, ils ont utilisé un algorithme d'optimisation fondé sur la méthode de la programmation dynamique pour minimiser une fonction de coût, tenant compte d'une tarification différenciée (heures creuses, pleines et de pointe), des contraintes de confort (température minimale et gradient de température maîtrisés) et de puissance maximale de l'équipement. Deux cas d'études correspondent au même bâtiment, mais avec deux configurations différentes : l'un ancien peu isolé et l'autre neuf performant. Dans le cas du bâtiment peu isolé, les résultats montrent qu'il peut subir un effacement partiel (non complet) du chauffage, pendant les heures de pointe. Cependant, ceci nécessite de chauffer les pièces à plus de 25°C avant l'effacement pour maintenir une température de confort de 19°C. Ils ont également constaté une forte

variation de la température intérieure qui passe de 19°C à 26°C pendant les périodes d'heures creuses de 1 h à 8 h du matin. Celle-ci est due à l'importance des puissances de préchauffage et du stockage d'énergie par inertie thermique. De plus, ils ont observé que la température chute brutalement de plus de 2,2°C par heure pendant les heures pleines. Dans le cas du bâtiment neuf, l'effacement des heures de pointe est complet, alors que la variation de la température intérieure ne dépasse pas 1,4°C par heure. Enfin, par rapport à une régulation classique qui consiste à maintenir la température intérieure à 19°C, une régulation optimale par rapport au coût d'électricité, avec l'effacement des heures de pointe obtenue avec la programmation dynamique, permet de réaliser 18 % d'économie : 22,5€ par semaine contre 27,3€ pour une régulation classique, en fonction des hypothèses tarifaires prises. Néanmoins, il est à noter que la consommation d'énergie a augmenté de 16 % à cause du besoin de préchauffage.

Berthou *et al.* [22] ont étudié la possibilité de diminuer les besoins en chauffage dans un bâtiment de bureaux. Pour cela, ils ont opté pour trois scénarios d'effacement : diminution de la température de consigne de 2 °C, arrêt de la ventilation et arrêt total du chauffage. Les résultats montrent que la diminution de la température de consigne de 2 °C sans créer d'inconfort, de 18 h à 20 h, provoque une diminution du besoin en chauffage, mais crée un effet de relance qui est important à la fin de l'effacement. L'arrêt de la ventilation, qui ne peut être appliqué que si la qualité de l'air intérieur respecte les normes à chaque instant de l'effacement, provoque une baisse immédiate des besoins de chauffage sans engendrer d'effets de relance à la fin. L'arrêt complet du chauffage pendant deux heures cause une chute rapide de la température intérieure d'environ 3°C.

I.2.2 Application de l'effacement en été

D'autres études se sont intéressées aux méthodes d'application de l'effacement basées sur l'inertie thermique du bâtiment en été. Le but est de réduire la consommation du système de refroidissement tout en maintenant un certain confort thermique dans le bâtiment. Pour cela, plusieurs méthodes existent : utilisation de la ventilation lors de l'application de l'effacement, anticipation de l'effacement par un pré-refroidissement ou bien décalage du refroidissement aux heures creuses.

Favre [23] a étudié l'utilisation de la surventilation nocturne qui permet l'amélioration du confort thermique lors d'une période de forte chaleur dans un bâtiment performant sans système de climatisation. La méthode d'optimisation employée était la programmation dynamique et les commandes étudiées concernent la ventilation forcée (avec un surcoût énergétique de

fonctionnement) et la ventilation naturelle (sans surcoût énergétique). Cette étude a observé que la ventilation naturelle était plus efficace que la ventilation forcée. En effet, celle-ci a permis de maintenir le confort dans le bâtiment en utilisant seulement son inertie thermique.

Dans la même thématique de l'application de l'effacement en été, d'autres études ont été menées sur la possibilité d'appliquer l'effacement dans des immeubles de bureaux et dans des laboratoires tests, et elles ont toutes montré le potentiel des différentes méthodes d'application de l'effacement. On peut citer par exemple Ruud *et al.* [24] ; Coniff [25]; Morris *et al.* [26] ; Keeney et Braun. [27].

Xu *et al.* [28] ont étudié le potentiel de réduction de la demande de consommation d'électricité pour la climatisation d'un immeuble de bureaux en appliquant une méthode de pré-refroidissement. Après avoir défini un intervalle pour la température de confort (entre 21,1°C et 23,9°C), le bâtiment est maintenu à la température minimale de confort, qui est de 21,1°C pendant la période occupée, de 5 h jusqu'à 14 h, puis de 14 h à 17 h (pendant les heures de pointe) la température de zone est laissée libre et autorisée à atteindre la température maximale de 25,5°C. Grâce à cette méthode, la puissance de la machine frigorifique est réduite de façon importante, de 80% de la puissance nominale jusqu'à un arrêt total de la machine, pendant les heures de pointe, en limitant le problème de confort thermique.

Sana et Guay [29] ont étudié une technique d'optimisation dynamique en temps réel pour répondre à une problématique d'effacement pour la réduction de la consommation d'énergie dans un bâtiment. En effet, la consommation d'électricité doit être minimisée en réponse à la capacité de la production et à la tarification en temps réel sur un horizon de quinze jours. Les résultats ont montré que cette technique d'optimisation convient à la réduction des pics et aussi à réduire de manière significative le coût énergétique.

I.3 Application de l'effacement dans le secteur du froid

La consommation d'électricité utilisée pour le froid et le conditionnement d'air représente une part importante de la consommation mondiale, soit 17% pour les pays industrialisés [30]. En effet, cela s'explique par le besoin de froid dans de multiples secteurs (industriel, tertiaire et résidentiel) comme le montre la figure 2. De plus, les installations frigorifiques représentent un potentiel important pour l'application des effacements. A titre d'exemple, d'après Grein et Pehnt [31], le potentiel théorique de la gestion de charge des systèmes de réfrigération en Allemagne est de 214MW pour un effacement d'une heure.

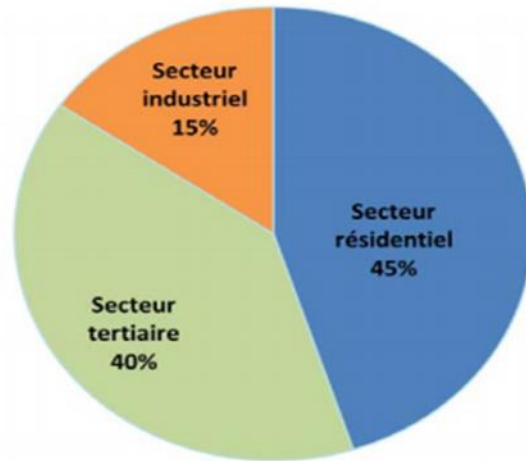


Figure 2 : Répartition mondiale de la consommation d'électricité pour la production de froid entre les utilisations résidentielles, tertiaires et industrielles IIF [30]

Les chambres froides et les entrepôts frigorifiques (1,7 millions en Europe) représentent un potentiel important pour l'application de l'effacement. En effet, ces équipements et ces infrastructures ont une capacité de 60 à 70 millions de m^3 de volume de stockage, avec notamment une consommation d'énergie spécifique (SEC) comprise entre 6 et $240 kWh.m^{-3}.année^{-1}$ pour le stockage des produits surgelés [6, 32]. Les méthodes d'application de l'effacement dans les entrepôts et les chambres froides se basent d'une part sur l'utilisation de l'inertie thermique de leur enveloppe (grande similarité avec les bâtiments) ; et d'autre part, sur l'utilisation des différents types de stockage d'énergie thermique tels que l'inertie thermique du produit (stockage passif) ou les réservoirs de stockage thermique (stockage actif). Les entrepôts frigorifiques et chambres froides, forment à eux seuls, de par l'inertie thermique de la masse des produits, une source importante de stockage thermique rapidement accessible. Ils peuvent être considérés comme un réseau national de « batteries thermiques » d'ores et déjà disponibles. En effet, le stockage d'énergie thermique « passif » permet de limiter les remontées de température en cas de périodes d'arrêts des machines frigorifiques [7] ou d'effacement. A l'inverse, les dispositifs « actifs », comme les réservoirs de stockage d'énergie thermique, doivent être installés [33]. Ces dispositifs de stockage (passif ou actif) peuvent apporter une flexibilité énergétique au système et favoriser d'avantage l'application de l'effacement.

Bien qu'il semble très intéressant d'appliquer l'effacement dans des entrepôts frigorifiques ou des chambres froides pour diminuer la consommation d'électricité et améliorer la gestion du réseau électrique, cette action peut également se révéler problématique pour la qualité des

produits entreposés, notamment lorsque ces derniers atteignent les limites réglementaires de température de stockage. A noter que plusieurs études se sont intéressées aux différentes méthodes d'application de l'effacement dans les entrepôts frigorifiques et les chambres froides en respectant la régulation de la température et la qualité des aliments. Parmi les solutions envisagées, on peut citer l'arrêt des ventilateurs des évaporateurs, la surproduction de froid pendant les heures creuses et la réduction des opérations de refroidissement pendant les heures pleines, l'augmentation de la température de consigne et l'arrêt de la machine de réfrigération lorsque la ventilation est en marche.

Koca et Hellickson [34] ont étudié la possibilité de faire des économies d'énergie électrique grâce à l'arrêt des ventilateurs de l'évaporateur dans une installation de stockage de pommes à atmosphère réfrigérée contrôlée, de taille réelle à Yakima, dans l'État de Washington. La demande de refroidissement de la pièce et le fonctionnement du ventilateur de l'évaporateur étaient contrôlés par la température du fruit en vrac. La température du réfrigérant était réglée par une séquence de montée en puissance contrôlée et une moyenne pondérée de trois thermistances plutôt qu'un thermostat d'ambiance. Les résultats ont démontré qu'un fonctionnement discontinu des ventilateurs de l'évaporateur offrait des économies d'énergie supérieures à 50 % tout en ne provoquant que des oscillations de température de 0,1°C pendant le stockage. En effet, lorsque les ventilateurs de l'évaporateur étaient éteints, la température des fruits en vrac était stable. Grâce à l'inertie thermique des produits, les conditions ambiantes, la perte de masse du produit et la qualité des fruits n'ont pas été compromises.

East *et al.* [35] ont étudié le potentiel d'économie d'énergie généré à l'aide de deux méthodes de régulation de la température de pommes entreposées sous atmosphère contrôlée. La première méthode consiste à réduire la consommation du système de réfrigération pendant les périodes de pointe. La seconde consiste à produire plus de froid pendant les heures creuses, mais en maintenant un certain niveau de réfrigération pendant les heures de pointe. Les résultats démontrent que grâce à l'inertie thermique des pommes (stockage passif), il n'a été observé qu'une augmentation mineure de la température des fruits, lorsque les systèmes frigorifiques étaient coupés. Cette augmentation a peu d'influence sur la qualité des pommes, et d'après les résultats de simulateurs, un cycle d'arrêt de 9 h à 15 h permettrait de réaliser une économie d'environ 40% des coûts d'électricité en ne provoquant qu'un écart de 0,5°C de la température moyenne des fruits. Ces résultats suggèrent qu'il existe des possibilités d'économies d'énergie substantielles dans les magasins de pommes à atmosphère contrôlée.

Ambaw *et al.* [36] ont étudié les régimes de température et de débit d'air dans les entrepôts réfrigérés de pommes à atmosphère contrôlée pour répondre aux problèmes de coûts énergétiques. Plusieurs méthodes d'application des effacements ont été testées : faire varier la température de consigne entre 1,2°C et 0,6°C après un régime jour / nuit ; faire fonctionner la machine frigorifique de manière discontinue, soit 12 h on / 12 h off ; 10 h on / 14 h off ; et 8 h on / 16 h off. D'après les résultats, grâce à l'inertie thermique des pommes, la température du produit variait entre 0,51°C et 1,22°C (avec une moyenne temporelle de 0,88°C) pour la méthode 12 h on / 12 h off. Pour 10 h on / 14 h off, la température moyenne était de 0,94°C avec un minimum et un maximum égal à 0,51°C et 1,32°C, respectivement. Pour la troisième méthode, 8 h on / 16 h off, la température moyenne du produit était de 1,01°C et fluctuait entre 0,52°C et 1,50°C. De plus, en réduisant les heures de travail du ventilateur de circulation d'air, une réduction significative de la consommation énergétique a été observée. Par exemple, pour la méthode de cycle 8 h on / 16 h off, la charge de réfrigération peut être réduite de 55% par rapport au refroidissement à une température constante de 1°C. En outre, les ventilateurs ne fonctionneraient que 33% du temps, entraînant une économie supplémentaire.

Brooks *et al.* [37] ont étudié le potentiel d'utilisation de l'inertie thermique du produit congelé (stockage passif) pour réduire la consommation d'électricité des chambres froides de stockage à long terme. Ils ont mentionné dans leur étude qu'il existait un potentiel important pour élaborer des méthodes de contrôle avancées afin de réduire le coût de l'approvisionnement en électricité des magasins réfrigérés. Ces résultats ont montré que l'utilisation du stockage passif permet une augmentation de la température de l'air et du produit inférieure à 4 °C, lorsque la machine frigorifique était coupée pendant 8 h. Par ailleurs, le ventilateur était utilisé pour assurer des conditions d'entreposage homogènes et uniformes. Les auteurs ont aussi noté que le pré-refroidissement des magasins en périodes creuses s'était révélé être une bonne solution.

Il est à noter qu'il existe peu de travaux réalisés sur l'application de l'effacement dans le domaine du froid. L'analyse de ces études a montré que l'effacement ne provoque pas une grande variation de température du produit. Cependant, la littérature actuelle n'est pas suffisante pour évaluer les impacts que génère l'effacement sur les comportements thermique et énergétique d'un système frigorifique.

I.4 Evaluation de l'impact énergétique de l'effacement

Malgré le potentiel que représentent le stockage d'énergie par inertie thermique dans les entrepôts frigorifiques et les chambres froides pour l'application de l'effacement, il existe des

freins et des barrières qui le rendent souvent difficile à mettre en œuvre, en raison de demandes de délestage ou de consommations imprévues. Parmi ces freins, on trouve les incertitudes sur l'impact énergétique de l'effacement, qui se traduisent par les effets de rebond / report.

L'effet rebond est défini comme une demande de puissance importante pendant une courte période (un pic de consommation) au redémarrage du système après un effacement, tandis que l'effet report est lié à la surconsommation d'énergie servant à la récupération du niveau de température de référence, dans un cas sans effacement [38] (figure 3). Certains travaux sur les aspects généraux des effets rebond et report sont présentés dans la littérature [39, 40]. Cependant, en se référant aux diverses recherches consultées, aucune étude n'a examiné ces effets pour une application entrepôt frigorifique / chambre froide.




Figure 3 : Représentation de l'effacement, période de report et période de rebond [41]

Pour tenir compte de ces effets rebond et report, mais aussi de l'impact des applications d'effacement sur le stockage du produit, il est nécessaire de disposer de méthodes et d'outils permettant de comprendre et de modéliser le système étudié (entrepôt ou chambre froide contenant des produits) afin de prédire son comportement thermique.

I.5 Méthodes de modélisation

D'une façon générale, pour prédire le comportement thermique d'un système (entrepôt frigorifique / chambre froide), plusieurs approches de modélisation peuvent être considérées. Ces approches appartiennent à deux grandes familles : des méthodes fondées sur la description physique (boîte blanche) et des méthodes inverses ou mathématiques (boîte noire ou grise).

I.5.1 Approche boîte blanche

L'approche de modélisation « boîte blanche » provient des méthodes du génie des procédés. Elle est nommée aussi modélisation physique car elle utilise des équations décrivant les phénomènes physiques qui se produisent dans les systèmes étudiés. Cette approche est fondée sur un bilan thermique / énergétique qui tient compte des différents flux / charges thermiques mis en jeu : les pertes thermiques à travers les parois, la quantité d'énergie thermique stockée, la puissance frigorifique apportée, etc. [15]. Cette méthode présente l'avantage de décrire les différents composants du système et leur influence sur le comportement thermique de la chambre ou de l'entrepôt, ce qui permet d'envisager différents scénarios de variation des charges thermiques, sans nécessiter d'un nombre important de données d'entrée. L'utilisation de cette approche adaptée à la configuration physique considérée nécessite des connaissances précises sur le fonctionnement du système à étudier [42] (caractéristiques de machine frigorifique et des échanges thermiques dans l'entrepôt / chambre froide et avec l'extérieur), ce qui n'est pas toujours accessible dans un contexte industriel. Pour cela, il est nécessaire soit de formuler des hypothèses afin de simplifier le modèle (par exemple regrouper des salles d'un bâtiment en zones thermiques homogènes [43]), soit de caler certains paramètres afin de mieux représenter les conditions réelles [44]. La modélisation par cette approche nécessite donc d'exécuter plusieurs simulations pour tester différents scénarios qui permettraient d'avoir une base de données pour reproduire au mieux la réalité. Cela se traduit, ainsi, par un coût de calcul important. Par ailleurs, cette approche n'est pas généralisable en raison de la singularité de chaque système ou site industriel.

I.5.1.1 *Comportement thermique des entrepôts frigorifiques et chambres froides*

Il existe plusieurs catégories d'entrepôts et de chambres froides, classées par niveaux de température ou d'hygrométrie, type de produit stocké, position des palettes dans la salle et volume disponible [6, 45, 46]. Plusieurs études ont montré l'effet des fluctuations de température sur la qualité du produit pendant l'entreposage à différentes étapes de la chaîne du froid [36, 47]. D'autres travaux ont été réalisés pour comprendre le flux d'air et le transfert de chaleur dans les chambres froides comme les principaux facteurs affectant leur comportement thermique. Une étude expérimentale menée par Duret *et al.* [48] a observé une hétérogénéité de la température et de l'humidité avec un flux d'air non uniforme dans une chambre froide chargée. D'autres auteurs ont utilisé l'approche de la mécanique des fluides (CFD - computational fluid dynamics avec une discrétisation fine du domaine physique étudié) pour

modéliser le transfert d'air et de chaleur dans le stockage frigorifique ([49], [50], [51], [52], [53], [54]). Ils ont montré que plusieurs facteurs peuvent affecter le comportement thermique d'une salle de réfrigération tels que la température, la vitesse de l'air, l'humidité, le positionnement de la charge (produit) et de l'évaporateur / ventilateur. D'autres auteurs (Wang et Touber [55], Laguerre *et al.* [56]) ont préféré développer des modèles simplifiés utilisant des techniques de réduction de modèle pour décrire les comportements thermique et aéraulique dans une salle de réfrigération afin de réduire d'une façon importante le temps de calcul. Enfin, d'autres travaux ont étudié l'influence des conditions météorologiques, comme la température extérieure, le rayonnement solaire et l'isolation du bâtiment, sur le système de réfrigération et la charge de refroidissement [11, 21, 57-59].

1.5.1.2 *Système de réfrigération et modélisation des charges de refroidissement*

La consommation d'énergie d'un entrepôt ou d'une chambre froide est principalement due à sa machine frigorifique ; elle représente environ 35% de la consommation électrique dans l'industrie alimentaire [60]. Différents modèles mathématiques ont été développés pour réduire la consommation d'énergie pour les systèmes réfrigérés. Leducq *et al.* [61, 62] ont étudié la modélisation dynamique et le réglage optimal du contrôle des cycles de compression afin de réduire la consommation d'énergie. Glavan *et al.* [63] ont développé un modèle hybride de systèmes de réfrigération composés de trois modèles (vitrine, évaporateur et formation de glace) afin d'évaluer et de comparer les actions d'optimisation sur les systèmes de réfrigération des supermarchés. Li et Alleyne [64] ont élaboré un modèle pour le système de climatisation et de réfrigération qui tient compte des caractéristiques du cycle du compresseur lors des opérations d'arrêt et de démarrage. Cecchinato *et al.* [65] ont développé un modèle mathématique pour estimer la capacité de refroidissement / chauffage et la consommation d'énergie des unités de réfrigération et de climatisation des supermarchés à partir de conditions nominales ; différents niveaux d'intégration entre le système HVAC (*Heating, Ventilation and Air-Conditioning*) et les unités de réfrigération ont été pris en compte. D'autres études ont préféré développer des modèles mathématiques pour prédire la consommation d'énergie en fonction des caractéristiques de l'entrepôt, de la surface des magasins, du cycle de réfrigération [6, 45, 46]. La modélisation de l'enveloppe du bâtiment pour définir la charge de transmission de chaleur au travers des murs a également été étudiée [66-68]. Par ailleurs, de nombreux travaux ont modélisé certains bâtiments pour tester des méthodes et des scénarios d'effacement [22, 69].

Cependant, peu de travaux se sont intéressés à l'application de l'effacement et sa modélisation dans le domaine du froid, plus exactement dans le cas des produits congelés. A notre connaissance, seuls Brooks *et al.* [37] ont étudié expérimentalement et par modélisation l'utilisation potentielle de l'inertie thermique du produit congelé pour modifier la consommation d'électricité. Dans leur étude, ils ont utilisé des chambres froides de stockage à long terme comme site de mesure. Ils ont mentionné qu'il existait un potentiel important pour élaborer des méthodes de contrôle avancées afin de réduire le coût de consommation en électricité des magasins réfrigérés. Ils ont aussi noté que le pré-refroidissement des magasins en périodes creuses s'était révélé être une bonne solution. L'augmentation de la température de l'air et du produit était inférieure à 4 °C lorsque la réfrigération (machine frigorifique) était coupée pendant 8 h, tout en laissant le ventilateur allumé pour assurer des conditions d'entreposage homogènes et uniformes [37]. En effet, les produits congelés entreposés à l'intérieur peuvent être considérés comme des dispositifs de stockage d'énergie thermique « passifs » [37, 38] déjà disponibles pour être utilisés.

Dans la même lignée, Altwies et Reindl [7] ont exploré par modélisation l'utilisation du stockage passif d'énergie thermique par les produits stockés pour déplacer la charge frigorifique. Des modèles prenant en compte plusieurs facteurs (température de l'air, vitesse de l'air, température du produit, cycle du ventilateur) pour calculer la charge totale et le coût énergétique ont été intégrés.

Dans le cadre de la présente étude, Akerma *et al.* [70] ont investi dans une nouvelle approche de modélisation, autre que les modèles thermiques / aérauliques de type CFD, fondée sur des modèles orientés objet pour prédire le transfert de chaleur et la consommation d'énergie dans un entrepôt frigorifique afin d'évaluer l'impact énergétique de l'effacement. Ce modèle a été développé en combinant plusieurs modules (objets) : l'enveloppe de l'entrepôt, machine frigorifique, régulation, chargement...). De plus, il a été montré que les paramètres importants à prendre en considération lors d'application de l'effacement sont : la saison, le pourcentage de produits de chargement et la durée de la période d'effacement (période de puissance hors tension).

Cependant, dans certains cas, l'utilisation du stockage passif n'est pas suffisante pour apporter plus de flexibilité nécessaire à l'application de périodes d'effacement. Il est alors intéressant d'envisager un autre type de stockage « actif » en utilisant par exemple des réservoirs de stockage d'énergie thermique. Ainsi, Cui *et al.* [71] ont montré l'avantage d'utiliser ce type de

stockage actif. Dans leur configuration étudiée, lorsque 2 évaporateurs sur un total de 4 sont arrêtés pendant 2h, la température de l'air peut s'élever de 2,5°C, alors que cette même augmentation de température est limitée à 0,3 °C en présence d'une capacité de stockage « active » intégrant des PCM dans le système de réfrigération.

Ainsi, prédire le comportement d'une chambre froide ou d'un entrepôt frigorifique lors de l'application de l'effacement, en modélisant physiquement son comportement en termes de fluctuation de température et de consommation électrique, est donc réalisable. Néanmoins, comme il est dit précédemment, cette approche n'est pas généralisable en raison de la singularité de chaque système ou site industriel. En effet, le comportement du système est complexe étant donné qu'il dépend de plusieurs caractéristiques : géométrie de l'enveloppe, composition du bâtiment, apports extérieurs, production du froid, chargement, propriété thermo-physique du produit entreposé, propriétés des architectures internes... De plus, le système est dynamique compte tenu de son évolution dans le temps. Il est également dépendant des apports de chaleur lors des charges et des décharges de produits, mais aussi du mode de régulation du système frigorifique.

De par la grande complexité du système, le besoin de précision sur la modélisation boîte blanche ainsi que la sensibilité de l'approche au bruit ou à l'incomplétude des données, ce type de modèle est très intéressant pour l'identification de liens de causalité entre les paramètres. En revanche, lorsque le seul objectif de la modélisation est de prédire les sorties souhaitées à partir des variables d'entrées qu'elle reçoit, une autre approche complètement exploratoire peut s'avérer intéressante pour notre étude. Elle consiste à masquer ou ignorer les équations en posant la question « quels types de relations » peuvent y avoir entre les données. Cette approche est nommée « approche boîte noire ». En effet, celle-ci ne nécessite pas la connaissance des caractéristiques physiques du système. Elle est focalisée sur les données et l'exploration des relations existantes entre celles-ci, cela en apprenant à partir de leur comportement physique et non à partir des équations qui les décrivent. Dans notre cas, les prévisions concernent la température à l'intérieur du système ainsi que de la consommation pendant l'effacement. Afin de souligner les avantages et les limites de ce modèle, notre étude de littérature est consacrée aux modèles de type boîte noire qui sera expliqué dans la section suivante.

I.5.2 Approche boîte noire

L'approche « boîte noire », qui ne nécessite pas la connaissance des caractéristiques physiques du système, est focalisée sur les données afin d'explorer les relations existantes entre les données en apprenant à partir de leur comportement physique et non à partir des équations qui les décrivent (dans notre cas, prévision de la température à l'intérieur du système ainsi que de la consommation électrique). Le système de la boîte noire est généralement décrit par le schéma simple représenté en figure 4.




Figure 4 : Schéma d'un système « boîte noire »

L'entrée $u(t)$ et la sortie $y(t)$ ne sont pas identifiées directement. Elles sont souvent mesurées quand le système est perturbé. En effet, la modélisation par cette méthode inverse est essentiellement construite par des relations mathématiques liant les entrées et les sorties du système. Cette approche présente la particularité que ses relations soient des équations paramétrées (algébriques, différentielles, ou récurrentes) et que ces paramètres peuvent être obtenus en ayant peu, voire pas de connaissance sur le système étudié. Comme toute approche, cette méthode a des avantages et des inconvénients. Ses points forts se déclinent par la simplicité et la rapidité de réalisation, ainsi que l'indépendance des résultats avec des hypothèses ou simplifications physiques. Cette approche présente en outre l'avantage d'être facilement généralisable, du moins en présence de données suffisantes. Cependant, ce type de modélisation exige justement d'avoir une très grande base de données. De plus, en cas d'échec de la simulation, il est difficile de cibler la partie du modèle mise en cause. Par ailleurs, un manque de données est un frein pour la performance du modèle puisque dans ce cas, les données ne pouvant pas représenter l'état du système et ne permettent pas la généralisation des résultats [68].

Les opérateurs d'effacement (agrégateurs) utilisent souvent cette approche pour prédire le comportement d'un système sans avoir à le modéliser physiquement. La boîte noire dépend

complètement des données, soit expérimentales (obtenues par des capteurs de température, de pression ou d'humidité), soit issues d'un autre outil de simulation qui représente au mieux la réalité du comportement du système. Elle ne peut donc être développée que si ces données sont disponibles.

Cette méthode « boîte noire », qui appartient au domaine de l'intelligence artificielle (IA), est généralement caractérisée par un apprentissage automatique (*Machine Learning*) qui, lui-même, est un sous-ensemble de l'IA. Il est capable de reproduire un comportement complexe grâce à des algorithmes qui sont alimentés par un grand nombre de données. Pour des systèmes complexes, des méthodes appelées réseaux de neurones artificiels, s'inspirant du fonctionnement d'un cerveau humain, peuvent être considérées. De plus, si le besoin est de proposer une présentation conceptuelle détaillée du comportement du système, on peut faire appel à l'apprentissage profond (*Deep Learning*).

La figure 5 résume le lien hiérarchique des concepts suivants : IA, *Machine Learning* et *Deep Learning*.

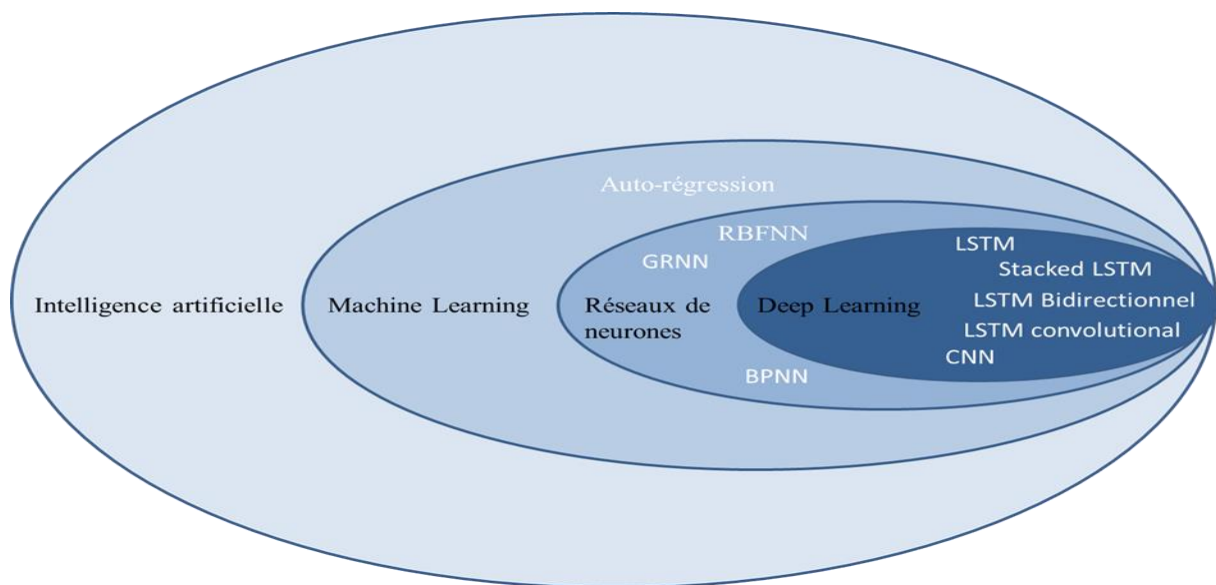


Figure 5 : Le positionnement des notations : intelligence artificielle, *Machine Learning* et *Deep Learning* [72]

L'intelligence artificielle a été développée et utilisée pour traiter plusieurs applications comme le traitement d'image, le traitement du signal ou de la langue, et ce en utilisant des données de différentes natures : images, son, segmentation des mots,...etc. Des études récentes se sont intéressées à l'importance d'utiliser les modèles IA pour la prédiction de la charge afin de décider de la meilleure façon de procéder à la réalisation de l'effacement [73].

Dans notre étude, où l'un des objectifs était de prévoir le comportement dynamique de la chambre froide, il est prioritaire de s'intéresser à l'utilisation de données temporelles - des séries temporelles.

I.5.2.1 *Séries temporelles*

Parmi les différentes données pouvant être utilisées, les séries temporelles, dites chronologiques sont définies comme une séquence de données temporelles vu que, chaque instant se trouve relié aux instants qui le précèdent ou qui le suivent. Il s'agit des séquences de points de données, mesurées généralement à des moments successifs, qui sont espacées à des intervalles de temps souvent uniformes. Les modèles de prévision de séries temporelles ont la particularité de prévoir des valeurs futures fondées sur des événements passés connus. Ces modèles peuvent être appliqués à des applications différentes [74]. Hagan et Behr [75] ont effectué l'une des premières études en 1987 en examinant des modèles basés sur des séries temporelles, utilisées pour la prévision de la charge électrique. Par la suite en 2001, N.Amjady [76] a étudié la modélisation de ces séries pour la prévision de la consommation électrique à court et moyen terme. Cette approche permet de prévoir avec précision les charges horaires des jours de semaine.

Certains auteurs ont choisi d'utiliser les données des séries temporelles pour prédire la consommation d'énergie. Taylor *et al.* [77] ont concentré leur étude pour comparer la performance des méthodes de prédiction à court-terme de la demande d'électricité, à l'aide d'une série temporelle. Aman *et al.* [78] ont travaillé dans le but d'augmenter la précision des modèles utilisés pour la prédiction de l'effacement électrique. Cette prédiction consistait à l'utilisation de très petites granularités des données de puissances électriques dans un bâtiment.

D'autres travaux se sont intéressés à l'utilisation des séries temporelles dans la modélisation à l'aide des modèles « boîte noire ». En effet, les modèles de la modélisation boîte noire peuvent être organisés en plusieurs familles. La majorité est utilisée pour la modélisation des systèmes HVAC. Compte tenu de la grande similarité entre les entrepôts / chambres froides (avec une installation frigorifique) et les bâtiments intégrés de systèmes HVAC, il serait pertinent d'analyser les travaux réalisés sur ces derniers.

D'une manière générale, les modèles boîte noire peuvent être différenciés en deux groupes : les modèles paramétriques linéaires et les modèles non-linéaires.

I.5.2.2 *Modèles linéaires*

Pour simplifier les problèmes, certains auteurs choisissent de remplacer des relations non linéaires, telle que la régulation en température d'un système de refroidissement, par des relations linéaires. Les modèles boîte noire linéaires paramétriques, utilisent des équations simples, comme les fonctions de transfert, pour présenter le lien entre les entrées et les sorties du système. En effet, ses paramètres peuvent être interprétés par les comportements physiques du système. Ces modèles ont comme avantage la facilité d'usage dans les systèmes de contrôle, contrairement aux modèles non-linéaires. Cependant, ils souffrent de la difficulté à s'adapter à des changements dans le comportement du système, comme par exemple, des changements climatiques [79]. Aussi, ils ne permettent pas de tenir compte d'une relation non linéaire entre les entrées et les sorties. Avant d'utiliser ce type de modèle, il est nécessaire de choisir l'ordre des équations liant les entrées et les sorties du système étudié.

I.5.2.2.1 Modèles d'espace d'état

Les modèles d'espace-état intègrent la distinction entre les variables observées (le signal) et les variables cachées (les états internes qui résument le comportement dynamique du système) [80]. Ce type de modèle dérive directement des données du système étudié vers l'espace-état. Il peut être décrit par des équations différentielles sous forme matricielles.

Une équation dynamique reliant les entrées $u(t)$ à l'état $x(t)$.

$$\dot{x}(t) = ax(t) + bu(t) \quad (1)$$

En ajoutant une équation statique liant l'état $x(t)$ aux sorties $y(t)$ et aux entrées, on trouve :

$$y(t) = cx(t) + du(t) \quad (2)$$

D'après ces deux équations trois variables peuvent être distingué :

$x(t)$: variable d'état du système caractérisant ses comportements.

$u(t)$: variable d'entrées du système étudié (mesures, consignes, etc.).

$y(t)$: variable de sorties.

Ces modèles d'espace d'état sont retenus par plusieurs auteurs comme les modèles paramétriques linéaires les plus testés. En effet, ils ont l'avantage de pouvoir transformer le

modèle d'état en un modèle de fonction de transfert voir même en un modèle de régression [69, 81].

I.5.2.2.2 Modèles autorégressifs

Les modèles autorégressifs sont systématiquement utilisés dans le cas où il est difficile de représenter le problème posé par des principes fondamentaux. Ils sont caractérisés par leur facilité d'adaptation et n'exigent pas de connaissances du système physique. Cependant, ils nécessitent de bien paramétrer toutes les relations qui relient les entrées et les sorties du système, afin de bien caractériser l'état du système et voir le résultat souhaité. Dans le cas des séries temporelles, la prédiction dans ce type de modèle se présente comme une extrapolation. Cette extrapolation à partir de données mesurées peut entraîner de graves erreurs, car l'évolution de chaque instant présent est reliée aux instants précédents. De plus, il est difficile de trouver l'origine des erreurs de prévision à cause des sorties des modèles qui sont très éloignées de la référence [68].

Les modèles autorégressifs qui peuvent être les plus adaptés à notre étude sont : ARMAX (*Auto Regressive Moving Average eXogenous*), ARX (*Auto Regressive eXogenous*), ARMA (*Auto Regressive Moving Average*), ARIMA (*Auto Regressive Integrated Moving*), FIR (*Finite Impulse Response*), BJ (*Box Jenkins*) et OE (*Output Error*). L'annexe 1 présente des descriptions succinctes de ces modèles.

De nombreuses études ont utilisé ces modèles pour prédire l'évolution de la température dans un bâtiment. Mustafaraj *et al.* [43] ont étudié la prédiction du comportement thermique en termes de température intérieure du bâtiment et son humidité en utilisant ARX, ARMAX, BJ et OE, pour différentes échelles de temps : 30 minutes ou 2 heures. Ils ont démontré que ces modèles donnent des prévisions raisonnables, mais que BJ surpassait les modèles ARX et ARMAX. Ríos-Moreno *et al.* [82] ont, quant à eux, comparé deux modèles autorégressifs linéaires ARX et ARMAX pour étudier le comportement dynamique de la température de l'air à l'intérieur des salles de classe. H.U. Frausto et J.G. Pieters [83] ont eux aussi étudié ces deux modèles pour prédire la température d'une serre. Ces deux travaux ont montré que ces modèles sont capables de prédire la température à l'intérieur du bâtiment. D'autres études ont testé cette catégorie de modèles sur la consommation électrique : Taylor *et al.* [77] ont utilisé le modèles ARIMA pour prédire la demande en électricité dans trois villes, Berthou [69] a choisi d'utiliser ARMAX et le modèle d'espace d'état, pour prédire la consommation dans un bâtiment.

Toutefois, peu de travaux existent sur l'utilisation des modèles de régression pour la prédiction de l'effacement. Aman *et al.* [78] ont utilisé ARMAX pour prédire la consommation d'énergie dans un campus lors de l'application de l'effacement. Ils ont montré que ce type de modèle est précis à court terme (horizon 1 h). Néanmoins, il avait un coût d'entraînement élevé, ce qui le rendait problématique pour l'effacement. Aussi, ils ont souligné que l'effacement nécessite une prévision de la consommation à très court terme pour prendre des décisions adaptatives en temps réel. De plus, afin de concevoir un modèle précis pour l'effacement, les travaux devaient exploiter des données massives.

Les avantages de ces modèles (autorégressives) sont multiples et il existe de nombreuses implémentations et études de validité, en particulier pour la prédiction des séries temporelles. Nous pouvons citer, l'avantage d'être des approximations universelles, c'est-à-dire, qui permettent de trouver des approximations relativement fiables à partir des données fournies durant l'apprentissage. Cependant, leur utilisation est assez limitée en termes de prévisions à long terme. Les résultats peuvent s'agir parfois d'approximations simplistes de la réalité.

Les principales caractéristiques des modèles sont résumées dans l'annexe 1.

1.5.2.3 *Modèles non linéaires*

En raison de la très grande complexité du système (entrepôt / chambre froide) et du besoin de précision lié à l'utilisation de la modélisation linéaire, la transition vers un autre type de modélisation plus appliqué peut-être envisagée. Lorsque l'objectif principal est de connaître le résultat final obtenu à la sortie du système, sans égard au fonctionnement interne, il peut être intéressant d'examiner l'utilisation des modèles non linéaires, dont le seul but est de prédire les paramètres de sortie à partir des entrées. Cela représente en outre l'avantage d'être beaucoup plus facilement généralisable, au moins en présence de données de qualité suffisante et en trouvant un modèle correspondant à notre problématique. Il s'agit, en effet, d'adapter les différents paramètres lors de l'étude d'un nouveau système.

Il existe plusieurs modèles non linéaires, parmi eux : les machines à vecteurs de supports ou séparateurs, la logique floue et les réseaux de neurones. Dans le cadre de notre travail, le choix s'est porté sur les réseaux de neurones artificiels.

Les réseaux de neurones artificiels (ANN) sont des systèmes informatiques dont la conception est inspirée du fonctionnement du cerveau humain.

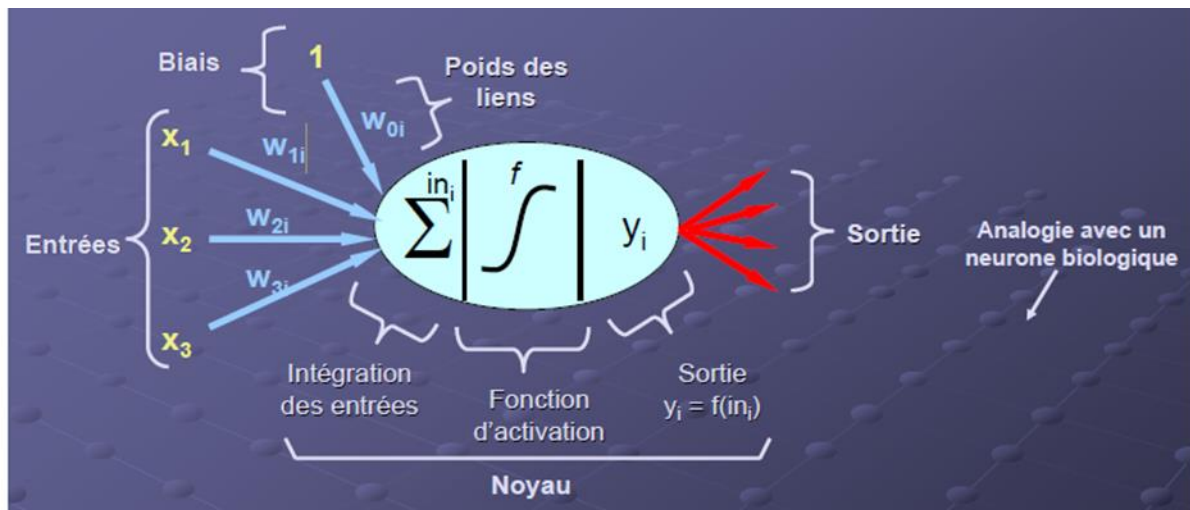


Figure 6 : Schéma d'un neurone artificiel A. Doncescu [84]

Un neurone artificiel est composé d'après la figure 6 de :

Entrée : provient de sources externes à l'entrée du système ou bien d'un autre neurone.

Biais : toujours caractérisé par une entrée égale à 1 qui permet d'ajouter de la flexibilité au réseau en permettant de varier le seuil de déclenchement du neurone par l'ajustement du poids du biais lors de l'apprentissage.

Poids : facteurs multiplicateurs qui affectent l'influence de chaque entrée sur la sortie du neurone.

Noyau : intègre toutes les entrées et les biais puis calcule la sortie du neurone selon une fonction d'activation. Cette fonction d'activation nous indique la manière dont le calcul de la sortie a été fait. Il existe plusieurs types de fonctions d'activation (linéaire, non-linéaire, Relu...[85]). Le choix de la fonction se fait au regard du type de calcul le mieux adapté à la problématique mais aussi à la fonction qui donnera les meilleurs résultats possibles.

Sortie : représente une sortie directe du système, ou peut être distribuée vers d'autres neurones.

Les réseaux de neurones forment une méthode d'apprentissage largement considérée comme très prometteuse, offrant une nouvelle façon de résoudre des problèmes complexes. La capacité des ANN à apprendre et à cartographier des relations non linéaires complexes, a permis de traiter plusieurs problèmes liés à la prédiction et l'analyse de données [86].

La littérature a démontré aussi leur capacité supérieure à modéliser des processus non linéaires et à trouver des solutions rapides par rapport aux méthodes conventionnelles, telles que la

prédiction de la demande de puissance (charge) ou la consommation d'énergie dans différents secteurs du bâtiment. Ces modèles ont une bonne capacité d'apprentissage et une particularité de généralisation des relations pour un ensemble de données. Ils permettent de fournir rapidement des estimations satisfaisantes. Bien qu'ils soient performants, ces modèles sont soumis à des phénomènes de sur-apprentissage difficilement contrôlables et leurs initialisations sont moins robustes. A noter aussi leur sensibilité aux entrées et le besoin d'avoir une très grande base de données.

Il existe plusieurs grandes familles de réseaux de neurones artificiels classiques : des réseaux à propagation avant (*feed-forward*) et des réseaux de neurones récurrents (recurrent neural network - RNN).

Un réseau à propagation avant est un réseau où l'information se propage de la couche d'entrée vers la couche de sortie, sans avoir ni un retour ni un stockage de l'information.

Un réseau de neurones récurrent est un réseau dans lequel l'information peut se propager dans les deux sens. Entre autre, il dispose de connexions arrière donc, il existe des cycles dans sa structure. Ces cycles permettent au réseau de neurones récurrents d'entretenir des informations passées lors du traitement de l'information à l'instant présent. De ce fait, ils permettent d'apprendre et de stocker l'information.

Toutefois, un réseau de neurones, de n'importe quelle famille qu'il soit, peut être distingué en deux catégories selon son architecture. En effet, il existe des réseaux de neurones perceptron **simple** et des réseaux de neurones perceptron **multiple**.

Les modèles de réseaux de neurones à perceptron simple sont des classifieurs linéaires, basés sur des algorithmes d'exploitation. Les relations qui relient les entrées et les sorties peuvent être des relations linéaires ou non linéaires, comme le montre la figure 7. Cette figure présente un réseau de neurones à perceptron simple possédant 3 couches, une couche d'entrée, une couche cachée et une couche de sortie.




Figure 7: Représentation graphique pour un réseau de neurones artificiel simple

Par ailleurs, les réseaux de neurones à perceptron multicouches (*Multi-Layer Perceptron*) sont composés essentiellement de trois niveaux de couches : l'entrée, la sortie et plusieurs couches cachées.

Une fois l'architecture du réseau fixée, il faut lui définir un algorithme de propagation des connexions (et mise à jour des poids) reliant les neurones entre deux couches successives et ce depuis la couche d'entrée jusqu'à la couche de sortie. Le but étant de tendre la configuration des connexions vers un modèle acceptable c'est-à-dire capable de donner une réponse en sortie très proche de la sortie prévue, pour une nouvelle entrée.

Pour cela, les algorithmes simples de propagation sont :

- de propagation avant de propager l'information (*Back Propagation* (BP)), au travers de ses couches successives, de la couche d'entrée à la couche de sortie, et sans avoir un retour de l'information en arrière. Les poids sont mis à jour à chaque nouvelle entrée. Ce type de propagation cherche à minimiser la distance (*score*) calculée entre la sortie attendue et la sortie obtenue [87],
- de retro-propagation : cherche à minimiser l'Erreur Quadratique Moyenne en utilisant un paramètre d'ajustement des poids pour minimiser davantage le score. Cette étape d'optimisation est le cœur des algorithmes d'apprentissage profond.

Li *et al.* [11] ont utilisé un réseau de neurones simple (3 couches) pour BPNN et un réseau de fonctions de base radiale (*Radial Basis Function* (RBFNN)) afin de prévoir les charges de refroidissement dans un bâtiment. S. Karatasou *et al.* [88] ont préféré l'utilisation d'autres types de réseaux de *neural feed-forward* (propagation directe, l'information circule uniquement de la couche d'entrée vers la couche de sortie) avec une seule couche cachée, afin de prédire la consommation énergétique dans un bâtiment.

Toutefois, ces réseaux de neurones simples sont limités pour traiter des problèmes complexes (comme par exemple, dans le cas de la prédiction de l'effacement) qui exigent une plus grande précision. A savoir, d'une part, ces réseaux se caractérisent par un apprentissage souple (ils ne possèdent que trois couches). D'autre part, leur utilisation dépend de la forme du réseau de neurones sur laquelle va s'appuyer l'identification et nécessite une longue durée d'apprentissage, pouvant varier de 2 jours à 2 ans [14]. De plus, ces réseaux n'acceptent pas les données bruitées et la classification non linéaire.

Plus un problème est complexe, plus il semble naturel de rajouter des couches intermédiaires au réseau pour augmenter l'apprentissage. Cette méthode est appelée apprentissage profond « *Deep Learning* », qui est l'une des nombreuses techniques utilisées en *Machine Learning*.

Les réseaux de neurones profonds (*Deep Learning*) sont simplement des perceptrons multicouches (*Multi-Layer Perceptron*) contenant au-delà de trois couches. D'une manière générale, quel que soit le réseau de neurones (simple ou multicouches), la méthode d'apprentissage peut être supervisée ou non supervisée.

L'apprentissage supervisé nécessite des interventions humaines pour contrôler et assurer la disposition des valeurs des poids du réseau. Inversement, pour l'apprentissage non supervisé, la connexion des neurones et les valeurs des poids se définissent de façon totalement autonome.

Seulement deux études se sont intéressées à la prédiction de la température et de la consommation électrique dans des bâtiments par l'apprentissage profond « *Deep Learning* » [12, 13].

Xu *et al.* [12] a étudié l'utilisation d'une nouvelle architecture d'apprentissage profond pour prévoir le comportement de la température de l'air à l'intérieur d'un bâtiment. L'objectif de cette étude était d'explorer le potentiel du modèle réseau de neurones récurrent à mémoire court et long terme (LSTM). Les performances de prévision de cette architecture (*Deep Learning* (DL)) LSTM ainsi que deux autres modèles communs de *Machine Learning* ont été aussi

explorés à savoir, *Support vector machine et Back Propagation Neural Network*. Cela dans le but de valider l'applicabilité et la supériorité du modèle d'apprentissage de *Deep Learning*. La validation de ces modèles a été faite sur des données expérimentales de la température intérieure avec un pas de temps de 5 min et 30 min recueillies dans un bâtiment pendant 2 mois. Les résultats montrent que le modèle LSTM présente de légers avantages par rapport aux autres modèles *Machine Learning* pour la prévision de la température intérieure, c'est-à-dire une augmentation du coefficient R^2 , allant de 1 % à 9,73 % avec un horizon de prévision de 5 minutes. Cette étude a mis en avant l'utilisation du modèle LSTM pour prédire la température intérieure dans un bâtiment.

Dans le cadre de la prédiction de l'effacement, aucune méthode de type « *Deep Learning* » ne semble avoir été appliquée pour prédire le comportement du système en termes de fluctuation de température ou de consommation électrique, dans le domaine du froid. Compte tenu de l'importance énergétique de ce domaine qui offre un panel d'opportunités significatives, l'utilisation d'une approche de modélisation pertinente peut démontrer (ou valider) l'utilisation de l'effacement dans les chambres froides et les entrepôts frigorifiques et aussi permettre (ou non) une augmentation significative de son application.

Parmi les modèles de *Deep Learning* existant, notre étude se basera sur les 5 modèles suivants : modèle de réseau de neurones convolutif, modèle de réseau récurrent à mémoire court et long terme (LSTM), LSTM Enchaîné (Stacked), LSTM Bidirectionnel, LSTM Convolutif.

Les modèles *Deep learning* prédictifs ont été choisis pour deux raisons. La première étant liée à la non-linéarité de ces modèles, compte-tenu la nature des données de la chambre froide, la seconde liée à leur performance de prédiction à partir de séries temporelles. En effet, ils apprennent les liens temporels existants entre les données et à partir desquels, sont capables ensuite de prédire le comportement du futur. Parmi ces modèles, ceux qui s'intéressent à la reconnaissance des formes ou à l'analyse des objets considérant seulement leurs informations spatiales ont été écartés car ils ne sont pas adaptés à notre type de données. Notre choix s'est porté sur les modèles récurrents qui tiennent compte de la répartition temporelle des données, précisément les modèles LSTM et leurs dérivés (modèle de réseau récurrent à mémoire court et long terme (LSTM), LSTM Enchaîné (Stacked), LSTM Bidirectionnel, LSTM Convolutif). En effet, ces derniers sont capables de mémoriser les événements passés en terme de changement de comportement et de les utiliser pour ajuster les résultats de la prédiction. Toutefois le modèle Convolutif classique a été comparé aux modèles LSTM pour vérifier notre

hypothèse mais aussi l'inadéquation de ce type d'architecture aux types des données que nous traitons. En effet, dans notre cas, la chambre froide est caractérisée par un comportement thermique et énergétique complexe (période de dégivrage, période d'effacement et cycle marche / arrêt du compresseur).

I.5.2.3.1 Modèle de réseau de neurones convolutif

Le réseau neuronal convolutif (CNN) est l'un des réseaux les plus populaires en l'apprentissage profond utilisé pour les traitements d'images et des vidéos, car il est basé sur le principe de calcul de similarité entre les données. Comme les autres réseaux neuronaux, il est composé d'une couche d'entrée, une couche de sortie et de nombreuses couches cachées. Le CNN est inspiré du cortex visuel des animaux, empilement multicouche de perceptrons (*MLP feed-forward*), qui sont très performants dans la reconnaissance de formes. En effet, ce modèle utilise un prétraitement pour trouver des caractéristiques sur de petites quantités de données. Le CNN utilise le concept de partage du poids pour les signaux entrants de chaque neurone d'un noyau de convolution, ce qui réduit la place de mémoire et améliore les performances.

He [89] a proposé une nouvelle architecture de réseau de neurones profond pour la prévision de charge à court terme (prévision un jour à l'avance des charges horaires basées sur l'apprentissage profond) à l'aide de nouveaux composants de réseaux de neurones convolutifs (CNN).

Plusieurs couches sont en général incluses dans un modèle convolutif (figure 8) :

- couches de convolution qui traitent les données d'entrées. Chaque couche porte une fonction d'activation, intégrée dans le but d'augmenter la convergence.
- couches de Max Pooling utilisées pour compresser l'information en réduisant la taille des données intermédiaires (sous-échantillonnage) et mettant en commun les sorties.
- couches entièrement connectées de type perceptron. Ces couches intègrent une fonction de coût (perte) qui indique dans quelle mesure le résultat obtenu est éloigné du résultat souhaité.

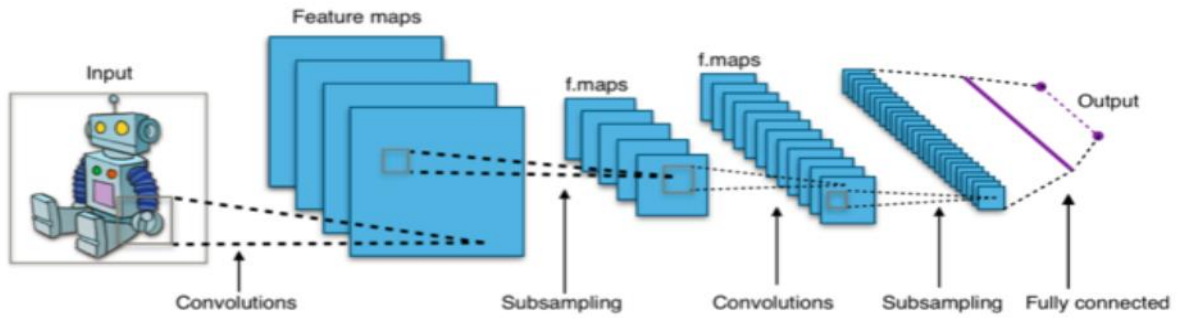


Figure 8 : Comportement d'un modèle Convolutif [90]

I.5.2.3.2 Modèle de réseau récurrent à mémoire court et long terme (LSTM)

Le réseau LSTM est un réseau neuronal récurrent utilisé dans l'apprentissage profond. Il dispose d'une structure de connexions en cycles et a été utilisé pour résoudre de nombreux problèmes séquentiels de type séries temporelles [91]. Ce réseau local dans l'espace et dans le temps, est également conçu pour résoudre les problèmes de dépendance à long terme.

Une unité LSTM commune est composée d'une **cellule**, d'une **porte d'entrée** « i » (*Input Gate*), d'une **porte de sortie** « o » (*Output Gate*) et d'une **porte d'oubli** « f » (*Forget Gate*). La cellule sert à conserver les valeurs, alors que les trois portes permettent de réguler le flux d'informations entrant et sortant de la cellule.

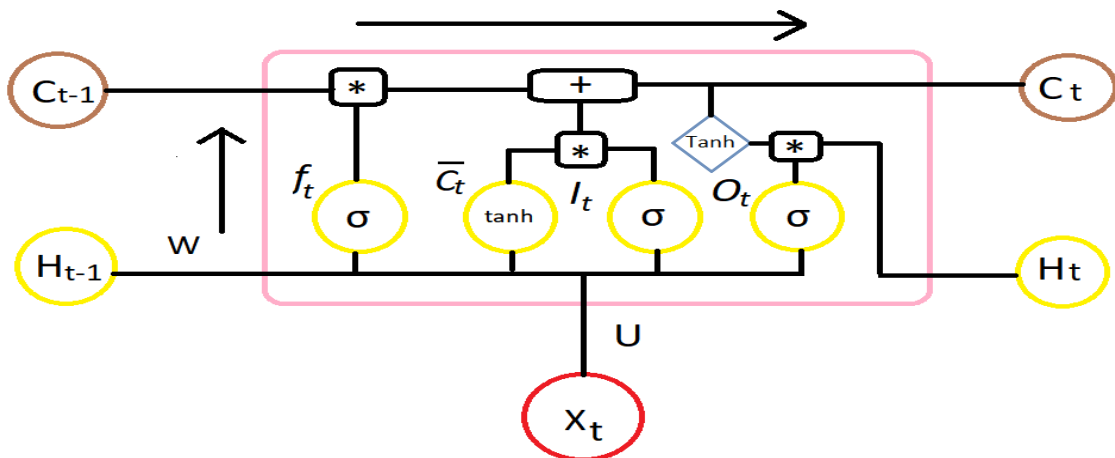


Figure 9 : Structure de l'unité LSTM [92]

D'après la figure 9, les équations de l'unité s'écrivent facilement de la manière suivante :

$$I_t = \sigma(U_i * X_t + W_i * H_{t-1} + b_i) \quad (\text{Porte d'entrée}) \quad (3)$$

$$O_t = \sigma(U_o * X_t + W_o * H_{t-1} + b_o) \quad (\text{Porte de sortie}) \quad (4)$$

$$f_t = \sigma(U_f * X_t + W_f * H_{t-1} + b_f) \quad (\text{Porte de sortie}) \quad (5)$$

$$\bar{C}_t = \tanh(U_c * X_t + W_c * H_{t-1} + b_c) \quad (\text{Couche candidate}) \quad (6)$$

$$C_t = C_{t-1} * f_t + \bar{C}_t * I_t \quad (7)$$

$$H_t = \tanh(C_t) * O_t \quad (8)$$

Avec :

X_t : Vecteur d'entrée.

H_{t-1} : Sortie de la cellule précédente (le vecteur de la couche cachée précédente).

C_{t-1} : Mémoire de la cellule précédente.

H_t : Sortie de la cellule actuelle ou bien, le vecteur de la couche cachée.

C_t : Mémoire de la cellule actuelle.

σ est la fonction d'activation (logistique),

* est le multiplicateur élément par élément,

+ est l'addition élément par élément,

\tanh est la fonction tangente hyperbolique de h utilisée pour les fonctions de transfert

U et W sont les matrices servant de paramètres au modèle.

Ce type de réseau a été développé pour contourner les problèmes de convergence de gradient, dans le but d'apprendre à mémoriser des événements passés qui sont généralement rencontrés dans les réseaux neuronaux récurrents.

En général, le LSTM fournit de bons résultats prévisionnels, car il permet de conserver l'information à court terme (changements récents et tendances actuelles des données) et à long terme (périodicité, événements récurrents ou non récurrents).

D. L. Marino *et al.* [93] ont montré que le LSTM standard est capable de prédire les données de consommation électrique sur les données de charge à pas de temps d'une heure, pour un horizon de 60 h. Ils ont également démontré la supériorité de la mémoire à court terme (LSTM) fondée sur le modèle de séquence à séquence, par rapport aux réseaux récurrents standards.

Ping-Huan et Chiou-Jye [94] ont utilisé les modèles CNN et LSTM pour prédire la demande d'électricité durant 1 mois sur des données expérimentales de la consommation électrique, d'un site en Texas, d'une durée de 2 mois pour l'apprentissage. Cette étude montre que le modèle

LSTM peut traiter les problèmes séquentiels dans le temps, et la prévision était correcte. Toutefois, le modèle CCN proposé pour la révision des charges (connu sous le nom *DeepEnergy*) donne de bons résultats de prédiction avec une très grande précision, d'une valeur moyenne de MAE=0,8 (Eq. 32) et RMSE=17,9 (Eq. 34).

I.5.2.3.3 LSTM-Stacked (Enchaîné)

Un modèle LSTM empilé, ou LSTM-Stacked, consiste en un empilement de plusieurs couches LSTM simples, mises bout à bout, et où chaque couche LSTM contient plusieurs cellules de mémoire (figure 10).

Dans certains problèmes de prédiction, il est en effet très avantageux d'augmenter la profondeur d'un réseau pour obtenir de meilleurs résultats. Hermans et Schrauwen [95] ont donné une interprétation de ce type de réseau plus profond, comme une chaîne de traitement (*pipeline*), où chaque couche traite une partie du problème puis communique cela à la couche suivante. Cette méthode a été initiée et appliquée au traitement de la reconnaissance de la voix par Graves *et al.* [96], qui ont trouvé que la profondeur du réseau pouvait être bien plus importante que le nombre de cellules de mémoire dans un réseau LSTM.

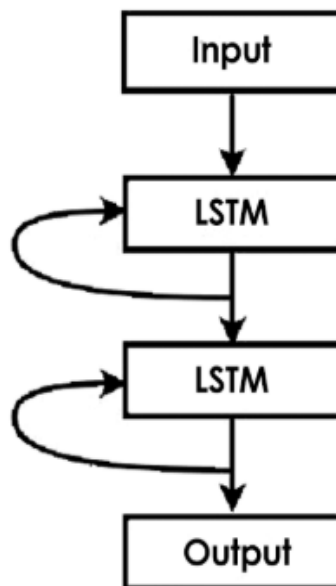


Figure 10 : Exemple de LSTM Stacked [97]

I.5.2.3.4 LSTM Bidirectionnel

Les modèles de réseaux de neurones bidirectionnels, proposés par Sutskever *et al.* [98] en 1997, ont pour objectif d'augmenter l'efficacité des réseaux de neurones pour relier les unes aux autres en fonction de leur ordre dans la base de données à traiter.

Cela est notamment le cas pour la majorité des systèmes de traitement des données spatiales et temporelles, où la proximité et l'enchaînement des données peuvent fournir des informations permettant l'obtention de très bons résultats de prédiction.

Dans le cas des réseaux bidirectionnels, il s'agit donc de relier à la fois les données passées et futures en tant qu'informations pour la prédiction. Autrement dit, sont connectées les deux couches cachées de directions opposées à la même sortie (figure 11).




Figure 11 : Exemple d'un réseau LSTM Bidirectionnel [99]

Graves *et al.* [87] ont ainsi trouvé que l'utilisation de réseaux bidirectionnels, et notamment dans le cadre des LSTM, permettait d'avoir des résultats significativement meilleurs que les réseaux unidirectionnels et ce, dans le cas des phénomènes acoustiques, phonétiques et les systèmes de reconnaissance automatique de la parole.

L'architecture d'un réseau LSTM consiste donc en l'enchaînement de couches LSTM à la fois pour les données passées et les données à venir, qui sont ensuite traitées ensemble afin de prédire les données courantes.

Althelaya *et al.* [100] ont utilisé Stacked LSTM et bidirectionnel LSTM pour la prévision des marchés boursiers à court et à long terme. Ils ont démontré que LSTM bidirectionnel donnait de meilleurs résultats avec une erreur absolue moyenne de $MAE < 0,008$.

I.5.2.3.5 LSTM Convolutif

Un modèle LSTM Convolutif est un modèle LSTM où les transformations d'entrée (input-to-state) et les transformations récurrentes (state-to-state) sont convolutives, ce qui permet donc d'associer les deux types de modèles ensemble (figure 12).

Ce modèle a été proposé à partir du modèle LSTM entièrement connecté (*Fully Connected LSTM*) [101], notamment pour son application à la prédiction des précipitations sur des images spatiales. Ce modèle leur a permis d'obtenir de bien meilleurs résultats qu'avec un simple réseau LSTM ou *Fully-Connected LSTM*. Ceci a ainsi prouvé l'efficacité potentielle de ce modèle dans certaines applications, et a entraîné plusieurs utilisations par la suite.




Figure 12 : Exemple d'un modèle LSTM convolutif [102]

Le CNN-LSTM est surtout utilisé pour le traitement de données vidéo ou de captures d'images récurrentes dans le temps, puisqu'il associe un LSTM (très utilisé pour l'étude au cours du temps) et un réseau convolutif (très utilisé pour l'étude des images).

De nombreuses études récentes se sont intéressées à la prédiction de la demande en électricité en utilisant les modèles de *Deep Learning*. T-Y. Kim et S-B. Cho [103] ont utilisé le modèle

LSTM - CNN pour prédire la consommation d'électricité dans une maison. Dans cette étude ils ont démontré la facilité d'utilisation de ce modèle et sa performance comparée à d'autres méthodes d'apprentissage automatique profondes de type multi-perceptron (MLP).

Ping-Huan et Chiou-Jye [104] quant à eux, se sont intéressés à la prédiction du coût de l'électricité. Cette étude a démontré la faisabilité et l'aspect pratique d'utiliser un modèle hybride de type CNN-LSTM. Afin de comparer ce modèle hybride CNN-LSTM avec les modèles de *Machine Learning* traditionnels (CNN, LSTM, MLP), les mesures d'évaluation de l'erreur absolue moyenne (MAE) et de la racine de l'erreur quadratique moyenne (RMSE) ont été appliquées dans leurs tests. Les résultats des expériences montrent qu'en comparant ce modèle hybride CNN-LSTM avec les modèles de *Machine Learning* traditionnels (CNN, LSTM, MLP), le modèle hybride s'était avéré être le meilleur candidat pour la prévision des prix d'électricité.

Encore une fois, à notre connaissance, il n'existe pas de travaux sur l'application de ces modèles (convolutif, LSTM, Stacked LSTM, Bidirectionnel LSTM, LSTM-CNN) sur la prévision de la température ou de la consommation électrique dans le domaine du froid, spécialement dans les entrepôts frigorifiques et chambres froides.

1.5.2.4 Bilan sur les modèles boîte noire

L'analyse bibliographique montre qu'il est possible de modéliser un système de type entrepôt et chambre froide avec des modèles linéaires simples et des modèles non-linéaires de type boîte noire.

Deux catégories de modèles existent, les modèles paramétriques (avec les équations) et non paramétriques avec les réseaux de neurones. Parmi des réseaux de neurones, l'utilisation des réseaux de neurones profonds est prometteuse pour apprendre les comportements complexes d'un système sous réserve que l'on dispose d'un grand volume de données couvrant l'ensemble des comportements types du système.

Le tableau ci-dessous représente un sommaire des études faites sur la comparaison des différents modèles boîte noire, afin de déterminer le modèle le plus adapté aux besoins de chaque étude.

Tableau 1 : Récapitulatif des différents articles sur la modélisation des bâtiments avec les modèles boîte noire.

Etude – Objet de prédiction (température / puissance)	Boîte noire			Horizon de prédiction	Nature des données (simulée /mesurée) / Pas d'acquisition	CONCLUSION
	AR	ANN simple	DL			
Rabl 1988 [58] / chauffage Puissance	✓			4.75 jours	Mesurée / --	Equation d'état plus performante qu'ARMAX pour la prédiction de la consommation électrique
H.U.Fransto et al 2003 [105] / refroidissement Température	✓			1 année	Simulée / 5min	ARX plus performant qu'ARMAX pour la prédiction de la température
A.BenNakhi 2003 et al [57] / refroidissement Puissance		✓		1 année	Simulée / heure et jours	GRNN le plus performant pour prédire les charges en refroidissement
G.J.Riomoreno et al 2007 [82] / chauffage et refroidissement Température	✓			15 jours	Mesurée / 5 min	ARX plus performant que ARMAX inspiré de Fransto 2003
Mustafaraj et al 2010 [43] Température	✓			57 heures	Mesurée / 5 min	Bj plus performant qu'ARMAX et ARX
Mustafaraj et al 2011 Mustafaraj <i>et al.</i> [14] Température	✓	✓		114 heures	Mesurée / 5 min	NNARX plus performant qu'ARX
T.Berthou 2012 [22] Puissance et Température Refroidissement et chauffage	✓	✓		1 semaine	Simulée / 6 min	NNARX est plus performant que les équations d'état
T.Berthou 2012 [69] Puissance et Température	✓	✓		1 semaine	Simulée / 6 min	Modèle d'équation d'état plus performant qu'ARMAX
Ping-Huan et al [94] Puissance			✓	1 mois	Mesurée / --	LSTM et CCN-LSTM donnent des résultats corrects pour la prédiction de la consommation électrique. CNN-LSTM plus performant

* ✓ étudié

A partir de ce tableau, il apparaît que ces travaux se sont intéressés à la prédiction de la température et de la puissance dans des bâtiments en utilisant des données soit simulées ou soit mesurées, mais jamais les deux types de données en même temps, ce que nous proposons de faire dans notre étude. D'après notre étude bibliographique, les prédictions ont été réalisées principalement par des modèles autorégressifs ou des modèles de réseau de neurones simple, mais peu de travaux existent sur l'utilisation des modèles Deep Learning. De plus, leur utilisation pour la prédiction de la température et de la puissance lors d'un effacement dans le domaine du froid n'a pas encore été réalisée à notre connaissance. Une approche utilisant les méthodes de Deep Learning pour ce cas d'application constituerait un travail original.

L'originalité de notre étude consiste ainsi à comparer plusieurs modèles de Deep Learning (CNN, LSTM, LSTM-Stacked, LSTM-Bidirectionnel, LSTM-Convolutif) pour la prédiction de l'évolution de la température et de la puissance lors d'un effacement dans une chambre froide. Ces modèles doivent faire face à la diversité des sources des données.

1.5.2.5 Interaction des deux approches de modélisation

Comme vu précédemment, la modélisation du comportement du système par approche boîte blanche, qui est une modélisation fondée sur des équations physiques, nécessite une connaissance précise d'un ensemble de paramètres. En revanche, la modélisation par approche boîte noire a besoin d'une grande base de données. Ainsi, chaque méthode présente des avantages et des inconvénients.

A titre d'exemple, afin d'utiliser la boîte blanche pour la prédiction, il est nécessaire de connaître avec précision plusieurs paramètres de tous les composants et les différents échanges qui se produisent à l'intérieur du système. Autrement, il existe des sources d'aléas qui sont liées, soit à la spécification (le type de matériaux, la géométrie et le fonctionnement énergétique à l'intérieur du système) soit à la modélisation (simplification de la géométrie et les phénomènes physiques, zonage) [106]. Par conséquent, certains paramètres doivent être ajustés pour avoir une meilleure prédiction et représenter au mieux la réalité [107]. D'autres désavantages peuvent être cités comme les incertitudes de simulation introduites lors de la discrétisation et la simulation numérique, mais aussi les coûts de calculs. Enfin, la prédiction des comportements thermique / énergétique d'un système donné, à plusieurs scénarios, nécessite plusieurs simulations.

Ce type d'approche est difficilement généralisable. Si l'objectif final n'est pas de reproduire tous les phénomènes physiques qui se produisent à l'intérieur du système, mais plutôt de s'intéresser uniquement aux données de sortie du système (ici le niveau de température de l'air, des produits...), quelques auteurs ont privilégié l'utilisation de la représentation simplifiée du système étudié et à l'identification des paramètres de ce modèle afin de minimiser les erreurs de prédiction.

La modélisation par approche boîte noire qui ne demande pas des connaissances précises sur la structure interne d'un composant ou d'un système, a aussi plusieurs limites. A noter que la prédiction avec ce type d'approche nécessite de collecter des données massives de plusieurs scénarios. Ceci a pour but d'entraîner le modèle à apprendre le comportement du système pour

mieux prédire la sortie désirée. Les données d'entrée et de sortie dépendent des données expérimentales qui ne sont pas toujours facilement disponibles. De ce fait, d'autres auteurs ont préféré remplacer des données mesurées par celles issues d'un modèle de type boîte blanche. Celui-ci peut générer un grand nombre de données dans des conditions variables et extrêmes. Un autre avantage de ce type de données est qu'elles ne sont pas perturbées par des bruits des capteurs.

Puisque chaque approche possède ses propres avantages et inconvénients, actuellement, de nombreux auteurs s'intéressent à l'interaction et au couplage de ces deux approches de modélisation, boîte noire et boîte blanche, pour la prédiction des charges électriques et de la température interne d'un système. Ce couplage peut être réalisé en créant un modèle, nommé « boîte grise », qui englobe des caractéristiques et des avantages des deux approches.

Le modèle boîte grise est un modèle hybride ou nommé semi physique utilisant une représentation physique simplifiée pour présenter la structure du système. L'identification des paramètres se fait en utilisant la performance de la boîte noire afin de minimiser les erreurs de prévision.

Berthou [69] a utilisé un modèle boîte grise de type R6C2 d'ordre 2 pour prévoir la puissance de climatisation et la température intérieure moyenne en chauffage et en refroidissement. Il s'agit d'un modèle inspiré de l'analogie électrique / thermique avec des résistances R et des capacités C qui s'écrit sous forme d'équations par une loi des nœuds. Il est à souligner que ce type de modèle est largement utilisé pour des bâtiments. Il a également permis de simuler les différents scénarios d'effacements. Les résultats ont démontré que ce modèle (R6C2) est robuste face à des situations inconnues (scénarios d'effacement), absence de la phase d'apprentissage. Toutefois, il nécessite des connaissances supplémentaires sur le bâtiment à modéliser.

Tian *et al.* [108] ont utilisé un modèle boîte grise pour simuler la charge de refroidissement à l'intérieur d'un entrepôt à Pékin. Ils ont noté que leur modèle boîte grise de type R2C3 repose principalement sur la précision et la robustesse des capteurs de température, en particulier celui de la température ambiante. Les résultats de la simulation ont été validés avec la puissance mesurée des compresseurs.

Dans le cadre de notre travail, une autre méthode de couplage sera testée. Cette méthode utilise le modèle boîte blanche afin de générer une base de données pour alimenter la boîte noire. En

effet, ce couplage peut être utilisé dans le cas de manque de données expérimentales ou quand leur rassemblement est difficile (par exemple à cause de leur nature ou leur taille) pour l'apprentissage et la validation des modèles.

Berthou et al. [18] ont utilisé un modèle boîte blanche pour générer des données (modélisation sous *TRNsys*) pour alimenter la boîte noire de type modèles linéaires (équations d'état, ARMAX et fonction de transfert) et non linéaires (réseaux de neurones NNARX). Cette étude a pour but de mettre en place des stratégies d'effacement dans un bâtiment. Les résultats montrent que le modèle boîte noire a de bonnes performances de prédiction pour représenter les stratégies d'effacement.

Ben-Nakhi et Mahmoud [52] quant à eux, ont utilisé un modèle boîte blanche (code de simulation *ESP-r*) pour collecter les données (entrées et sorties) pour alimenter le modèle boîte noire (réseau de neurones simple) afin de prédire les charges de refroidissement de trois bâtiments. Les résultats montrent que le modèle réseau de neurones prédit avec précision les profils de charge de refroidissement. Cette étude a mis en avant la prévision des réseaux de neurones simples fondée sur l'utilisation de la température extérieure.

Mercier et Uysal [109] ont utilisé un modèle de transfert thermique pour générer les données de températures à l'intérieur d'une palette qui est soumise à différentes températures ambiantes. Ce modèle est par la suite utilisé afin de développer un réseau de neurones pour prédire les températures périssables des produits dans la palette. Ils ont démontré qu'un réseau de neurones alimenté à partir d'un modèle de transfert de chaleur peut prédire la distribution de la température à l'intérieure d'une palette avec une erreur moyenne petite (RMSE <0,5 K).

I.6 Conclusion

Dans ce chapitre, un inventaire des différents travaux existants dans la littérature a été réalisé. Plusieurs sujets ont été abordés :

- méthodes d'application de l'effacement dans plusieurs secteurs (industriel, bâtiment et le froid),
- comportement thermique de la chambre froide / entrepôt frigorifique,
- systèmes de réfrigération et méthodes de modélisation des charges thermiques - approche boîte blanche,
- approche boîte noire,
- interactions entre les deux approches de modélisation.

Cette partie a permis de mettre en avant les avantages que présentent les entrepôts frigorifiques et les chambres froides, grâce au stockage d'énergie thermique « passif » apporté par leur chargement, pour l'application de l'effacement afin de réduire leur consommation électrique. Cependant, malgré ces avantages, il existe bien des impacts qui rendent l'effacement difficile à mettre en œuvre, à savoir son influence sur le comportement thermique de l'air et du chargement, sur le fonctionnement de la machine frigorifique et la consommation du système frigorifique.

Par ailleurs, ce chapitre a montré l'importance de prédire le comportement thermique d'un système (chambre froide / entrepôt frigorifique) lors de l'application de l'effacement, afin de respecter la température et la qualité des aliments. Cette prédiction peut se faire par deux approches de modélisation : boîte blanche et boîte noire. Cette étude a également souligné la robustesse de la prédiction en utilisant les modèles réseaux de neurones de type *Deep Learning* qui est un sujet d'actualité. De nos connaissances, il n'existe pas de travail sur l'utilisation de ces modèles (*Deep Learning*) pour la prédiction de la consommation ou de la température dans le domaine du froid en général, et tout particulièrement lors de l'application de l'effacement.

Finalement, des possibilités d'interaction et de couplage des deux approches ont été examinées. Elles peuvent devenir des solutions par rapport aux problèmes de manque de données expérimentales pour l'apprentissage et la validation des modèles *Deep Learning*.

Chapitre II : Etude expérimentale de l'effacement dans une chambre froide et dans un entrepôt frigorifique

L'objectif de ce chapitre est d'étudier expérimentalement l'effet de l'application de l'effacement dans une chambre froide et dans un entrepôt frigorifique. Tout d'abord, le développement d'un dispositif expérimental – une chambre froide laboratoire, a été réalisé dans le but de caractériser l'effacement et d'analyser l'effet des différents paramètres, à savoir le chargement et les conditions opératoires, sur le comportement thermique de l'air et du chargement. Puis, de nouveaux indicateurs pour caractériser les impacts de l'effacement ont été proposés afin d'étudier l'impact de l'effacement sur le comportement thermique, le fonctionnement de machine frigorifique et la consommation du compresseur. Une campagne de mesure a également été réalisée dans un entrepôt frigorifique industriel. Celle-ci a été effectuée dans le cadre du projet Flexifroid, par un autre lot de travaux en dehors de cette thèse. Toutefois, elle a été présentée dans ce manuscrit afin de permettre une analyse comparative des effets de l'effacement à une échelle plus grande que celle de la chambre froide.

Un nouveau dispositif expérimental - une chambre froide laboratoire a été développée dans cette étude afin de pouvoir effectuer un ensemble de mesures difficilement réalisables dans un entrepôt industriel. En effet, les contraintes liées aux mesures dans un site industriel sont multiples :

- contraintes de qualité et d'hygiène : risque de dégradation des produits,
- contraintes techniques : manque de capteurs ou absence de capteurs adaptés pour évaluer par exemple l'état de chargement, quantité de produits lors des chargements ou déchargements, état d'ouverture des portes, flux de personnes et de véhicules ... ,
- contraintes réglementaires : des effacements avec une remontée de la température au-dessus de la température réglementaire ne sont pas par exemple envisageables,
- contraintes liées à l'activité de l'entrepôt : la position des capteurs doit prendre en compte le flux des personnes et véhicules, des mesures dans un entrepôt vide ne sont pas envisageables dans le projet Flexifroid,
- contraintes climatiques : la mesure doit être réalisée sur une période de temps suffisamment longue pour avoir des conditions météorologiques différentes.

Quelques mesures sur site ont été néanmoins effectuées et ont été utilisées pour valider le modèle boîte blanche sur une configuration différente de la chambre froide.

II.1 Développement d'un dispositif expérimental – Chambre froide laboratoire

Le dispositif expérimental principalement constitué d'une chambre froide en laboratoire a été développé pour cette étude. Il s'agit d'une chambre froide réelle utilisée par des industriels pour l'entreposage des produits de température négative. Représentée par la figure 13, la chambre froide occupe un volume de $11,5 \text{ m}^3$ (2,4 m de longueur, 2,4 m de largeur et de 2,1 m de hauteur). Elle a été construite avec des panneaux isolants en polyuréthane (10 cm d'épaisseur, $\lambda_{\text{paroi}} = 0,023 \text{ W m}^{-1} \text{ K}^{-1}$). Le coefficient de transfert de chaleur global mesuré de la chambre est de $0,29 \text{ W m}^{-2} \text{ K}^{-1}$. Cette valeur est légèrement supérieure aux valeurs communes pour les entrepôts ($\sim 0,15 \text{ W m}^{-2} \text{ K}^{-1}$), ceci s'expliquant principalement par un rapport surface des parois / volume de la chambre plus important que celui d'un entrepôt de grande dimension.




Figure 13 : Chambre froide avec 4 palettes (chacune chargée de 392 kg de quartzite)

La température ambiante de la chambre froide est contrôlée à l'aide d'une machine frigorifique qui fonctionne avec une stratégie de régulation marche / arrêt du compresseur. La machine frigorifique est placée en partie supérieure d'un mur, près du plafond, à une extrémité de la chambre. Elle fonctionne grâce à un système à détente directe utilisant le R404A comme fluide frigorigène. Elle est dotée d'un seul évaporateur (en serpentins) et d'un ventilateur à débit unitaire constant de $1931,5 \text{ m}^3 \text{ h}^{-1}$. De plus, elle est équipée d'un système de dégivrage à gaz chaud permettant de maintenir la marche du compresseur et d'éteindre le ventilateur pendant la période de dégivrage. Le coefficient de performance (COP) de cette machine frigorifique a été mesuré (voir l'annexe 2) : sa valeur de 1,4 a été obtenue à $-16 \text{ }^\circ \text{C}$. Un boîtier de commande installé à l'extérieur de la chambre permet de réguler les paramètres d'utilisation suivants : la température de consigne, le régime du compresseur, les périodes de dégivrages et les alarmes.

Cette chambre froide a été installée à l'intérieur d'une autre chambre, appelée « cellule externe », de grandes dimensions de 3,39 m de longueur, 4,47 m de largeur et 3 m de hauteur. La cellule externe est équipée d'un climatiseur pour simuler différentes conditions météorologiques. Les portes de la chambre froide et de la cellule externe ont été maintenues fermées pendant toutes les périodes d'essais afin de ne pas perturber le fonctionnement intérieur de la chambre froide et de la cellule externe.

II.1.1 Chargement de la chambre

Quatre palettes en bois (contreplaqué) de dimensions extérieures de 0,7 m de longueur, 0,7 m de largeur et 1,4 m de hauteur sont utilisées pour l'entreposage du produit (figure 14).




Figure 14 : Palette en bois utilisée pour le chargement

Afin de simuler le comportement du produit congelé pendant un stockage à long terme, le quartzite [110] a été choisi comme matériau de stockage de substitution car ses propriétés thermiques (conductivité, chaleur spécifique et diffusivité thermique) sont similaires à celles des carottes congelées [111], comme le montre le tableau 2. Chacune des quatre palettes contient 392 ± 2 kg de quartzite en vrac, pour un poids total de quartzite de 1568 kg.

Tableau 2 : Propriétés thermo-physiques du quartzite et de la carotte

Produit	Quartzite [110]	Carotte [111]
Densité, ρ , kg m^{-3}	2650	969
Chaleur spécifique, C_p , $\text{kJ kg}^{-1} \text{K}^{-1}$	0,74	2
Capacité thermique volumétrique, ρC_p , $\text{kJ m}^{-3}\text{K}^{-1}$	1960	1940
Diffusivité thermique, $\rho^{-1} C_p^{-1} \lambda$, $\text{m}^2 \text{s}^{-1}$	$7,65 \times 10^{-8}$	$7,22 \times 10^{-8}$
Conductivité thermique dans un empilement, λ , $\text{W m}^{-1} \text{K}^{-1}$	0,15	0,13

II.1.2 Instrumentation

Deux types de capteurs ont été utilisés pour mesurer la température instantanée : 56 thermocouples de type T (précision de $\pm 0,1$ ° C) pour les températures de l'air et de la surface du produit à l'intérieur de la chambre froide ainsi que la température de l'air dans la cellule externe et 12 sondes PT100 (précision $\pm 0,15$ ° C) pour la température du produit au centre des 4 palettes (voir la figure 15 a et b).

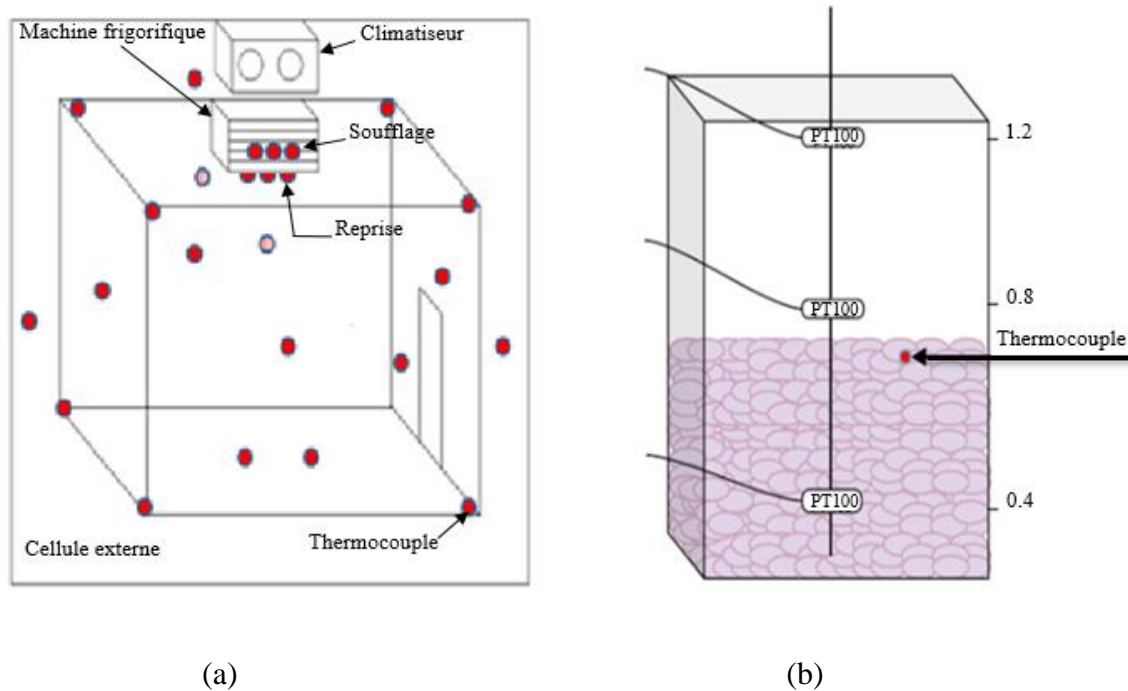


Figure 15 : Disposition de l'instrumentation du système

- Instrumentation des thermocouples à l'intérieur de la chambre froide et dans la cellule externe
- Instrumentation des sondes de PT100 à l'intérieur de la palette

Le comportement thermique du produit est caractérisé par deux températures : une à la surface du produit et une autre au cœur de la palette. Chacune est représentée par la valeur moyenne obtenue par quatre capteurs (1 dans chaque palette).

Deux wattmètres (Digiwatt, précision 2%) ont été utilisés afin de suivre la mesure instantanée de la puissance électrique consommée, l'un par la machine frigorifique dans sa totalité, l'autre par le compresseur uniquement.

Les données ont été enregistrées avec deux pas de temps de 5 et de 20 secondes. Les premières expériences ont été réalisées avec un pas de temps de 5 s afin de pouvoir capter des variations rapides. Dans un second temps, suite aux problèmes d'acquisition, nous avons opté pour un pas

de temps plus grand (20 s) pour les autres expériences. Il est à noter qu'un cycle de variation de température est d'environ de 5 minutes (cycle marche / arrêt du compresseur, Cf. tableau 14).

L'ensemble des capteurs (voir tableau 3) ont été raccordés à une centrale de mesure pilotée par un ordinateur de bureau pour suivre l'évolution de la température de l'air (à l'intérieur de la chambre et dans la cellule externe) et du produit ainsi que la consommation électrique du système de réfrigération.

Tableau 3 : Liste des capteurs

Type de capteur	Nombre	Précision
Thermocouple de type T	56	$\pm 0,1 \text{ } ^\circ \text{C}$
PT100	12	$\pm 0,15 \text{ } ^\circ \text{C}$
Wattmètres	2	2%

II.1.3 Protocole expérimental

Le protocole expérimental avait pour objectif de permettre la caractérisation de l'évolution de la chambre froide et des produits lors d'effacements de durée variable. Il avait également pour but d'identifier le rôle des paramètres les plus influents sur ce comportement tels que la durée de l'effacement, la température à l'extérieur de la chambre, le taux de remplissage en produits ainsi que la température de consigne à l'intérieur de la chambre.

L'ensemble des mesures recueillies ont été ensuite utilisées pour fournir aux modèles « boîte noire » les données nécessaires à l'apprentissage et à la validation. Ces mêmes données ont été également utilisées pour valider le modèle « boîte blanche ».

La figure 16 illustre le protocole expérimental suivi au cours de chaque essai. Chaque expérience est composée de trois étapes, à savoir une étape de refroidissement (AB) en partant de la température ambiante dans la chambre, une étape de stabilisation (BC) qui permet d'obtenir une température homogène dans la chambre et les produits, puis l'étape d'effacement (CD).

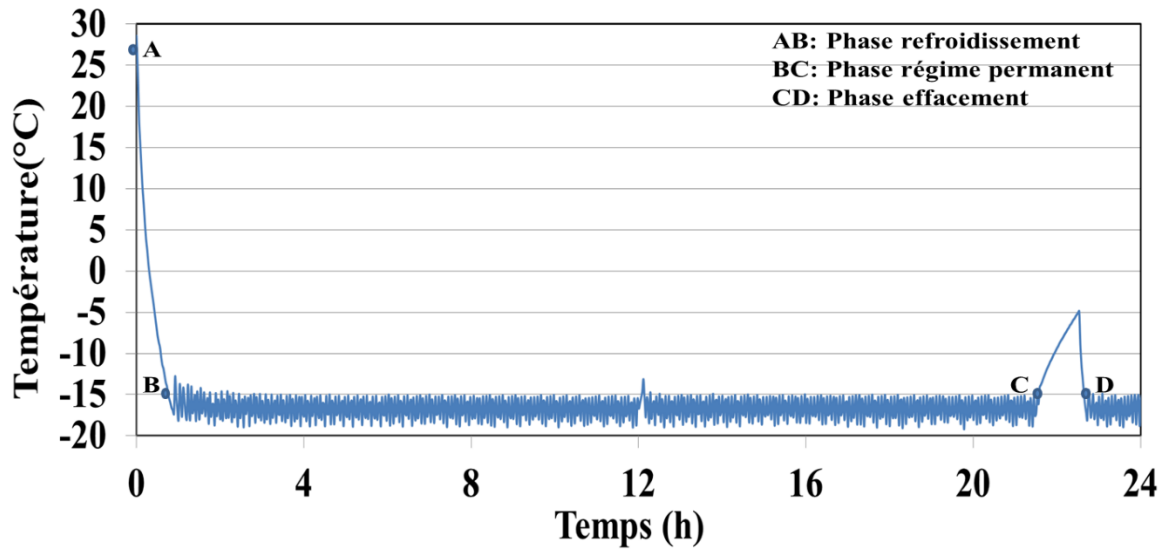


Figure 16 : Exemple de protocole expérimental pour les essais avec la chambre vide

Au cours de la phase de refroidissement, une phase de préparation de la chambre qui n'existe pas dans une procédure réelle d'effacement dans un entrepôt, la machine frigorifique refroidit la chambre jusqu'à la température de consigne définie (mesurée par un capteur à la reprise). Ensuite, lors de la phase du régime permanent, la chambre est maintenue à la température de consigne. Les cycles de dégivrage automatiques (caractérisés par un petit pic de température comme on peut le voir dans la figure 16) ont lieu toutes les 12 h pour la chambre vide, et toutes les 6 h pour la chambre chargée. Le dégivrage de l'évaporateur est réalisé par gaz chaud. Au cours de la phase d'effacement, le compresseur est éteint tandis que les ventilateurs de la machine frigorifique sont maintenus en fonctionnement pour assurer des conditions de stockage uniformes [37]. L'effacement est appliqué entre deux périodes de dégivrage afin que le dégivrage ne puisse pas affecter l'analyse de la période d'effacement.

Seules les étapes du régime permanent (BC) et de l'effacement (CD) seront présentées dans les résultats.

II.1.4 Configurations et paramètres étudiés

Plusieurs tests ont été réalisés pour étudier l'impact des paramètres suivants sur l'effacement :

- chargement : chambre froide vide et chargée.
- température extérieure : 17 ° C (climat tempéré) et 30 ° C (climat chaud). Cette gamme de température (entre 17 et 30) correspond à la gamme de température extérieure

observée au cours des mesures effectuées dans l'entrepôt industriel (entre 14 et 19, température au mois de février où les mesures ont été effectuées). Il faut aussi noter que les limites de température (17°C et 30 °C) étaient imposées par des limitations techniques de la cellule externe.

- température de consigne : -18 ° C (valeur standard pour le produit congelé) et -5 ° C (valeur maximale pour le système froid étudié). La valeur de -5°C a été choisie pour permettre d'observer des différences significatives de comportement thermique en fonction de la température intérieure de la chambre, mais ne correspond pas cependant à des valeurs usuelles de fonctionnement dans un entrepôt en situation réelle.
- durée de l'effacement : 1 h, 2 h et 3 h. Ces durées sont les durées d'effacement les plus souvent rencontrées lors des délestages du réseau en site industriel. Il est rare de procéder à des effacements de plus longue durée.
- fréquence de l'effacement : 1 effacement / jour pendant 3 jours, ou 1 effacement / 3 jours.

Pour chaque test, la période de stabilisation est de 5 jours en moyenne pour la chambre chargée. Le passage à la phase d'effacement est déclenché lorsque les variations de température au cœur de la palette sont inférieures à une tolérance fixée (+ / - 0,15 °C). Ainsi, la durée moyenne d'un test (la phase du régime permanent et la phase d'effacement) atteint 10 jours.

Le tableau 4 résume les scénarios étudiés. Dans tous ces scénarios, la durée de la phase où les effacements (Eff) sont appliqués est de 3 jours. Dans le scénario de référence et les scénarios 1, 2 et 3, trois effacements successifs de durées 1 h, 2 h et 3 h avec une fréquence d'un effacement / jour sont réalisés. Dans le scénario de référence, la chambre froide est chargée, la température de consigne est fixée à -18 °C et la température de la cellule externe est réglée à 30 °C. Selon chaque scénario 1, 2 ou 3, un seul paramètre, soit le chargement, soit la température de consigne, soit la température extérieure respectivement, est modifié tandis que les autres paramètres sont conservés avec la même valeur que le scénario de référence. Pour les scénarios 4, 5 et 6, un seul effacement est réalisé pendant 3 jours pour tester une fréquence d'effacement différente. Pour chaque scénario (4, 5 et 6), un seul paramètre, à savoir la durée de l'effacement (1 h, 2 h et 3 h respectivement), est modifié. Les autres paramètres (le chargement, la température de consigne et la température extérieure) sont maintenus à la même valeur que le scénario de référence. Pour finir, le scénario 7 correspond à une expérience d'anticipation pour limiter la remontée de la température du produit au cœur des palettes due à l'effacement : la

température de consigne a été diminuée de 1°C pendant 1 journée avant l'application d'un effacement d'une heure.

Tableau 4 : Scénarios étudiés

Scénario	Chargement	Fréquence de l'effacement	Température de consigne (°C)	Température extérieure (°C)
Scénario de référence- 3 Eff	Chargée	1 Eff / jour	-18	30
Scénario 1 - 3 Eff, <i>chambre vide</i>	Vide	1 Eff / jour	-18	30
Scénario 2 - 3 Eff, <i>augmentation $T_{consigne}$</i>	Chargée	1 Eff / jour	-5	30
Scénario 3 - 3 Eff, <i>diminution T_{ext}</i>	Chargée	1 Eff / jour	-18	17
Scénario 4 - 1 Eff d'1 heure	Chargée	1 Eff / 3jours	-18	30
Scénario 5 - 1 Eff de 2 heures	Chargée	1 Eff / 3jours	-18	30
Scénario 6 - 1 Eff de 3 heures	Chargée	1 Eff / 3jours	-18	30
Scénario 7 - Anticipation, eff d'une heure $T_{consigne}$ à -19 pendant le premier jour	Chargée	1 Eff / 3jours	-18 après le premier jour	30

II.1.5 Développement des indicateurs pour caractériser les impacts de l'effacement

Au vu des longues périodes d'effacement, qui peuvent varier d'1 à 3 heures pendant lesquelles le compresseur de la machine frigorifique est arrêté, plusieurs impacts sur la température de l'air et du produit dans la chambre froide d'une part et sur le fonctionnement de la machine d'autre part, peuvent être générés. Afin d'analyser ces impacts, de nouveaux indicateurs ont été proposés en répondant aux questions suivantes :

- quels sont les niveaux d'augmentation de la température de l'air et du chargement au cours des effacements ?

- l'effacement modifie-t-il le fonctionnement de la machine frigorifique lors de son redémarrage ? Si oui, quelle est la durée nécessaire après un effacement pour que la machine frigorifique retrouve son fonctionnement normal (avant l'effacement) ?
- la consommation est-elle modifiée suite aux effacements ?

Nous apportons les réponses à ces questions dans la suite de ce chapitre au travers des scénarios décrits plus haut.

II.1.5.1 Impact de l'effacement sur le comportement thermique de l'air et du chargement

La figure 17 présente l'évolution de la température de reprise avant, pendant et après l'application de l'effacement. Cette température est la moyenne de 3 mesures de température de l'air à la reprise de l'évaporateur (voir figure 15a). Une augmentation significative est observée pendant l'effacement et se caractérise par un pic (valeur maximale, T_{max_eff}). Avant et après l'effacement, le comportement de l'air subit les variations dues aux cycles marche /arrêt du compresseur.

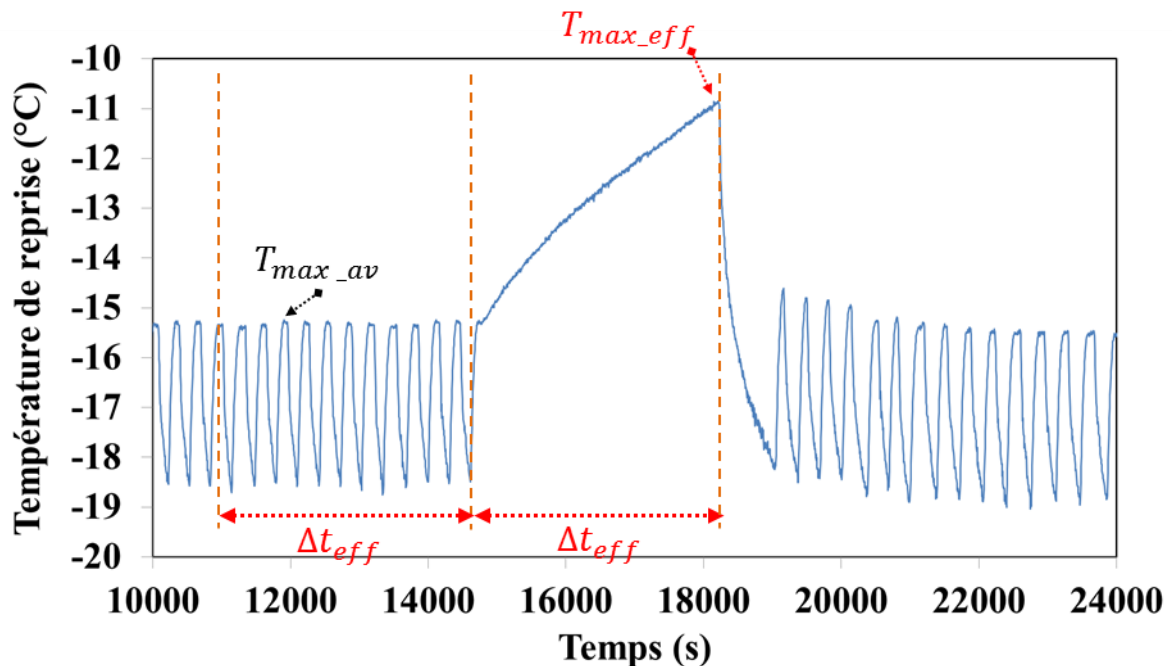


Figure 17: Evolution de la température de l'air à la reprise au cours d'un effacement

L'indicateur ΔT_{max} (°C) a été défini pour caractériser l'augmentation de la température lors d'un effacement :

$$\Delta T_{max} = T_{max_eff} - T_{max_av} \quad (9)$$

Avec :

T_{max_eff} -la valeur de température maximale obtenue durant la période d’effacement

T_{max_av} la valeur de température maximale obtenue durant la période qui précède l’effacement, une période de la même durée que l’effacement (Δt_{eff}) est utilisée pour déterminer cette valeur.

L’indicateur ΔT_{max} est appliqué pour évaluer l’impact de l’effacement sur :

- la température de l’air à la reprise $\Delta T_{max_reprise}$ (°C) : elle représente la température de l’air issue des échanges thermiques avec les produits et les murs de la chambre froide.
- la température à la surface du produit $\Delta T_{max_surface}$ (°C) : la surface est l’endroit du produit (Cf. figure 15b) le plus sensible à la variation de température de l’air.

Ce critère n’a pas été appliqué pour la température du produit au cœur des palettes car cette température peut continuer à augmenter même après l’effacement à cause de l’inertie thermique du produit (Cf. IV.1.1.2.1.2 Impact sur le produit).

II.1.5.2 Impact de l’effacement sur les performances de la machine frigorifique

Le fonctionnement de la machine peut être analysé au travers de l’évolution temporelle de la puissance du compresseur. Ce dernier, en régime établi (régime permanent) cyclique fonctionne par des cycles réguliers marche / arrêt comme le montre la figure suivante.

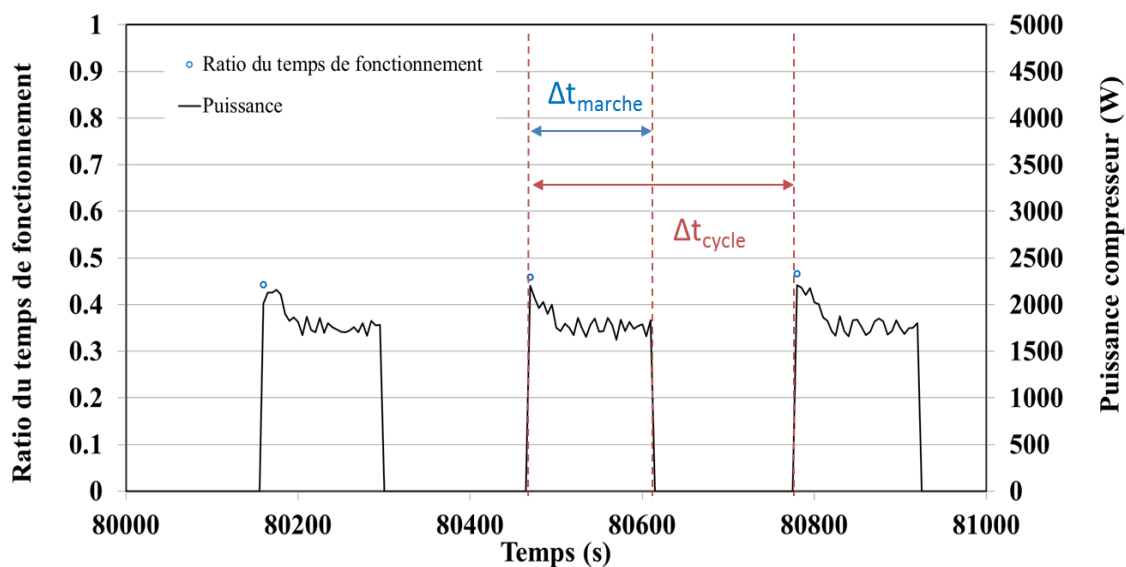


Figure 18 : Evolution temporelle de la puissance du compresseur en régime établi

Pour un cycle marche / arrêt, un ratio de temps de fonctionnement, $ratio_{fonc}$ (représenté par des points bleus dans la figure 18) peut être défini par le rapport :

$$ratio_{fonc} = \frac{\Delta t_{marche}}{\Delta t_{cycle}} \quad (10)$$

La figure 19 montre l'évolution de la puissance du compresseur et du $ratio_{fonc}$ avant, pendant et après un effacement; l'effacement, dans ce cas, correspond à la période de 2 heures pendant laquelle le compresseur est éteint (puissance = 0 W). La valeur moyenne du $ratio_{fonc}$ (m) pendant toute la durée de l'expérience (4 jours) est représentée par la droite horizontale violette (les valeurs $> 0,6$ ne sont pas prises en compte). Les deux parallèles rouges en pointillées représentent les seuils suivants : $m \pm$ l'écart type du $ratio_{fonc}$.

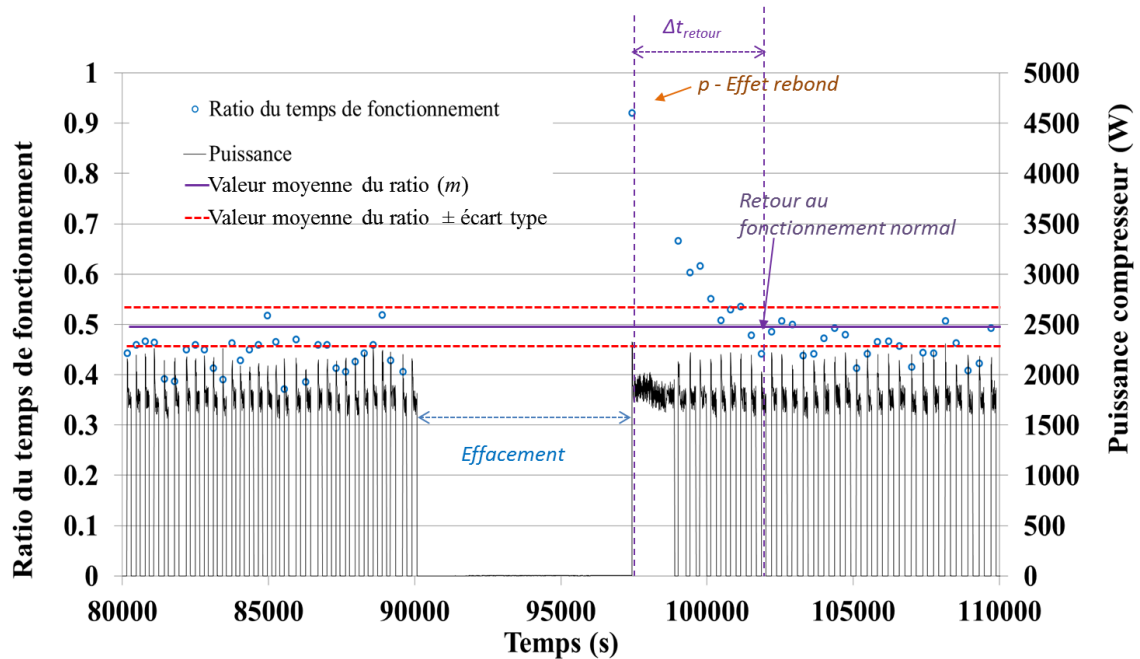


Figure 19: Evolution temporelle de la puissance du compresseur et du ratio du temps de fonctionnement au cours d'un effacement de 2 heures (scénario de référence)

Lors du régime établi avant l'application de l'effacement, le ratio de fonctionnement varie autour de sa valeur moyenne ($m = 0,454$ dans ce cas). Il est à noter que cette valeur est différente d'une expérience à une autre car elle dépend du scénario étudié. Juste après l'effacement, un pic (p) du $ratio_{fonc}$ est observé. Ce pic, nommé « effet rebond », correspond au 1^{er} cycle marche / arrêt après l'effacement où le temps de marche est nettement plus important que celui des cycles en régime établi. Ce fonctionnement intensif est dû à l'augmentation de la température de l'air et du produit pendant l'effacement, il continue pendant un certain temps jusqu'à ce que le $ratio_{fonc}$ retrouve ensuite son niveau avant l'effacement.

Deux indicateurs sont définis suite à cette analyse :

- taux de rebond :

$$taux_{rebond} = \frac{p-m}{m} \quad (11)$$

Avec m : valeur moyenne du $ratio_{func}$ et p : valeur du $ratio_{func}$ lors du pic de l'effet rebond

- le temps nécessaire pour le retour au fonctionnement normal est appelé : Δt_{retour} (h)

Le retour au fonctionnement normal, comme représenté par la figure 19, est le temps entre le redémarrage de la machine frigorifique et le moment où la valeur du $ratio_{func}$ diminue pour la première fois après l'effacement en dessous de sa valeur moyenne (courbe violette). Comme les autres indicateurs, il s'agit d'une nouvelle définition proposée par cette étude.

II.1.5.3 *Impact de l'effacement sur la consommation du système frigorifique*

Afin d'analyser l'impact de l'effacement sur la consommation, l'énergie consommée lors de chaque scénario de l'effacement E_{avec_eff} (tableau 4) est comparée à l'énergie consommée dans les mêmes conditions sur la même durée et sans effacement E_{sans_eff} . Un indicateur est défini par la différence Δe (%) entre ces consommations.

Cette différence peut être aussi défini par Δe en MégaJoule:

$$\Delta e = E_{avec_eff} - E_{sans_eff} \quad (12)$$

Le taux de consommation, Δe (%), entre l'énergie consommée avec et sans effacement est calculée par :

$$\Delta e = \frac{E_{avec_eff} - E_{sans_eff}}{E_{sans_eff}} \times 100\% \quad (13)$$

Les indicateurs proposés dans cette étude sont récapitulés dans le tableau 5. A notre connaissance aucun travail n'a été réalisé sur les indicateurs de l'effacement pour les systèmes frigorifiques

Tableau 5 : liste des indicateurs développés dans le cadre de cette thèse

Indicateur	Signification
$\Delta T_{\max_reprise}$ (°C)	Augmentation maximale de la température de l'air à la reprise lors de l'effacement
$\Delta T_{\max_surface}$ (°C)	Augmentation maximale de la température à la surface du chargement lors de l'effacement
$taux_{rebond}$	Effet rebond - Augmentation du ratio de temps de fonctionnement – pic de rebond après l'effacement
Δt_{retour} (h)	Temps pour le retour au fonctionnement normal après un effacement
Δe (%)	Différence entre l'énergie consommée avec ou sans effacement sous les mêmes conditions de fonctionnement

II.2 Etude expérimentale dans un entrepôt frigorifique

Afin d'observer les impacts de l'effacement dans un entrepôt industriel et valider le modèle boîte blanche dans une configuration différente que celle de la chambre froide, des mesures ont été réalisées dans un entrepôt frigorifique. Ces mesures, réalisées dans le cadre du projet Flexifroid par un autre lot de travaux en dehors de cette thèse, seront présentées dans ce manuscrit afin de permettre une analyse comparative des effets de l'effacement dans deux configurations de différentes échelles.

II.2.1 Présentation de l'entrepôt

L'entrepôt dans lequel les mesures ont été effectuées est de 125 m de longueur, 50 m de largeur et 11 m de hauteur. Cela correspond à un volume de 6875 m³, soit presque 600 fois le volume de la chambre froide. L'isolation est assurée par une couche de polyuréthane de 15 cm. En ce qui concerne le sol, la température est régulée par un système de chauffage à 2 °C sous l'isolant afin d'éviter la dilatation et la rupture de la dalle. Cet entrepôt est équipé de sept évaporateurs situés à 10 m de hauteur (voir la figure 20) :

- trois évaporateurs à droite de 116 kW unitaire, 714 m² de surface d'échange totale, et de quatre ventilateurs de 4 kW chacun.
- quatre évaporateurs à gauche de 105 kW unitaire, 714 m² de surface d'échange totale, comportant quatre ventilateurs de 4 kW chacun.




Figure 20 : Vue de haut de l'entrepôt frigorifique

Dans l'entrepôt, les produits sont stockés en vrac dans des palettes ; ces produits sont d'abord placés dans une enveloppe plastique, puis installés à l'intérieur de palettes en bois hermétiquement fermées afin de limiter le transfert de masse entre l'intérieur et l'extérieur. Chaque palette de volume (1,2 m de longueur x 1 m de largeur x 1,6 m de hauteur) contient 1000 kg de légumes surgelés (voir le tableau 2). La masse totale des produits est de l'ordre de 16000 tonnes.

Pour l'instrumentation, des capteurs de type iButton (précision de $\pm 0,3$ °C) non étalonnés ont été utilisés pour mesurer la température de l'air et du produit à la surface et au cœur de la palette.

II.2.2 Protocole de mesure

Trois essais d'effacement ont été réalisés avec une fréquence d'un effacement par jour et avec des durées croissantes de 1 h, 2 h et 4 h.

La température de l'air a été mesurée dans plusieurs emplacements à l'intérieur de l'entrepôt. Cette température est représentée par la moyenne des mesures obtenues par tous les capteurs. Pour le comportement thermique du produit, celui-ci est caractérisé, comme dans le cas de la chambre froide, par deux variables :

- la température à la surface du produit : elle est obtenue en calculant la valeur moyenne des mesures de deux capteurs placés à la surface de la palette (voir la figure 21),
- la température au cœur de la palette (voir la figure 21).




Figure 21 : Instrumentation des iButtons à la surface et au cœur de la palette.

La méthode d'application de l'effacement est la même que celle appliquée dans le cas de la chambre froide. En effet, l'installation frigorifique est totalement arrêtée tandis que les ventilateurs sont maintenus en marche.

Chapitre III : Modélisation boîte noire et boîte blanche

L'objectif de cette partie est d'étudier les méthodes de modélisation - boîte noire et boîte blanche ainsi que leur couplage. La modélisation boîte blanche appliquée aux deux systèmes étudiés, c'est-à-dire la chambre froide laboratoire et l'entrepôt industriel, sont présentés. Les charges thermiques prises en compte dans ce modèle physique ont été élaborées. Pour la modélisation boîte noire, les modèles Deep Learning développés, leurs caractéristiques et les séries de données utilisées sont présentés. Plusieurs systèmes de combinaison des variables d'entrée et de sortie sont considérés pour ces modèles. Le choix des critères de performance de prédiction des modèles est également abordé. Enfin, une étude sur l'interaction entre les deux approches a été décrite.

III.1 Approche boîte blanche

Comme discuté dans le chapitre consacré à l'état de l'art, deux grandes approches candidates de modélisation peuvent être appliquées, la boîte blanche et la boîte noire. Cette partie est focalisée sur l'étude de l'approche de modélisation dite « boîte blanche », qui consiste à décrire les phénomènes physiques par des expressions mathématiques. Cette approche s'appuie donc sur la connaissance de la physique du système.

Dans notre cas, 2 systèmes seront étudiés :

1. système industriel : un entrepôt industriel avec une installation frigorifique.
2. système laboratoire : une chambre froide où le maintien en température est assuré par un groupe froid.

Ces systèmes (entrepôt et chambre froide) sont dynamiques. Ils sont caractérisés par l'évolution des phénomènes physiques (variation de la température extérieure, chargement de nouveaux produits, ouverture des portes...) au cours du temps. L'état futur de ces phénomènes dépend de leur état présent ou passé (série temporelle). De plus, dans le cas de la mise en place des scénarios d'effacement (réduction de la ventilation, coupure complète du groupe froid...), de fortes variations de température de l'air à l'intérieur (par exemple : 10°C dans le cas de scénario de référence pour un effacement de 3 h dans la chambre froide) peuvent apparaître.

Le modèle thermique utilisé dans cette partie a été développé dans le cadre du projet Ademe Flexifroid (<https://flexifroid.irstea.fr>), dans un autre lot de travaux en dehors de la thèse. Toutefois, cet outil (développé sous Python et les bibliothèques *Numpy et Scipy*) a été utilisé dans ce travail afin de tester 2 configurations : chambre froide laboratoire et entrepôt industriel. Les simulations ont été réalisées par un PC de bureau (Windows 7, Intel Core i7-6700 CPU, 3,4 GHz et 16 Go). Une interaction de cet outil avec les modèles « boîte noire » a été également proposée (Cf .III.3). Ce modèle a été développé en tenant compte des fortes contraintes sur le temps d'exécution (temps de calcul devant être inférieur à une dizaine de secondes pour un outil web) et sur la robustesse de la simulation. Il est ainsi composé d'un ensemble d'équations différentielles décrivant les transferts thermiques entre la paroi et l'air de l'entrepôt, entre l'air et les produits, le transfert à l'intérieur du produit par conduction, d'un inventaire des charges thermiques dans la chambre froide ou dans l'entrepôt et inclut également un modèle de cycle thermodynamique afin de prédire la performance et la consommation électrique du groupe frigorifique.

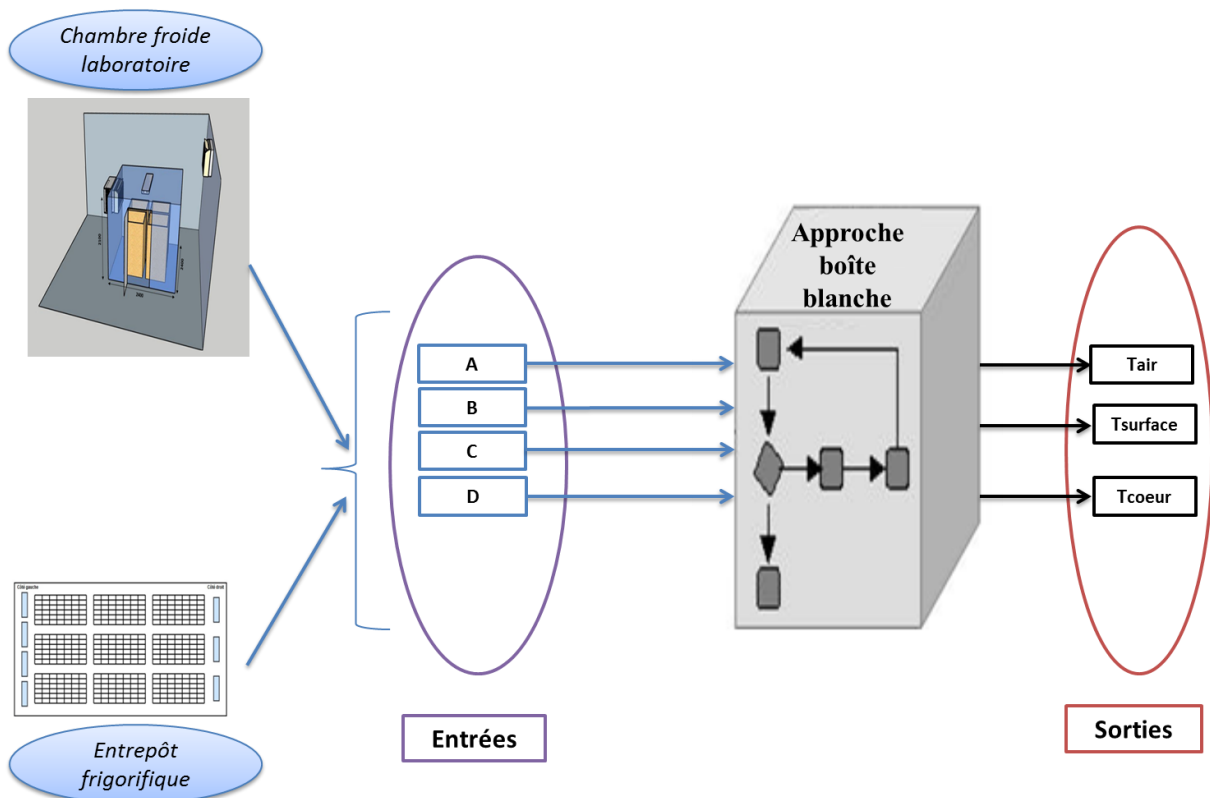


Figure 22 : Organisation des entrées et sorties de l'approche boîte blanche

La figure 22 représente le schéma organisationnel de l'approche boîte blanche. Celle-ci a besoin de données issues d'un système physique : soit de la chambre froide ou de l'entrepôt frigorifique industriel. Comme le montre cette figure, les entrées se composent des différents paramètres :

A - la géométrie et la composition de l'enveloppe du bâtiment : dimensions et compositions des murs

B - des conditions externes : température extérieure - T_{ext} et le flux solaire...

C - le fonctionnement de la machine frigorifique : température au soufflage - T_{souf} , température de consigne - $T_{consigne}$, ON / OFF compresseur, de débit d'air des ventilateurs, la puissance de la machine...

D - l'état interne du système étudié : pourcentage du chargement, charges thermiques dues à l'éclairage, aux ventilateurs et aux personnels...

Ce modèle physique permet de prédire l'évolution dynamique de la température de l'air et du produit (à la surface et au cœur de la palette).

Le modèle est principalement basé sur l'approche de calcul des différentes charges thermiques présentes dans un entrepôt. Celles-ci sont présentées dans le manuel de référence pratique sur les différents thèmes du chauffage, de la ventilation, de la climatisation et de la réfrigération (ASHRAE 24). Les sources d'apport de chaleur dans un entrepôt proviennent principalement :

- de la conduction à travers les parois dépendant de la température extérieure,
- du chauffage du sous-sol dans le cas des entrepôts à température négative (chauffage ayant pour fonction d'éviter la rupture de la dalle de sol),
- des ouvertures de portes,
- du chargement et déchargement des produits,
- du dégivrage des évaporateurs,
- de l'éclairage,
- de la ventilation,
- des machines diverses (comme les véhicules),
- des personnes présentes dans l'entrepôt.

Toutes ces charges thermiques sont prises en compte dans le modèle.

Les variations de température sont plus ou moins ralenties par :

- l'inertie thermique de l'air échangeant avec les produits
- l'inertie thermique des équipements à l'intérieur de l'entrepôt (échangeurs, palettes, conteneurs, rails de guidage, etc...)
- l'inertie thermique des produits eux-mêmes dans laquelle la chaleur se propage par conduction (et partiellement par convection naturelle si le produit est un empilement poreux d'objets)

Ces différents facteurs gouvernant l'évolution de la température dans l'entrepôt sont pris en compte dans le modèle à travers un ensemble d'équations algébriques, différentielles et aux dérivées partielles qui seront présentées dans cette partie.

III.1.1 Pertes par transmission à travers les parois




Figure 23 : Transfert de chaleur à travers la paroi

Les flux de chaleur régissant le transfert de chaleur à travers une paroi (voir figure 23) sont calculés de la façon suivante:

Convection intérieure (à l'intérieur de la configuration) :

$$\varphi_{ci} = h_{ci} \times (Ta_i - Ts_i) \quad (14)$$

Conduction dans la paroi (à travers la paroi):

$$\varphi_{cond} = \frac{\lambda}{x} \times (Ts_i - Ts_e) \quad (15)$$

Convection extérieure (dans le milieu externe de la configuration) :

$$\varphi_{ce} = h_{ce} \times (Ts_e - Ta_e) \quad (16)$$

Avec :

Ta_i : Température de l'air intérieur

Ts_i : Température de surface intérieure

Ts_e : Température de surface extérieure de la paroi

T_{a_e} : Température de l'air extérieur

h_{ci} : Coefficient d'échange convectif intérieur

h_{ce} : Coefficient d'échange convectif extérieur

λ : Conductivité thermique de la paroi

x : Epaisseur de la paroi

Enfin l'apport de chaleur à travers les parois, le sol et le plafond peut être calculé par :

$$\dot{q}_{parois} = UA_{parois}\Delta T \quad (17)$$

Où A est la surface des parois, ΔT est la différence de température entre l'intérieur et l'extérieur, U est le coefficient de transfert global qui peut être calculé par :

$$U = \frac{1}{1/h_{ci} + x/\lambda + 1/h_{ce}} \quad (18)$$

Où h_{ci} est le coefficient d'échange par convection à l'intérieur du système (soit chambre froide ou entrepôt frigorifique), x est l'épaisseur de la paroi, λ est la conductivité de la paroi et h_{ce} est le coefficient d'échange par convection à l'extérieur. Des valeurs de 1,6 pour h_{ci} et h_{ce} sont recommandées par l'ASHRAE. Si la paroi extérieure est exposée au vent, une valeur de 6 pour h_{ce} est recommandée. U peut être également mesuré expérimentalement (pour la chambre froide, la valeur obtenue est de 0,29 W / m². K).

Afin de prendre en compte l'ensoleillement, un ajustement de la différence de température entre l'intérieur et l'extérieur est effectué en fonction de la nature des parois et de leur couleur [112](ASHRAE 24.1).

III.1.2 Infiltration d'air par ouverture des portes

Dans l'entrepôt frigorifique, les portes d'un entrepôt s'ouvrent dans la plupart des cas dans une salle intermédiaire, et non vers l'extérieur. L'infiltration de l'air dans ce cas est liée à la différence de densité de l'air entre l'entrepôt et la salle et à la nature du système de protection éventuel de la porte (rideau). L'apport de chaleur peut être évalué par l'équation suivante :

$$\dot{q}_{infiltration} = qD_t D_f (1 - E) \quad (19)$$

q représente le flux de chaleur qui serait atteint dans le cas d'un régime établi. Les facteurs D_f , D_t et E dépendent du temps d'ouverture de la porte, de la présence d'obstacles et de la nature des protections. Le calcul de ces différents facteurs est décrit dans ASHRAE 24.1.q [112] est calculé par l'équation de Gosney and Olama (1975) et prend en compte les différences d'enthalpie et de densité de l'air dans les deux salles ainsi que des dimensions de la porte.

III.1.3 **Chargement et déchargement des produits**

Les produits introduits à l'intérieur de l'entrepôt dans le cas industriel ont été congelés préalablement dans un surgélateur à -18°C [113] et peuvent être considérés comme étant déjà à la température de l'entrepôt. Cette charge est négligée dans le cas de la chambre froide car il n'y a pas eu d'entrées ou de sorties de produits pendant les essais.

III.1.4 **Dégivrage**

La puissance, la fréquence ainsi que la durée du dégivrage sont des données d'entrée du modèle et sont appliquées périodiquement au cours de la simulation.

III.1.5 **Eclairage**

La puissance due à l'éclairage est calculée par la formule suivante :

$$\dot{q}_{\text{éclairage}} = P_{lum} \cdot t / 24 \quad (20)$$

P_{lum} : Puissance installée (W)

t : Temps de marche par jour (h)

III.1.6 **Ventilation**

La puissance thermique dégagée par la ventilation est calculée par la formule suivante :

$$\dot{q}_{frig} = P_{ven} \cdot t / 24 \quad (21)$$

P : Puissance de ventilation (W)

Dans notre cas elle est en marche tout le temps

III.1.7 **Machines diverses**

La puissance due au matériel roulant (véhicules) dans la chambre ou l'entrepôt est de :

$$\dot{q}_{véhicules} = P_{matériel} \cdot i \cdot t / 24 \quad (22)$$

$P_{matériel}$: Puissance totale de chaque type de matériel (W)

i : Nombre de matériels roulants

t : Heures de fonctionnement du matériel (h)

III.1.8 Personnel

La quantité de chaleur dégagée par les personnes travaillant est exprimée par la relation suivante :

$$\dot{q}_{personnes} = N \cdot P \cdot t / 24 \quad (23)$$

N : Nombre de personnes

P : Puissance dégagée par une personne (W). La valeur de cette puissance peut être estimée par l'expression $P=272- 6 * T$ (ASHRAE 24) où T est la température de l'air dans la chambre en °C.

t : Temps de présence dans la chambre (h)

III.1.9 Echange de chaleur avec le produit

Dans l'entrepôt, les palettes de produit sont supposées parallélépipédiques. L'échange de chaleur entre l'air et les parois des palettes se fait par convection forcée :

$$\dot{Q}_{produit} = hA_{prod} \Delta T \quad (24)$$

Où h est le coefficient de transfert entre l'air et les produits.

L'équation de la conduction de la chaleur à l'intérieur du produit est formulée en une dimension (une caisse de produits étant quasi cubique) et discrétisée en volumes finis. Les conditions aux limites sont le flux de chaleur par convection à la surface du produit et une condition de symétrie au centre du produit.

$$\left\{ \begin{array}{l} \rho C_p \frac{\partial T}{\partial t} = k \frac{\partial^2 T}{\partial x^2} \\ \dot{q} = h A_{prod} \Delta T \text{ pour } x = 0 \\ \dot{q} = 0 \text{ pour } x = L/2 \end{array} \right. \quad (25)$$

III.1.10 Bilan thermique sur l'air-liste des paramètres

Le bilan thermique de l'air inclut les différentes sources de chaleur, l'échange de chaleur avec le produit et la puissance frigorifique fournie par la machine et peut être calculé par :

$$m C_{p_{air}} \frac{dT}{dt} = \dot{q}_{parois} + \dot{q}_{infiltration} + \dot{q}_{éclairage} + \dot{q}_{chauffage\ sol} + \dot{q}_{dégivrage} + \dot{q}_{véhicules} + \dot{q}_{personnes} + \dot{q}_{produit} + \dot{q}_{frig} \quad (26)$$

Tableau 6 : Paramètres de la simulation « boîte blanche »

	Paramètre	Chambre froide	Entrepôt frigorifique
Murs	Longueur (m)	2,4	124
	Largeur (m)	2,4	49
	Hauteur (m)	2,0	10
	Epaisseur (m)	0,15	0,15
	Isolant	Polyuréthane	Polyuréthane
Machine frigorifique	Température de consigne moyenne (°C)	-16,75	-18,20
	Puissance totale évaporateurs (W)	2450	750000
	Mode de régulation de puissance	Tout ou rien	Variation de puissance
	Largeur de bande en °C si la régulation tout ou rien	2,5	2
	Réfrigérant	R404a	R717
	Type de condenseur	Air	Air
	Nombre de ventilateurs par condenseur	1	2

	Puissance des ventilateurs condenseur (W)	112	10000
	Autre consommation électrique (W)	75	40000
Production chaleur	Puissance de l'éclairage (W)	72	8000
	Durée de l'éclairage (min / jour)	1440	1440
	Type de dégivrage	Gaz	Electrique
	Nombre de dégivrages par 24h	6 ou 4	0,1
	Puissance de dégivrage (W)	200	10000
	Durée de dégivrage (min)	10	60
	Nombre de ventilateurs par évaporateur	1	7
	Puissance moteur des ventilateurs évaporateurs (W)	105	4000
	Efficacité moteur des ventilateurs évaporateurs (%)	100	85
Produit	Type de produit	Basalte	Carotte
	Masse de produit (tonnes)	1,6	90000
	Température initiale à la surface (°C)	-16,8	18,3
	Température initiale à cœur (°C)	-16,6	18,1
Palettes	Nombre de palettes dans la longueur	2	10
	Nombre de palettes dans la largeur	2	10
	Nombre de palettes dans la hauteur	1	6

Le tableau 6 présente les paramètres de la simulation pour le cas de la chambre froide et pour l'entrepôt frigorifique

Pour l'effacement, 5 paramètres sont considérés : pas de temps, début de la simulation, nombre de jours de simulation, début d'effacement et fin de l'effacement.

III.2 Approche boîte noire

Cette partie concerne l'étude de l'approche boîte noire, complètement guidée par les données. Cette étude a pour but de prédire le comportement du système sans avoir à le modéliser physiquement. Cette approche (développée sous Python et les bibliothèques *Keras et Sklearn*) a été utilisée pour développer les modèles « *Deep Learning* ». Les simulations ont été réalisées par un PC de bureau (Windows 7, Inter Core i7-6700 CPU, 3,4 GHz et 16 Go). L'objectif principal de cette partie est de :

1. formaliser notre problématique qui est de prédire la température à l'intérieur de la chambre, la consommation d'énergie ainsi que la température des produits
2. développer les modèles capables d'apprendre le comportement des données et pouvoir le généraliser
3. sélectionner et analyser les données d'étude puis les transformer afin qu'elles puissent être traitées par le modèle de prédiction.

Pour ces raisons, cette partie présente la méthodologie développée permettant de construire les modèles « *Deep Learning* » dans le but de prédire le comportement à l'intérieur de la chambre froide lors des effacements. Le choix des variables d'entrées et de sorties et une étude plus approfondie sur les modèles de type *Deep Learning* seront présentées. De plus, la transformation des données de mesures en séries chronologiques sera également expliquée. Enfin, l'ensemble des critères que nous avons employés pour valider les performances de nos modèles sera présenté.

Les modèles *Deep learning* prédictifs ont été choisis pour leur adaptation à la prédiction des séries temporelles. En effet, ils apprennent sur des caractéristiques utiles à partir d'un ensemble de paramètres de la série temporelle pour donner une prédiction d'une sortie (\hat{Y}_t). Celle-ci est ensuite comparée à la sortie réelle (Y_t) mesurée pour optimiser les réponses du modèle, sachant que (Y_t) est la valeur réelle de référence à l'instant t et (\hat{Y}_t) est la valeur prédite au même instant.

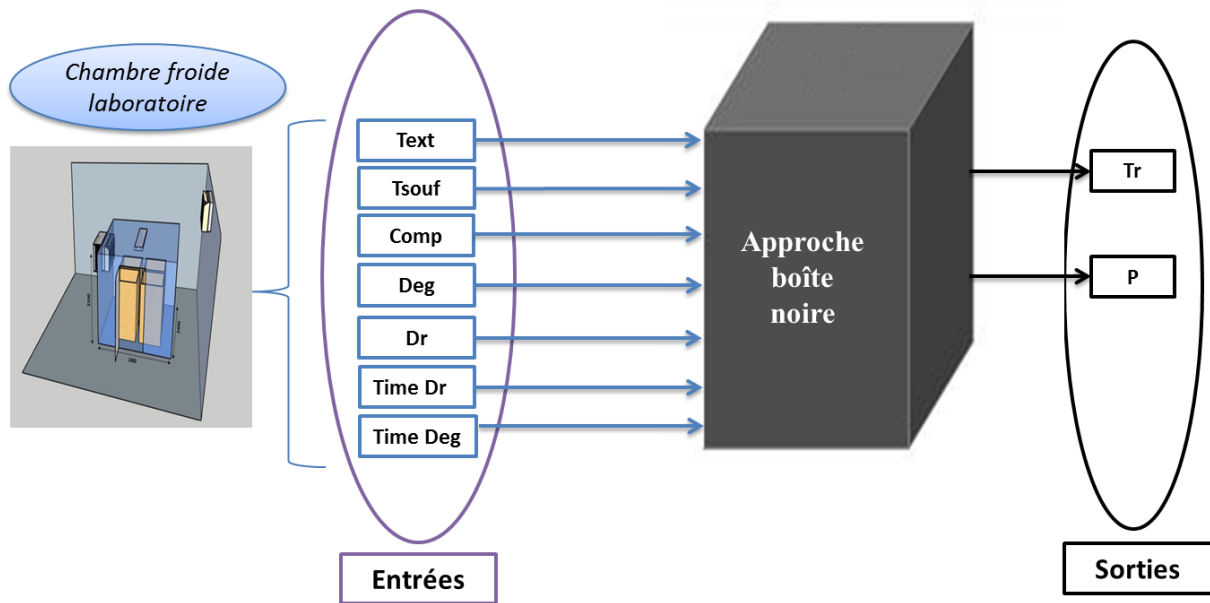


Figure 24 : Schéma représentatif de l'approche boîte noire

La figure 24 illustre les entrées et les sorties de l'approche boîte noire (Cf. tableau 8). Les entrées de cette approche sont issues des données réelles temporelles mesurées depuis la chambre froide laboratoire (Cf. Chapitre 2 – Etude expérimentale). Les sorties prédites par cette approche sont comparées aux données réelles issues de la chambre froide laboratoire.

Comme prouvé dans la littérature, le modèle LSTM est capable d'apprendre une relation de dépendance temporelle entre les données de série temporelle en utilisant des mécanismes spécifiques de synchronisation et de mémorisation. Pour cela, le choix des modèles *Deep Learning* est basé sur des architectures qui dérivent du LSTM classique dont les trois suivants : LSTM-Convolutif, LSTM-Stacked, LSTM-Bidirectionnel. Le modèle Convolutif a été ajouté à la liste des modèles développés afin de tester sa capacité à prédire des séries temporelles.

III.2.1 Modèles Deep Learning développés et leurs caractéristiques

Une implémentation de cinq modèles de Deep Learning a été réalisée, à savoir : un réseau de neurones convolutif et les quatre architectures du modèle LSTM (LSTM simple, LSTM-Stacked, LSTM Bidirectionnel et LSTM Convolutif).

Les cinq modèles étudiés comportent généralement : une couche d'entrées, une ou plusieurs couche(s) intermédiaire (s) et une couche de sorties (voir figure 25).




Figure 25 : Architecture d'un modèle de réseau de neurones

Le nombre d'entrées peut être parmi 6, 7 ou 10, et le nombre de sorties peut être entre 2 ou 4. Les choix des entrées et des sorties sont expliqués dans la section III.2.4.

III.2.1.1 Réseau de neurones convolutif (CNN)

Le modèle de réseau de neurones convolutif développé pour notre étude est constitué d'une couche d'entrées, des couches intermédiaires de convolutions 1D, de Max Pooling 1D et une couche de sorties.

En effet, les couches de convolutions 1D sont utilisées pour traiter les données d'entrée. Chaque couche de convolutions 1D possède une fonction d'activation de type ReLu définie par l'équation 27. Cette fonction ReLu a pour but d'accélérer considérablement la convergence du réseau et la stabilité.

$$\text{ReLu}(x) = \max(0, x) \quad (27)$$

De plus, chaque couche de convolution 1D contient des biais pour le filtre et la taille du noyau de convolution.

Dans notre cas, le choix était de prendre 20 filtres. Ce choix a été fixé expérimentalement en regardant le temps d'exécution et l'erreur de prédiction.

La couche de convolution est suivie par une couche de Max Pooling 1D pour garder les caractéristiques détectées tout en réduisant la taille des données intermédiaires.

Un modèle de réseau de neurones se distingue par rapport à un autre par la manière dont les couches sont empilées, mais également par les hyper-paramètres qui sont principalement la taille du filtre, le nombre de filtres, le nombre de neurones par couche, et le nombre de couches. Le nombre de couches de convolution 1D et le nombre de couches Max Pooling 1D ont été définis par rapport aux nombres d'entrées et de sorties.

En effet, pour un nombre d'entrées supérieur à 7, le nombre de couches de convolution 1D et de couches Max Pooling 1D est égale à 3 (voir figure 26a). Cependant, pour un nombre d'entrées inférieur ou égal à 7, le nombre de couches de convolution 1D et de couches Max Pooling 1D est égal à 2 (voir la figure 26b et c).

Une fonction de coût (Eq.28) indiquant l'erreur entre le résultat obtenu et le résultat souhaité a été définie. Dans notre cas, il s'agit d'une fonction de coût en erreur quadratique moyenne (MSE). Le choix de cette fonction a été effectué dans le but de minimiser les erreurs et adapter les réponses de ce réseau pour converger vers la sortie souhaitée.

$$\text{coût}(w, b) = \frac{1}{2n} (\sum_x \|y_x - \hat{y}_x\|^2) \quad (28)$$

où : w la matrice des poids, b le biais, n la taille de l'échantillon d'apprentissage, y_x est le vecteur de sortie prévu associé à l'entrée x , \hat{y}_x est la valeur de la sortie prédite pour la même entrée x .

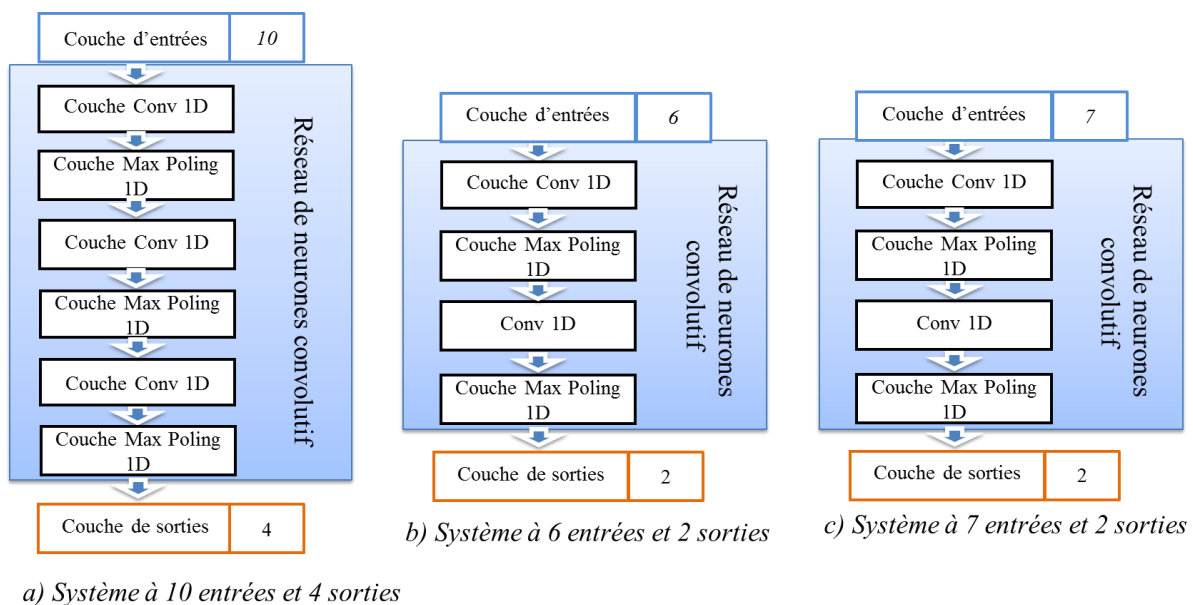


Figure 26 : Architecture du modèle de réseau de neurones convolutif pour les 3 systèmes

- a) Système à 10 entrées et 4 sorties
- b) Système à 6 entrées et 2 sorties
- c) Système à 7 entrées et 2 sorties

Ce type de modèle, réseau de neurones convolutif (*feed-forward*), est assez classique dans le cadre de l'apprentissage profond. En effet, il est assez efficace pour des problèmes de reconnaissance des formes où la relation spatiale entre les pixels est entièrement prise en

compte. Cependant, son application directe à des données temporelles n'est pas du tout adaptée. Néanmoins nous l'avons considéré afin de vérifier s'il existe ainsi une relation spatiale même peu dominante dans nos données. Les résultats obtenus par ce réseau de convolution ont été comparés aux résultats obtenus par les modèles principaux, à savoir les modèles qui dérivent de LSTM.

III.2.1.2 Réseau récurrent à mémoire court et long terme (LSTM)

Un réseau de neurones récurrent à mémoire court et long terme (Long Short Term Memory) a été développé. Ce réseau, qui permet de conserver l'information à différentes échelles temporelles est le plus approprié à notre application. Un réseau LSTM simple choisi pour tous les systèmes (différentes combinaisons des entrées et des sorties) est construit à partir d'une couche d'entrées, une couche LSTM, deux couches cachées (dense) avec 64 et 32 neurones respectivement et enfin, une couche de sorties.

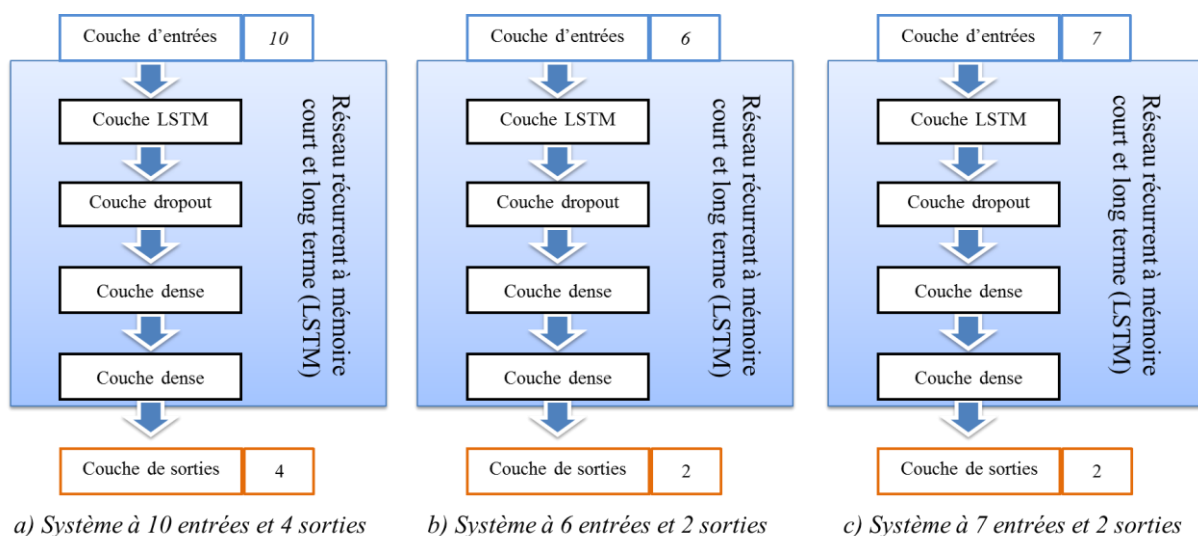


Figure 27 : Architecture du modèle de réseau récurrent à mémoire court et long terme (LSTM) pour les 3 systèmes

- a) Système à 10 entrées et 4 sorties avec une couche LSTM de 1024 unités
- b) Système à 6 entrées et 2 sorties une couche LSTM de 512 unités
- c) Système à 7 entrées et 2 sorties une couche LSTM de 512 unités

Une couche LSTM est caractérisée par un nombre d'unités pour mémoriser suffisamment d'informations. Le choix du nombre d'unités a été effectué par rapport au nombre d'entrées et de sorties des systèmes et aussi en équilibrant le temps d'apprentissage et la qualité de prédiction obtenue. En effet, pour un système à 10 entrées et 4 sorties (voir la figure 28a), le nombre d'unités est de 1024 unités. Cependant, pour les deux autres systèmes, à 6 entrées et 2

sorties et à 7 entrées et 2 sorties, le nombre d'unités est de 512 unités (voir la figure 27b et c). Cette couche de LSTM est connectée à la couche cachée suivante par une couche de dropout permettant ainsi d'accélérer l'apprentissage et d'éviter de faire du sur apprentissage. Cette dernière, une couche des neurones « d'oubli » pendant une phase de « training », permet d'obtenir des résultats plus facilement généralisables et de minimiser les risques de sur-apprentissage.

Afin d'obtenir de meilleurs résultats de prédiction, une fonction d'activation linéaire a été ajoutée à la sortie de la deuxième couche dense. Le choix d'utiliser ce type de fonction est basé sur l'hypothèse que le calcul de la somme des entrées et le biais d'un neurone a un comportement linéaire par rapport à ses entrées. Autrement dit, ce calcul a une dépendance sur chacune des entrées. Concernant la fonction de coût, celle-ci reste la même que celle dans le réseau de neurones convolutif (erreur quadratique moyenne (MSE)).

III.2.1.3 *LSTM-Stacked (Enchaîné)*

Le modèle LSTM-Stacked (LSTM enchaîné) a été développé sous l'hypothèse que l'augmentation de la profondeur du réseau permettrait d'extraire des caractéristiques temporelles multi-échelles et donc de mieux prédire chacune des variables de sortie.

Ce type de modèle est caractérisé par un empilement de plusieurs couches LSTM simple (définies précédemment dans le réseau récurrent LSTM). Le modèle LSTM-Stacked choisi est constitué d'une couche d'entrées, des couches LSTM (présentées précédemment), deux couches intermédiaires cachées (dense) avec 64 et 32 neurones respectivement et une couche de sorties.

Deux modèles LSTM-Stacked ont été choisis. Le choix de ces modèles a été fait par rapport au nombre d'entrées et de sorties. La différence entre les deux modèles se situe dans le nombre de couches d'LSTM et aussi sur le nombre d'unités de mémoire.

- a) Le 1^{er} modèle pour le système à 10 entrées et 4 sorties est défini par (voir la figure 28a) :
 - une première couche LSTM comprenant 1024 unités de mémoire.
 - une seconde couche LSTM comprenant 512 unités de mémoire.
 - une troisième couche LSTM comprenant quant à elle 256 unités de mémoire.

Chaque couche LSTM est séparée de la couche suivante par une couche de dropout.

- b) Le 2^{ème} modèle pour les deux systèmes (à 7 entrées et 2 sorties et 6 entrées et 2 sorties) est défini par (voir la figure 28b et c) :
 - une première couche LSTM comprenant 512 unités de mémoire.
 - une seconde couche LSTM comprenant 256 unités de mémoire.

Chaque couche du réseau est séparée de la couche suivante aussi par une couche de dropout.

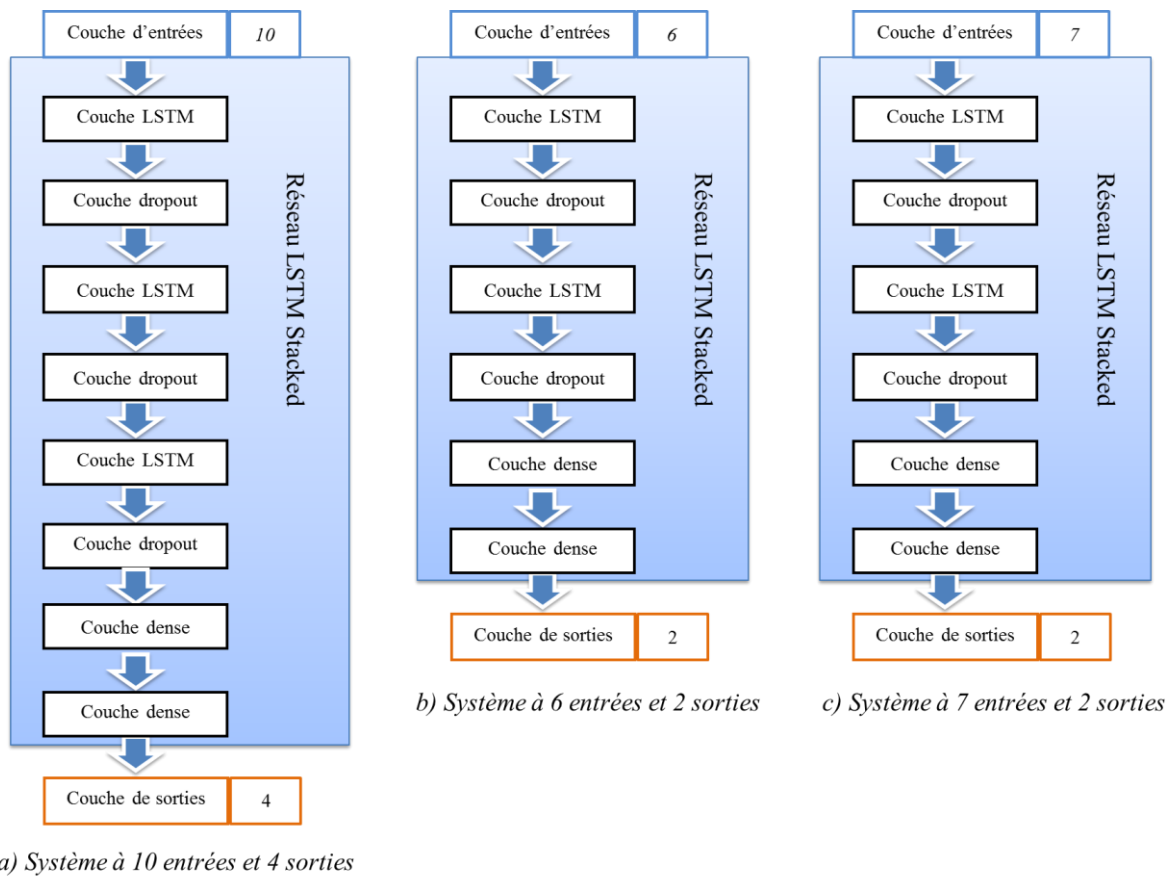


Figure 28 : Architecture du modèle de réseau LSTM Stacked pour les 3 systèmes

III.2.1.4 LSTM Bidirectionnel

Ce type de réseau a été créé pour conserver les informations à la fois liées aux données passées, mais également aux données futures. Et ce dans le but de voir si la conservation de ces informations permet au réseau de mieux prédire les sorties désirées.

Le LSTM Bidirectionnel choisi pour les trois systèmes est construit à partir d'une couche d'entrées, deux couches de LSTM qui possèdent chacune 512 unités de mémoire, une couche cachée (dense) avec 64 neurones et enfin, une couche de sorties (figure 29 a, b et c). Ce choix de limiter le nombre de couches LSTM à 2 et le nombre d'unités à 512 a été élaboré expérimentalement au regard de la qualité d'apprentissage (afin d'éviter le sur-apprentissage). Dans ce type de réseau, les mêmes fonctions d'activation et de coût que celles choisies dans les deux réseaux précédents (LSTM simple et LSTM-Stacked). Les même hyper-paramètres ont

été conservés pour les trois architectures dans le but de comparer leurs performances et de maintenir la comparaison des résultats.

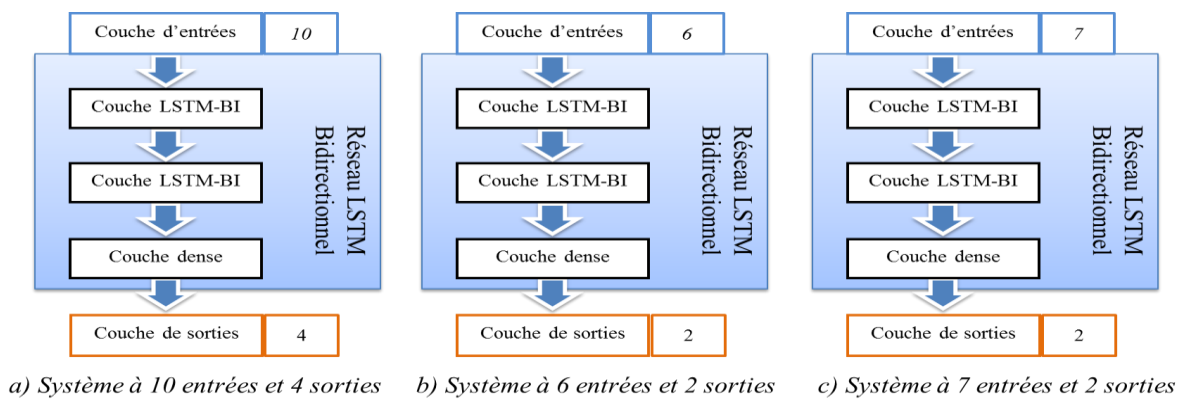


Figure 29 : Architecture du modèle de réseau LSTM Bidirectionnel pour les 3 systèmes

III.2.1.1 LSTM Convolutif

Le réseau LSTM convolutif a été choisi pour déterminer l'influence du couplage de deux réseaux de neurones de deux familles différentes sur la prédiction. L'hypothèse que nous avons posée est de pouvoir prendre en considération les dépendances temporelles (pour la même entrée) et spatiales (entre différentes entrées).

Le LSTM Convolutif choisi dans notre étude est construit à partir d'une couche d'entrées, d'une couche convolution-LSTM 2D, une couche de normalisation du groupe et une couche de sorties, et cela pour tous les trois systèmes des entrées et des sorties (voir la figure 30a, b et c). En effet, la couche convolution-LSTM 2D possède 20 filtres et une taille de noyau de 1 (kernel size). La couche de normalisation du groupe, qui permet de normaliser les activations de la couche du LSTM convolutif, était de type BatchNormalization. Cette normalisation permet de réduire les changements des covariances au niveau de chaque couche.

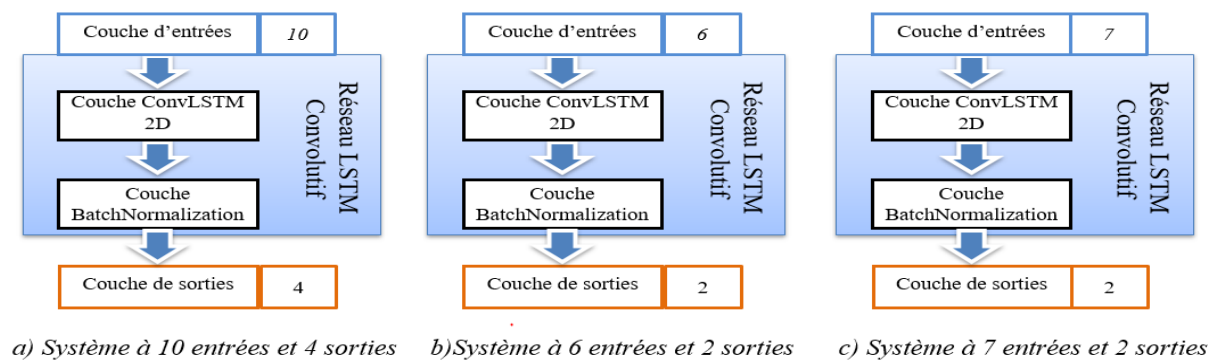


Figure 30 : Architecture du modèle de réseau LSTM Convolutif pour les 3 systèmes

III.2.2 Paramétrage des modèles

Pour l'apprentissage, le choix a été de garder le même paramétrage pour tous les modèles mentionnés ci-dessus. Ce paramétrage concerne le nombre d'itération (une itération égale à un cycle d'apprentissage) et la taille de batch size. Le nombre d'itérations est défini comme un hyper paramètre déterminant le nombre de fois que le modèle s'entraîne sur l'ensemble du jeu de données (phase d'apprentissage) du tirage aléatoire. Un nombre d'itération élevé (ou trop bas) peut générer des problèmes de sur-apprentissage (ou sous-apprentissage). Le batch size correspond au nombre de sous-échantillonnages que le modèle utilise pour apprendre à chaque fois.

III.2.3 Séries de données pour l'apprentissage et la validation des modèles

L'apprentissage et la validation des modèles de prédiction décrits précédemment se basent sur l'utilisation de données de type séries temporelles. Ces données permettent d'entraîner les modèles mais aussi de vérifier leurs prédictions [114, 115].

Dans notre étude, les données utilisées sont issues d'une chambre froide réelle (*Cf.* Chapitre 2 – Etude expérimentale). Le choix d'utiliser des données issues d'un système réel a été fait pour les raisons suivantes :

- les données ont été acquises dans un environnement bien contrôlé (les portes de la chambre et de la cellule extérieure étaient bien fermées lors de la prise des mesures).
- les données réelles très couteuses représentent les comportements physiques de la chambre froide. Ces comportements peuvent être identifiés et analysés (*Cf.* Chapitre 4 – Résultats expérimentaux).
- plusieurs consignes par rapport aux températures extérieure et intérieure peuvent être étudiées.
- plusieurs scénarios d'effacement peuvent être appliqués.
- une grande base de données avec une précision satisfaisante (petits pas de temps 5 secondes et 20 secondes) peut être générée.

Plusieurs séries temporelles (E_i où i allant de 1 jusqu'à 5) ont été générées pour l'apprentissage et la validation des modèles. Ces séries représentent différentes formes de signaux correspondant à plusieurs scénarios d'effacement et aux combinaisons de ces scénarios.

Série E1(37595 points) : constituée d'un ensemble de données, mesurées avec un pas de temps de 5 secondes, où la répartition des effacements est uniforme pendant 3 jours. En effet, trois effacements de 1 h, 2 h et 3 h respectivement, ont été réalisés sur une fréquence de 1 effacement par jour pendant 3 jours. Cette série simule une distribution uniforme des occurrences des effacements, avec des durées incrémentales et des instants aléatoires.

Série E2 (126355 points) : construite à partir d'un ensemble de données, mesurées avec un pas de temps de 5 secondes, avec une fréquence de 2 effacements par jour répartie d'une manière uniforme pendant 5 jours (à des heures fixes). Les durées d'effacement étaient de 30 min, 1 h et 2 h, choisies de façon aléatoire pour chaque effacement. Le but de construire cette série étant d'augmenter à la fois la fréquence de l'apparition de l'effacement par rapport à la série 1 et la quantité de données.

Série E3 (98196 points) : composée d'un ensemble de données, mesurées avec un pas de temps de 5 secondes, avec une fréquence de 1 effacement par jour répartie d'une manière aléatoire pendant 5 jours. Les durées d'effacements étaient les mêmes que la série E2 (30 min, 1 h et 2 h).

Série E4 (210307 points) : composée de la concaténation des trois séries précédentes E1, E2 et E3 ($E4=E1+E2+E3$) avec suppression des données du week-end (jours sans effacement). Le but de réaliser cette série a été d'obtenir une grande série de données de mesure (de 13 jours) qui contient plus de périodes d'effacement, avec différentes durées aléatoires. L'utilisation de cette série permet également d'augmenter l'horizon de prévision.

Séries E5 (17839 points) : construite à partir d'un ensemble de données, mesurées avec un pas de temps de 20 secondes, avec une fréquence d'effacement plus importante : 6 effacements (d'une durée identique d'1 heure) par jour avec un intervalle de 2 h entre 2 effacements. Cette série permet de voir également l'effet de l'augmentation du pas de temps sur la qualité de la prévision.

Il est à noter que l'application des effacements dans la série E4 ($E4=E1+E2+E3$) était manuelle : les effacements ont été programmés pendant les heures de travail (9 h- 18 h). En revanche, pour la série E5, un boîtier de commande a été utilisé pour appliquer les effacements d'une façon automatique.

La suite de cette étude sera effectuée sur ces deux séries E4 et E5. D'une part, ces séries contiennent la plus grande quantité de données liées aux périodes d'effacement : 18 périodes

d'effacement pour la série E4 et 24 périodes pour la série E5. D'autre part, elles ont un pas de temps différent : 5 secondes pour la série E4 et 20 secondes pour la série E5.

En respectant la chronologie des données, chacune des séries de données E4 et E5 a été divisée en deux parties, une pour l'apprentissage (60 % de l'ensemble des données) et une pour la validation (40 % de données). Ce choix de répartition a été fait d'après les travaux de Simmhan et Noor [115].




Figure 31 : Répartition entre l'apprentissage (en orange) et la validation (en bleu) des modèles *Deep Learning*, où x-température extérieure correspond aux données d'entrée et y-température de reprise aux données de sortie de la série E4.

La figure 31 présente la séparation entre des parties d'apprentissage et de validation de la série E4. Cette procédure est la même pour tous les systèmes à nombres d'entrées et de sorties différents. La partie d'apprentissage est définie comme la partie sur laquelle le modèle apprend le comportement du système. En effet, dans cette partie, les données d'entrées et de sorties sont utilisées pour construire les modèles. Ensuite, dans la partie de validation, les performances de la prédiction du modèle vont être mesurées pour un horizon de prédiction correspondant à la durée de cette partie où seules les données d'entrées sont utilisées pour la prévision. Le tableau 7 résume les nombres de point, les durées d'apprentissage et de validation pour les deux séries de données E4 et E5.

Tableau 7 : Durée d'apprentissage et de validation (horizon de prédiction)

Série	Phase d'apprentissage (points / jours)	Phase de validation (points / jours)
Série E4	126184 / 7,3	84123 / 4,9
Série E5	10704 / 2,5	7135 / 1,6

Le tableau 7 résume la durée d'apprentissage et la durée de validation pour les deux séries de données E4 et E5.

III.2.4 Ensemble des variables d'entrée et de sortie

Le tableau 8 résume l'ensemble des entrées et des sorties utilisées pour les modèles boîte noire.

Tableau 8 : L'ensemble des entrées et des sorties des modèles boîte noire

	Nom	Description
Entrées (x)	T_{ext} (°C)	Température extérieure
	T_{souf} (°C)	Température de soufflage
	Deg [0,1]	Dégivrage (Off / ON)
	Dr [0,1]	Effacement (Off / ON)
	Time Deg	Temps depuis dernier dégivrage
	Time Dr	Temps depuis dernier effacement
	Comp [0,1]	Compresseur (Off / ON)
Sorties (y)	T_r (°C)	Température de reprise
	P (W)	Puissance du compresseur

D'après le tableau 8, de nombreuses variables d'entrées de type série temporelle ont été utilisées pour les modèles *Deep Learning*. En effet, les deux premières entrées (T_{ext} and T_{souf}) sont des données mesurées dans le dispositif expérimental. La première entrée est dédiée à la température extérieure qui indique la condition extérieure à laquelle la chambre froide est exposée. La deuxième température indique la température de l'air au soufflage de l'évaporateur.

Cette température donne une information sur l'état intérieur de la chambre froide. Au vu de la complexité du système étudié, qui comporte plusieurs phases (phase du régime permanent, phase de dégivrage et phase d'effacement, voir le protocole expérimental), des données caractéristiques supplémentaires, nommées indicateurs de fonctionnement, ont été extraites à partir des données afin de bien distinguer les phases, particulièrement celles entre les périodes de dégivrage et d'effacement.

Les 5 indicateurs de fonctionnement sont :

- dégivrage (Off / ON) Deg [0,1] : variable binaire qui caractérise les phases de dégivrage arrivant plusieurs fois par jour (horaire d'apparition non programmable). Les périodes de dégivrage sont représentées par un nombre 1, les autres périodes, non-dégivrage, sont représentées par un nombre 0.
- effacement (Off / ON) Dr [0,1] : caractérise les phases d'effacement : valeur 1 qui correspond aux périodes d'effacement et 0 : en dehors des effacements
- le temps écoulé depuis le dernier dégivrage : ce temps permet aux modèles de mieux prédire le comportement de la chambre froide pour les instants suivant les phases de dégivrage.
- le temps écoulé depuis le dernier effacement : ce temps permet aux modèles de mieux prédire le comportement de la chambre froide pour les périodes suivant l'effacement.
- marche et arrêt du compresseur (Off / On compresseur) Comp [0,1] : variable binaire pour indiquer l'état de fonctionnement du compresseur. En régime permanent, le compresseur de la machine frigorifique est caractérisé par des cycles réguliers marche / arrêt (*Cf.* figure 34), et au cours des périodes d'effacement, le compresseur est arrêté. L'état de marche (ou d'arrêt) du compresseur est défini par un nombre 1 (ou 0) respectivement.

Les sorties ont été choisies dans le but de prédire le comportement de la chambre froide pendant les périodes d'effacement en termes de fluctuation de la température à l'intérieur de la chambre et de consommation électrique du compresseur. Pour cela, la température de reprise, qui peut être considérée comme résultante des échanges thermiques à l'intérieur de chambre froide, et la puissance du compresseur ont été sélectionnées.

III.2.5 Analyse de corrélation (étude des indépendances des variables d'entrée et de sortie)

Afin de vérifier s'il existe des dépendances entre les variables, une analyse de corrélation entre ces variables a été faite.

La mesure de la corrélation entre une variable d'entrée x et une variable de sortie y a été calculée en utilisant le coefficient de corrélation de Spearman défini par :

$$\rho(x, y) = \frac{\text{cov}(\text{rang}_x, \text{rang}_y)}{\sigma(\text{rang}_x) \sigma(\text{rang}_y)} \quad (29)$$

Où :

x et y : deux variables distinctes

rang_x et rang_y : vecteurs issus d'une classification de valeur de x et y

$\text{cov}(\text{rang}_x, \text{rang}_y)$: covariance de rang_x et rang_y

$\sigma(\text{rang}_x)$ et $\sigma(\text{rang}_y)$: Ecart-type de rang_x et rang_y

Le coefficient de Spearman varie entre $-1 \leq \rho(x, y) \leq 1$.

Le coefficient de Spearman prend une valeur proche de 0 lorsque les variables d'entrée et de sortie sont indépendantes.

Une valeur positive du coefficient de Spearman donne une tendance croissante et une valeur négative du coefficient donne une tendance décroissante.

Le tableau 9 présente le résultat de calcul du coefficient de corrélation de Spearman entre les entrées et les sorties du système étudié (tableau 9) obtenu avec la série E5

Tableau 9 : Corrélation entre les données d'entrée et de sortie (série E5)

	Sorties	T _r – température de reprise	P – Puissance du compresseur
Entrées	T _{ext}	-0,18	0,15
	T _{souf}	0,84	-0,27
	Comp	-0,31	0,79
	Deg	0,05	0,10
	Dr	0,71	0,11
	Time Deg	-0,04	0,01
	Time Dr	-0,58	-0,13

D'après ce tableau 9, il existe une forte corrélation entre quelques couples d'entrée et de sortie. En effet, la corrélation est importante (proche de 1) entre la température de soufflage T_{souf} et la température de reprise, entre Comp (état marche / arrêt du compresseur) et la puissance du compresseur et aussi entre Dr (état de système : effacement ou non) et la température de reprise. Pour le cas de T_{souf}, cette variable sera utilisée d'une façon limitée (Cf. IV.5.3 Influence des entrées sur la prédiction) alors que Comp et Dr sont des variables de renforcement pour apporter aux modèles les informations concernant l'état de fonctionnement de la machine frigorifique.

III.2.6 Systèmes étudiés

Des corrélations plus ou moins fortes peuvent exister entre les entrées et les sorties. De plus, la dimension et la nature de ces données d'entrée et de sortie ont une grande influence sur les résultats de la prédiction. Trois différents systèmes ont été étudiés afin de voir l'effet de la réduction du nombre des entrées et des sorties sur la prédiction. Ces systèmes sont résumés par les tableaux ci-dessous :

- système 1 : 10 entrées et 4 sorties
- système 2 : 6 entrées et 2 sorties
- système 3 : 7 entrées et 2 sorties

Tableau 10 : Système 1 avec 10 entrées et 4 sorties

Système à 10 entrées et 4 sorties (Sys : 1)	Nom	Description
Entrées	T_{ext} (°C)	5 mesures de température extérieure
	Deg [0,1]	Dégivrage (Off / ON)
	Dr [0,1]	Effacement (Off / ON)
	Time Deg	Temps depuis dernier dégivrage
	Time Dr	Temps depuis dernier effacement
	Comp [0,1]	Compresseur (Off / ON)
Sorties	T_r (°C)	3 mesures de température de reprise (température de reprise)
	P (W)	Puissance du compresseur

Tableau 11 : Système 2 avec 6 entrées et 2 sorties

Système à 6 entrées et 2 sorties (Sys :2)	Nom	Description
Entrées	T_{ext} (°C)	Température extérieure moyennée (moyenne des 5 températures)
	Deg [0,1]	Dégivrage (Off / ON)
	Dr [0,1]	Effacement (Off / ON)
	Time Deg	Temps depuis le dernier dégivrage
	Time Dr	Temps depuis le dernier effacement
	Comp [0,1]	Compresseur (Off / ON)
Sorties	T_r (°C)	1 mesure de température de reprise moyennée (la moyenne des 3 températures)
	P (W)	Puissance du compresseur

Tableau 12 : Système 3 avec 7 entrées et 2 sorties

Système à 7 entrées et 2 sorties (Sys :3)	Nom	Description
Entrées	T_{ext} (°C)	Température extérieure moyennée (moyenne des 5 températures)
	Deg [0,1]	Dégivrage (Off / ON)
	Dr [0,1]	Effacement (Off / ON)
	Time Deg	Temps depuis dernier dégivrage
	Time Dr	Temps depuis dernier effacement
	Comp [0,1]	Compresseur (Off / ON)
	T_{souf} (°C)	1 Température de soufflage moyennée (la moyenne des 3 températures)
Sorties	T_r (°C)	1 Température de reprise moyennée (la moyenne des 3 températures)
	P (W)	Puissance du compresseur

Les tableaux 10, 11 et 12 résument les entrées et les sorties de chaque système. Tous ces systèmes ont des entrées et sorties en commun : les cinq indicateurs de fonctionnement et la puissance du compresseur. Cependant, ils sont différents par rapport à la nature (moyennée ou non), au nombre de variables de température en entrées, ainsi qu'à la nature de la température obtenue en sorties.

Le tableau 10, qui résume les entrées et les sorties du système 1, cinq mesures de la température extérieure ont été considérées dans les entrées du système. Ces mesures ont été prises à l'aide de 5 capteurs placés dans cinq positions stratégiques à l'extérieur de la chambre froide (au milieu de chaque mur à l'extérieur de la chambre). Dans les sorties, trois mesures de température de reprise, obtenues à l'aide de trois capteurs différents ont été recueillies.

Toutefois, pour le Système 2 (voir le tableau 11), une seule mesure de température extérieure a été considérée en entrée. Cette mesure de température représente la moyenne des cinq mesures de température extérieure du système 1. Parmi les sorties, une seule mesure de température de

reprise a été utilisée. Celle-ci représente la moyenne des trois mesures de température du système 1.

Pour le Système 3 (voir le tableau 12), les mêmes entrées et sorties du système 2 ont été conservées (la moyenne de température extérieure et la moyenne de température de reprise). En revanche, la température de soufflage (moyenne de 3 mesures) a été ajoutée comme entrée.

III.2.7 Critères pour évaluer les performances des modèles

Afin de mesurer la performance des prévisions des modèles, plusieurs critères ont été envisagés :

- ✓ critère de Fitting qui permet de mesurer l'accord entre les valeurs de référence (Y) ainsi que celles prédites (\hat{Y}), défini par [69]:

$$\text{Fit}(\%) = 100 \times \left(1 - \frac{|\bar{Y} - Y|}{|Y - \bar{Y}|} \right) \quad (30)$$

- ✓ il existe d'autres critères qui évaluent l'erreur de prédiction en calculant les erreurs entre les sorties prédites et les valeurs réelles mesurées, qui sont : l'erreur quadratique moyenne (MeanSquaredError) et l'erreur absolue moyenne (MeanAbsoluteError) [14, 43, 116].

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (\hat{Y}_i - Y_i)^2 \quad (31)$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |\hat{Y}_i - Y_i| \quad (32)$$

Avec : N est le nombre des échantillons (observation)

- ✓ Quelques auteurs ont préféré utiliser le coefficient de variation (CV) afin d'évaluer la performance des mesures. Ce critère a été fourni par ASHRAE afin d'évaluer le niveau de prédiction des modèles pour la consommation énergétique des bâtiments. Il permet de voir de combien l'erreur de prédiction globale varie par rapport à la moyenne de sa cible. Autrement dit, il compare la variabilité de deux séries qui ont des moyennes très différentes. Il est défini par la relation suivante [73, 88, 117, 118] :

$$\text{CV}(\%) = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - \bar{Y})^2}}{\bar{Y}} \times 100 \quad (33)$$

On remarque que plus la valeur de CV est faible, plus l'estimation est précise, donc la gamme des erreurs est basse.

CV élevé : la dispersion autour de la moyenne est grande (estimation pas précise)

- ✓ La racine de l'erreur quadratique moyenne (rootmean square error) RMSE et l'erreur relative moyenne (mean relative error) MRE qui sont définies par :

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{Y_i - \hat{Y}_i}{Y_i} \right)^2} \times 100\% \quad (34)$$

$$MRE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \times 100\% \quad (35)$$

Le choix de ces critères a été fait en raison de leur capacité d'adaptation aux différents comportements. Ils peuvent donc être très prometteurs pour mesurer la performance de prédiction des modèles vis-à-vis des comportements dynamiques complexes de la chambre froide lors de l'effacement.

III.3 Interaction entre les deux approches –Boîte noire et Boîte blanche

L'intérêt d'étudier l'interaction des deux approches de modélisation est de bénéficier des avantages des deux approches. Ceci en utilisant la boîte noire pour la prédiction et la boîte blanche pour créer une base de données réaliste alimentant la boîte noire.

La prédiction de la boîte noire utilise les mêmes modèles *Deep Learning* décrits dans la section modèles *Deep Learning* (Cf. III.2.1). La figure 32 montre la manière dont les deux approches sont couplées.

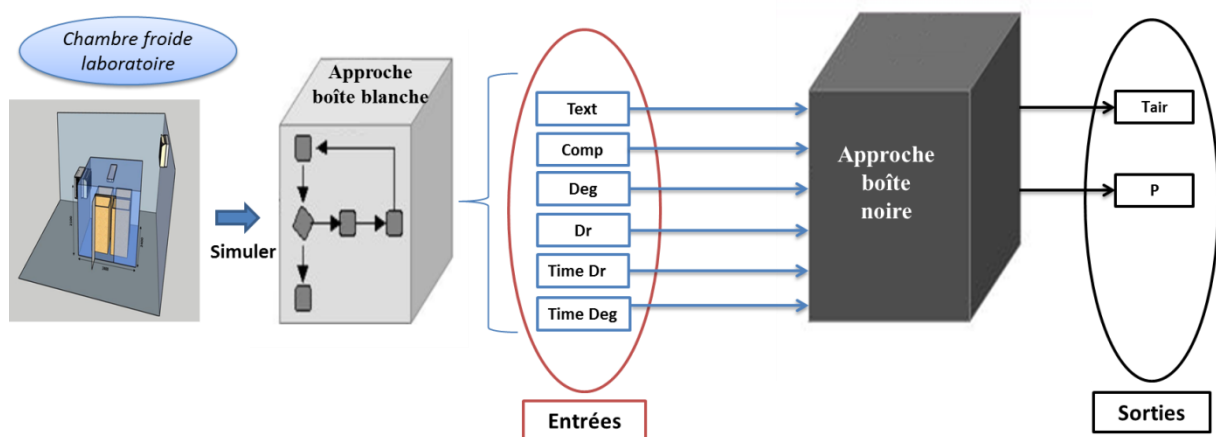


Figure 32 : Schéma représentatif de l'interaction entre les deux approches

L'approche boîte blanche (modèle physique Flexifroid, Cf. Chapitre 2 – approche boîte blanche) simule la chambre froide laboratoire. Puis, les données générées par l'approche boîte blanche seront utilisées comme des données d'entrées pour l'approche boîte noire. Ensuite, les sorties prédites par cette dernière sont comparées aux données de référence (boîte blanche).

Ce choix présente plusieurs avantages, à savoir :

- éviter les bruits de mesure,
- simuler plusieurs scénarios (durées d'effacement, température extérieure),
- avoir une base de données importante en peu de temps.

III.3.1 Série de données pour l'apprentissage et la validation des modèles

Une seule série de données E6 a été générée à partir du modèle Flexifroid (boîte blanche) pour l'apprentissage et la validation des modèles *Deep Learning*.

La série E6 (17277 points) est constituée d'un ensemble de données simulées pour le cas d'une chambre froide chargée avec un pas de temps de 20 secondes, et des effacements répartis uniformément pendant 4 jours. En effet, des durées d'effacement de 1 h et 2 h ont été réalisées sur une fréquence de 3 effacements par jour pendant 4 jours. Cette série représente un premier inventaire de l'utilisation des données issues d'un modèle physique (boîte blanche). La série simule la perturbation du système avec une seule fréquence d'apparition d'effacement, d'où une distribution uniforme du signal. L'utilisation de cette série permet également de simuler avec le modèle Flexifroid plusieurs températures extérieures, ce qui n'est pas réalisable avec la chambre froide (température extérieure limitée entre 17°C et 30°C). La température extérieure a été changée pour chaque effacement et sa variation a été choisie afin de respecter la variation journalière de la température extérieure.




Figure 33 : Série de données E6 où x-température extérieure correspond aux données d'entrée et y-température de l'air aux données de sortie.

La figure 33 illustre les données d'entrées (température extérieure) et de sorties (température de l'air) de la série E6. Cette série de données a été divisée en deux parties (60% des données pour l'apprentissage soit 10367 points, et 40% des données pour la validation soit 6910 points). La période de validation (les derniers 1,6 jours) correspond aux jours où la variation de la température extérieure était entre 13°C et 30°C.

III.3.2 Variables d'entrées et de sorties

Le tableau 13 résume les entrées et les sorties produites par le modèle physique (boîte blanche) pour des modèles *Deep Learning*. Pour les entrées : une mesure de la température extérieure a été considérée. Les 5 indicateurs de fonctionnement ont également été comptabilisés dans les entrées.

Les sorties sont constituées d'une température de l'air (représentant la moyenne à l'intérieur de la chambre) et de la puissance du compresseur.

Afin de mesurer les performances des modèles *Deep Learning*, les mêmes critères (Cf. III.2.7) que dans la partie boîte noire ont été utilisés.

Tableau 13 : Les variables d'entrées et de sorties des modèles *Deep Learning* avec des données du modèle boîte blanche

Système à 6 entrées et 2 sorties	Nom	Description
Entrées (x)	T_{ext} (°C)	1 température extérieure simulée
	Deg [0,1]	Dégivrage (Off / ON)
	Dr [0,1]	Effacement (Off / ON)
	Time Deg	Temps depuis dernier dégivrage
	Time Dr	Temps depuis dernier effacement
	Comp [0,1]	Compresseur (Off / ON)
Sorties (y)	T_{air} (°C)	1 température de l'air simulée
	P (W)	Puissance du compresseur

III.4 Conclusion

Ce chapitre a permis d'élaborer les méthodes de modélisation boîte blanche et boîte noire et d'étudier leur interaction. Pour l'approche boîte blanche, un inventaire des différentes charges thermiques des chambres froides et entrepôts industriels a été réalisé afin d'établir une modélisation basée sur les bilans thermiques. Les modèles développés permettent d'obtenir les données utilisées pour évaluer l'interaction entre les deux approches. Pour ce qui concerne l'approche boîte noire, l'implémentation des modèles *Deep Learning*, les séries de données utilisées, les systèmes étudiés et les critères de performance ont été abordés. Enfin, une interaction entre les deux approches boîte blanche et boîte noire a été étudiée afin de pouvoir bénéficier de leurs avantages et leurs complémentarités.

Chapitre IV : Résultats et discussion

Dans ce chapitre, les principaux résultats obtenus à l'aide des dispositifs expérimentaux et des différents modèles prédictifs et physique seront présentés et discutés. Tout d'abord, les résultats expérimentaux de la chambre froide et de l'entrepôt sont présentés et analysés. Ensuite, les résultats des deux approches de modélisation -boîte blanche et boîte noire seront abordés. Pour conclure, une interaction entre les deux approches citées précédemment sera abordée.

IV.1 Résultats expérimentaux

Cette partie présente la caractérisation de l'effacement et l'influence des différents scénarios sur le comportement thermique et énergétique. Deux régimes de fonctionnement ont été étudiés : permanent et périodes d'effacement.

IV.1.1 Cas chambre froide laboratoire

IV.1.1.1 Régime permanent

Dans cette partie, l'influence de différents paramètres (chargement en produit, température de consigne, température extérieure (Cf. tableau 4).) sur l'évolution thermique de l'air et le fonctionnement de la machine frigorifique sera analysée en régime établi (cycle thermique régulier).

IV.1.1.1.1 Influence des produits

La figure 34 illustre l'évolution de la température de l'air à la reprise pendant le régime permanent dans une chambre froide vide (figure. 34a, b; scénario 1) et chargée (figure. 34c, d; scénario de référence). La température de l'air à la reprise est souvent considérée comme représentative de la température moyenne à l'intérieur de la chambre car elle est le résultat d'un mélange de flux d'air provenant de l'intérieur de la chambre froide. La sonde de thermostat permettant de contrôler la température dans la chambre froide en particulier est souvent placée à la reprise de l'évaporateur. Pour les deux configurations (vide / chargée), les cycles marche / arrêt du compresseur sont similaires, et il a été noté que les fluctuations de la température de l'air dans les deux cas sont comprises entre -15 °C et $-19,5\text{ °C}$. Ces fluctuations sont dues aux cycles de fonctionnement du compresseur marche / arrêt, qui sont contrôlés par le thermostat.

Toutefois, pour les deux configurations, la forme d'un cycle de température est différente. La forme est presque sinusoïdale pour une chambre vide (figure. 34b). Pour la chambre chargée, la forme d'un cycle est plus similaire à une onde carrée (figure. 34d), avec un palier de température (autour de $-15,3\text{ °C}$). Ce palier est dû à l'échange de chaleur entre l'air et les produits qui ralentit l'élévation de la température de l'air, ce qui n'est pas le cas pour la chambre vide.

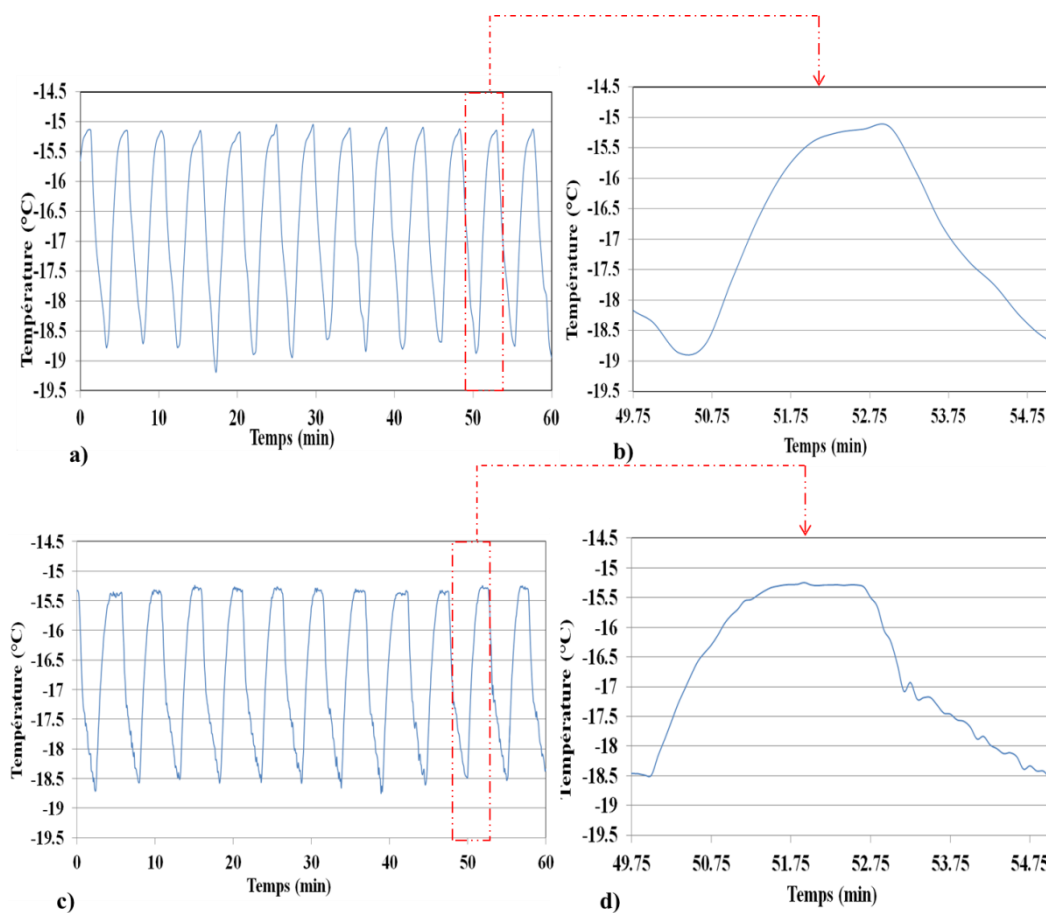


Figure 34 : Evolution de la température durant la phase du régime permanent

a – b) Chambre vide

c – d) Chambre chargée

Le tableau 14 présente la durée du cycle, le nombre de cycles par heure, la température moyenne de l'air et de la consommation d'énergie pendant 1 h en régime permanent pour différents scénarios. La température moyenne de l'air à la reprise pour la chambre vide et chargée est respectivement de $-16,7 \pm 1,3$ °C et $-16,7 \pm 1,7$ °C. Cependant, le cycle de température est légèrement plus long (5,3 min) pour la chambre chargée tandis que la durée du cycle est de 4,7 min pour la chambre vide. En conséquence, le nombre de cycles par heure est de 12,7 pour la chambre vide et de 11,5 pour la chambre chargée. En effet, la présence des produits a une influence importante sur la température de l'air et la machine frigorifique pendant le régime permanent.

Tableau 14 : Comparaison de la durée du cycle, du nombre de cycle par heure, de la température moyenne de l'air et de la consommation d'énergie pendant 1 h en régime permanent

Scénario	Température de consigne (°C)	Température extérieure (°C)	Cycles/h $\pm 10\%$	Durée de cycle (min)	Température moyenne de l'air (°C)	Consommation d'énergie / heure (kJ)
Référence	-18	30	11,5	5,3	-16,7 \pm 1,7	3074
Scénario 1 <i>Chambre vide</i>	-18	30	12,7	4,7	-16,7 \pm 1,3	2889
Scénario 2 <i>Augmentation $T_{consigne}$</i>	-5	30	8,0	7,8	-4,0 \pm 1,2	1837
Scénario 3 <i>Diminution T_{ext}</i>	-18	17	9,5	6,4	-16,5 \pm 1,2	1915

IV.1.1.1.2 Influence de la température de consigne

Pour le scénario 2 (chambre chargée, température de consigne plus élevée - 5 °C et 30 °C en tant que température extérieure), la température moyenne de l'air à l'intérieur de chambre est de -4,0 \pm 1,2 °C et la durée de cycle de 7,8 min. Cette durée est plus longue comparée à celle d'une température de consigne de -18 °C qui est de 5,3 min : la fréquence du cycle diminue avec l'augmentation de la température de consigne, le compresseur fonctionnant moins longtemps dans ce cas. Il est important de mettre en avant que le compresseur a besoin de plus d'énergie pour maintenir un niveau de température inférieur dans la chambre froide : 3074 kJ pour une température de consigne de -18 °C contre 1837 kJ pour une consigne de -5 °C.

IV.1.1.1.3 Influence de la température extérieure

Pour le scénario 3 (chambre chargée, température de consigne -18 °C, température extérieure 17 °C), la température moyenne de l'air dans la chambre est de -16,5 \pm 1,2 °C (tableau 14) et la durée du cycle est de 6,4 min. Ce paramètre a une influence sur le comportement du système pendant la phase du régime permanent. En revanche, son influence est moindre par rapport à la température intérieure pour ce cas d'étude.

IV.1.1.2 Période d'effacement

L'analyse des phénomènes se produisant pendant la période d'effacement se base sur les indicateurs d'impact de l'effacement définis préalablement (Cf. II.1.1.3 Développement des indicateurs pour caractériser les impacts de l'effacement).

IV.1.1.2.1 Impact d'un effacement sur le comportement thermique de l'air et des produits

IV.1.1.2.1.1 Impact sur la température de l'air

La figure 35 présente l'évolution de la température de l'air à l'intérieur d'une chambre vide (a, scénario 1, tableau 4) et chargée (b, scénario de référence) pendant 3 jours d'application de l'effacement (1 effacement / jour).




Figure 35 : Evolution de la température de l'air à l'intérieur de la chambre avec $T_{\text{consigne}}=-18^{\circ}\text{C}$ et $T_{\text{ext}}=30^{\circ}\text{C}$

a) Scénario 1 - chambre vide

b) Scénario de référence (chambre chargée)

Trois types de fluctuation de température avec des amplitudes différentes peuvent être observés dans les 2 cas. Les fluctuations de faible amplitude (entre -15 °C et -19,5 °C pour les deux scénarios) correspondent au cycle de fonctionnement normal (marche / arrêt) du compresseur. Les fluctuations de température d’amplitude moyenne allant jusqu’à -12°C) sont dues aux cycles de dégivrage automatique qui se produisent toutes les 12 h pour la chambre vide et toutes les 6 h pour une chambre chargée. Enfin, les plus grandes amplitudes de fluctuation correspondent aux applications de l’effacement une fois par jour avec des durées croissantes, 1 h, 2 h et 3 h. Pour une durée de 3 heures d’effacement, la température de l’air atteint 6 °C dans le cas d’une chambre vide et -5 °C pour une chambre chargée. La température de l’air augmente immédiatement et rapidement après l’arrêt du compresseur (la mise hors tension du compresseur). Ceci s’explique logiquement par la faible inertie thermique de l’air. L’augmentation de la température est quant à elle plus faible en présence du produit, car l’échange de chaleur entre le produit et l’air limite l’augmentation de la température de l’air à l’intérieur de la chambre froide durant la période d’effacement. Le produit joue ici le rôle de matériau de stockage thermique.

Tableau 15 : $\Delta T_{\max_reprise}$ – Température de l’air maximale atteinte après application d’un effacement à l’intérieur de la chambre froide

$\Delta T_{\max_reprise}$ (°C)	1 ^{er} effacement – 1 h	2 ^d effacement – 2 h	3 ^e effacement – 3 h
Référence	4,3	8,4	9,8
Scénario 1 <i>Chambre vide</i>	10,3	15,8	21,1
Scénario 2 <i>Augmentation $T_{consigne}$</i>	3,2	5,7	7,6
Scénario 3 <i>Diminution T_{ext}</i>	3,8	6,3	8,4

Le tableau 15 présente la remontée de température après application des effacements de 1 h, 2 h et 3 h pour les trois scénarios. D’après ce tableau, l’élévation de température est 2 fois plus faible dans le cas d’une chambre chargée comparée à celle d’une chambre vide (par exemple pour le scénario 1 – chambre vide et scénario de référence – chambre chargée). Pour tous les scénarios (référence, 1, 2 et 3), il a été observé que les $\Delta T_{\max_reprise}$ augmentent avec la durée de l’effacement (figure 36). La remontée de température est également en fonction de la différence de température entre l’intérieur et l’extérieure de la chambre : elle est plus faible pour le

scénario 2 (T intérieure = - 5 °C / T extérieure = 30°C) que pour le scénario de référence (-18°C / 30°C).




Figure 36: Remontée de la température en fonction de la durée de l'effacement pour les différents scénarios

La figure 36 présente l'élévation de température suite à l'application de l'effacement pour les quatre scénarios et pour différentes durées. Cette figure montre qu'il existe une relation quasi linéaire entre la remontée de température maximale et les durées d'effacement pour tous les scénarios.

Il est donc possible avec un nombre limité d'essais de prédire la remontée de température de l'air dans la chambre à partir d'une équation empirique simple de type At .

Le graphique montre que le coefficient A dépend en particulier de l'état du chargement de la chambre.

IV.1.1.2.1.2 Impact sur la température de produit


La figure 37 illustre l'évolution de la température de l'air et des produits à la surface et au cœur des produits pendant 7 jours pour le scénario de référence, le scénario 2 et le scénario 3. Les effacements ont été appliqués pendant les 3 premiers jours avec une fréquence de 1 / jour et des durées croissantes, 1 h, 2 h et 3 h.

Les évolutions de température à la surface du produit sont relativement similaires lors de ces 3 tests. Pour chaque effacement, une légère augmentation de la température de surface du produit comprise entre 0,5 et 3,1°C a été observée (figure 37).


A noter aussi d'après la figure 37 que le comportement de la température de l'air pour les scénarios 2 et 3 est similaire au scénario de référence (figure 37a), Cependant, comme le montre le tableau 15, les $\Delta T_{\max_reprise}$ pour ces deux scénarios (2 et 3) sont inférieurs à ceux des scénario de référence. Ceci s'explique par le fait que les consignes, soit intérieure (scénario 2) ou extérieure (scénario 3) ont été changées.

Tableau 16 : Evolution de la température de surface pour les scénarios 1, 2 et 3 et le scénario de référence


$\Delta T_{\max_surface}$ (°C)	1 ^{er} effacement– 1 h	2 ^d effacement– 2 h	3 ^e effacement – 3 h
Référence	0,9	1,6	3,1
Scénario 1			
Scénario 2	0,5	1,3	2,1
Scénario 3	0,6	1,5	2,3



a)



b)



c)

Figure 37 : Evolution de la température de l'air et du produit à la surface et au cœur des palettes
 a) Référence scénario $T_{\text{consigne}}=-18^{\circ}\text{C}$ et $T_{\text{ext}}=30^{\circ}\text{C}$
 b) Scénario 2 $T_{\text{consigne}}=-5^{\circ}\text{C}$ et $T_{\text{ext}}=30^{\circ}\text{C}$
 c) Scénario 3 $T_{\text{consigne}}=-18^{\circ}\text{C}$ et $T_{\text{ext}}=17^{\circ}\text{C}$

Afin d'expliquer les échanges de chaleur entre l'air et la surface du produit, l'amplitude de la variation de la température de l'air à la reprise et de celle de la surface du produit ont été tracées dans la figure 38.




Figure 38: Relation entre $\Delta T_{\max_reprise}$ et $\Delta T_{\max_surface}$

La figure 38 montre la relation entre $\Delta T_{\max_reprise}$ et $\Delta T_{\max_surface}$. Pour l'ensemble des 3 scénarios, une même relation quasi linéaire entre $\Delta T_{\max_reprise}$ et $\Delta T_{\max_surface}$ a été observée. Cette relation ne dépend donc pas de $T_{consigne}$ ou de T_{ext} mais de la nature de l'échange thermique entre l'air et le chargement dans la chambre qui est lié à la vitesse d'air et la configuration du chargement dans la chambre (identiques pour ces 3 scénarios).

En ce qui concerne le comportement de la température du produit au cœur des palettes durant 7 jours d'expérimentation, les mêmes profils de température ont été observés pour les 3 scénarios (figure 37). Ces profils montrent une lente modification de la température du produit au cœur des palettes. La température continue à augmenter même lorsque la température de surface commence à diminuer, avec un maximum atteint au bout de 3 jours. En effet, après chaque fin de l'effacement, la surface du produit refroidit rapidement grâce à l'échange par convection avec l'air froid à l'intérieur de la chambre, tandis que la température du produit au cœur des palettes continue à augmenter à cause de l'inertie thermique du produit et du délai nécessaire à la propagation de la chaleur à l'intérieur du produit. Ceci est lié aux propriétés thermophysiques du produit (faible diffusivité voir le tableau 2). L'échange thermique entre le produit au cœur des palettes est ainsi plus long, mais est aussi lié à la dimension de la palette

(0,7m x 0,7m x 1,5m). Après 3 jours, la température au cœur des palettes diminue jusqu'à rejoindre sa température initiale au bout de 7 jours. En conséquence, le produit emmagasine le froid en régime normal et le restitue pendant et après la phase d'effacement. Pour cette étude, la fréquence de l'effacement (1 par jour) est ainsi trop élevée pour que le produit ait le temps de revenir à sa température initiale avant l'application de l'effacement.

Pour la suite, afin d'éliminer l'effet de la fréquence de l'application de l'effacement sur l'augmentation de la température du produit au cœur des palettes et aussi pour examiner l'impact de la durée de l'effacement, 3 scénarios supplémentaires dans lesquels un seul effacement a été appliqué avec des durées différentes (1 h, 2 h et 3 h, scénarios 4, 5 et 6 du tableau 4) seront analysés.

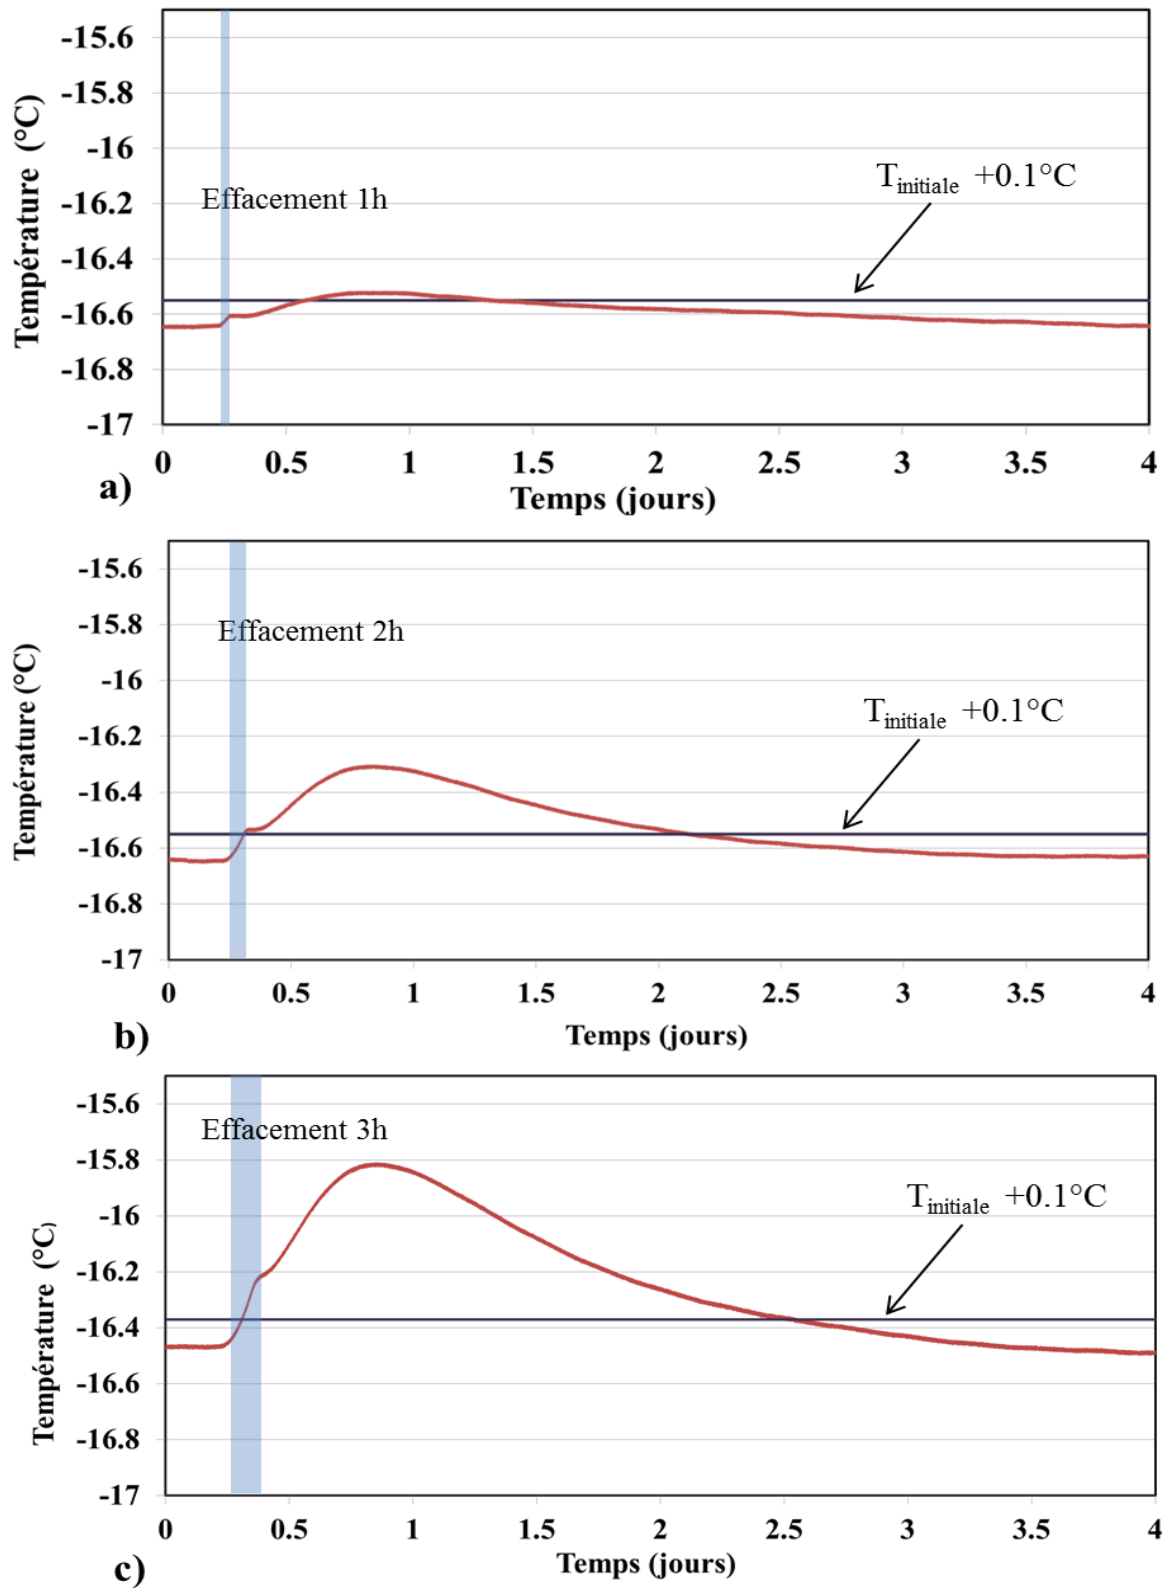


Figure 39 : Influence de la durée de l'effacement sur la température du produit au cœur des palettes à $T_{\text{consigne}} = -18^{\circ}\text{C}$ et $T_{\text{ext}} = 30^{\circ}\text{C}$

- a) 1 heure d'effacement
- b) 2 heures d'effacement
- c) 3 heures d'effacement

La figure 39 illustre l'influence de la durée de l'effacement sur la température du produit au cœur des palettes pour les scénarios 4, 5 et 6, ils ont la même température de consigne et température extérieure que celles du scénario de référence ($T_{\text{consigne}}=-18^{\circ}\text{C}$ et $T_{\text{ext}}=30^{\circ}\text{C}$). Après chaque application de l'effacement (figure 39 a, b et c), la température au cœur des palettes augmente lentement et continue à augmenter même lorsque l'effacement est arrêté pour atteindre son niveau maximum, au bout de 0,8 jour et ce quelle que soit la durée d'effacement étudiée. La température maximale lors de l'application de l'effacement est atteinte dans le cas d'un effacement de 3 h ($-15,8^{\circ}\text{C}$). Elle diminue ensuite progressivement jusqu'à rejoindre le niveau initial : un seuil est défini par $T_{\text{initiale}} +0,1^{\circ}\text{C}$, $0,1^{\circ}\text{C}$ étant la précision des capteurs de température. La durée pour que la température du produit au cœur de la palette rejoigne ce niveau à partir de la fin de l'effacement est de 1 jour pour un effacement de 1 h, 1,7 jours pour un effacement de 2 h et 2,2 jours pour un effacement de 3 h.




Figure 40 : Evolution de la température à cœur des produits dans le cas d'effacements à « haute fréquence » (1 / jour)

La figure 40 montre l'évolution de la température du produit au cœur des palettes lors du scénario de référence. Au cours de cette expérimentation, les effacements ont été appliqués pendant les 3 premiers jours avec une fréquence de 1 effacement / jour et avec des durées croissantes, 1 h, 2 h et 3 h. Le seuil ($T_{\text{initiale}} +0,1^{\circ}\text{C}$) est atteint au bout de 2,1 jours ce qui est proche du résultat obtenu avec un seul de l'effacement de 3 h. Le niveau maximal ($-15,8^{\circ}\text{C}$) est aussi proche du niveau atteint quand un seul effacement de 3 h a été appliqué. La durée de

l'effacement a donc plus d'impact que la fréquence sur le temps nécessaire pour que la température du produit au cœur des palettes retrouve son niveau initial.

IV.1.1.2.1.2.1 Anticipation sur l'effacement

Afin d'éviter une augmentation importante de la température du produit au cœur des palettes après application de l'effacement, un refroidissement des produits par anticipation d'un effacement a été réalisé (scénario 7, tableau 4). Ceci consiste à diminuer la température de consigne de 1°C une journée avant application de l'effacement.

La figure 41 illustre le comportement de la température du produit au cœur des palettes avec et sans anticipation. Après diminution de la température de consigne de 1°C une journée avant l'application de l'effacement, la température du produit diminue progressivement jusqu'à atteindre son minimum qui est de -17,15°C au début de l'effacement (voir la figure 41a). Cependant, le seuil max du retour au niveau initial de la température au cœur des palettes n'est jamais dépassé contrairement à celle sans anticipation. L'anticipation permet d'annuler l'impact de l'effacement sur la température du produit au cœur des palettes sans surconsommation électrique significative ($\Delta e = 0,68\%$).

Il serait intéressant de réaliser d'autres essais afin de déterminer la durée et le niveau de baisse de consigne pour les différents scénarios étudiés (Cf. tableau 4).




Figure 41 : Température du produit au cœur des palettes autour un effacement d'1h

- a) Scénario 7 - avec anticipation
- b) Scénario 4 - sans anticipation

IV.1.1.2.2 Impact de l'effacement sur les performances de la machine frigorifique

Cette partie analyse l'impact des effacements sur la machine frigorifique en utilisant la méthode développée dans la section (II.1.1.5.2).

Le tableau 17 présente des valeurs de la moyenne (m) et des pics de rebond (p) du $ratio_{fonc}$ et 2 indicateurs : taux de rebond ($taux_{rebond}$) et le temps de retour au fonctionnement normal Δt_{retour} (h) de 4 scénarios d'effacement : référence, 1, 2 et 3 (Cf. tableau 4).

Tableau 17 : Paramètres et indicateurs d'impact de l'effacement sur le fonctionnement de la machine frigorifique

Scénario	Référence	Scénario 1 <i>Chambre vide</i>	Scénario 2 <i>Augmentation $T_{consigne}$</i>	Scénario 3 <i>Diminution T_{ext}</i>
<i>Taux fonctionnement moyen (m)</i>	0,45	0,39	0,26	0,28
<i>Pic (p) – Eff, 1 h</i>	0,87	0,63	0,75	0,80
<i>Pic p – Eff, 2 h</i>	0,92	0,91	0,88	0,90
<i>Pic p – Eff, 3 h</i>	0,89	0,93	0,91	0,91
<i>$taux_{rebond}$ – Eff, 1 h</i>	0,92	0,62	1,93	1,83
<i>$taux_{rebond}$ – Eff, 2 h</i>	1,03	1,34	2,43	2,17
<i>$taux_{rebond}$ – Eff, 3 h</i>	0,97	1,40	2,57	2,23
<i>Δt_{retour} (h) – Eff, 1 h</i>	1,11	0,56	1,17	0,82
<i>Δt_{retour} (h) – Eff, 2 h</i>	1,23	1,38	2,89	2,38
<i>Δt_{retour} (h) – Eff, 3 h</i>	1,84	1,31	3,80	3,01

La valeur moyenne du $ratio_{fonc}$ (m) est différente pour chaque scénario : une valeur plus grande indique que la machine doit travailler plus pour produire le froid dans ce scénario. Ainsi, la valeur la plus importante a été obtenue pour le scénario de référence ($m=0,45$). Cela s'explique par le fait que la machine frigorifique est dans une condition de travail qui demande

plus de froid : chambre froide chargée, une consigne basse (-18°C) et une haute température extérieure (30°C). Pour les trois autres scénarios, une de ces conditions est « allégée », soit ; 1- chambre vide, 2-consigne plus haute (-5°C) ou 3-température extérieure plus basse (17°C).

La figure 42 présente le taux de rebond obtenu dans les 4 scénarios : référence, 1, 2 et 3 en fonction de la durée de l'effacement.




Figure 42 : Taux de rebond en fonction de la durée de l'effacement de différents scénarios

Le taux de rebond, qui représente l'augmentation du travail demandé au compresseur au moment du redémarrage après l'effacement par rapport à un fonctionnement normal, augmente avec la durée de l'effacement pour chaque scénario. Un taux de rebond plus important est remarqué pour les scénarios 2 et 3. Cependant, une valeur de taux de rebond ($taux_{rebond} = \frac{p-m}{m}$, eq 5) élevé n'indique pas un pic de rebond important car les valeurs p du tableau 17 sont autour de 0,8 – 0,9 pour tous les scénarios. En fait, le $taux_{rebond}$ correspond plus à une augmentation relative entre p et m et les scénarios 2 et 3 ont des valeurs les plus petites de m . Le compresseur au redémarrage tend en effet à fonctionner sans arrêt pendant une période de temps importante quel que soit le scénario, ce qui correspond à des valeurs de pic de rebond de

l'ordre de 0,9. Le taux de rebond dépend lui des charges thermiques qui diffèrent selon le scénario étudié.

Δt_{retour} , quant à lui, indique le temps nécessaire pour que la machine retrouve son état initial après un effacement. La figure 43 trace les évolutions de Δt_{retour} en fonction de la durée de l'effacement pour les 4 scénarios.




Figure 43 : Temps du retour au fonctionnement normal en fonction de la durée de l'effacement de différents scénarios

Un comportement assez proche de celui du taux de rebond (figure 42) a été observé pour le temps de retour au fonctionnement normal : la machine a besoin de plus de temps pour retrouver son fonctionnement normal après un effacement avec un taux de rebond plus important. Cependant, une relation non-linéaire est observée entre ces 2 paramètres comme le montre la figure suivante :




Figure 44 : Taux de rebond et temps de retour au fonctionnement normal

IV.1.1.2.3 Impact de l'effacement sur la consommation du système frigorifique

La méthode de calcul de la réduction de consommation d'énergie a été présentée dans le paragraphe II.1.5.3.

Tableau 18 : Réduction de la consommation d'énergie due à l'application de l'effacement

Réduction de la consommation	Δe (%)	Δe [MJ]
Reference	-10,2	-23
Scénario 1 <i>Chambre vide</i>	-7,4	-15,6
Scénario 2 <i>Augmentation $T_{consigne}$</i>	0,8	1
Scénario 3 <i>Diminution T_{ext}</i>	0,3	0,4

Le tableau 18 indique que l'application de l'effacement peut générer une réduction de la consommation d'énergie (valeurs négatives dans ce tableau). Une explication possible est que lors d'un effacement l'air et le produit se réchauffent, ce qui fait qu'ils subissent moins de

dépense thermiques avec l'extérieur, ce qui réduit la consommation de la machine frigorifique.

La résolution de l'appareil de mesure est de 2%. L'incertitude globale de la mesure est estimée à 5%. Celle-ci prend aussi en compte la période d'échantillonnage qui est comprise entre 5 et 20 secondes.

La réduction de la consommation d'énergie la plus importante a été obtenue avec le scénario de référence. Le chargement, la température de consigne et la température extérieure sont des paramètres importants influençant cette réduction.

IV.1.2 Cas d'un entrepôt frigorifique

Dans le cadre du projet Ademe Flexifroid, des effacements ont été réalisés en entrepôt frigorifique de grande dimension. Pour des raisons de confidentialité, la température présentée dans les résultats de l'entrepôt est une température relative. Cette température relative a été obtenue en soustrayant la valeur mesurée à une température de référence choisie.

IV.1.2.1 Impact d'un effacement sur la température de l'air




Figure 45 : Evolution de la température relative de l'air à l'intérieur d'un entrepôt frigorifique avec des effacements de 1 h, 2 h et 4 h

La figure 45 présente l'évolution de la température relative de l'air à l'intérieur d'un entrepôt frigorifique alors que des effacements sont effectués. L'application de l'effacement a été faite une fois par jour avec des durées croissantes 1 h, 2 h et 4 h pendant 3 jours. Comme observé précédemment dans le cas de la chambre froide, une augmentation immédiate de la température de l'air a été observée après application de chaque effacement. En revanche, cette remontée de température de l'air est limitée. Ceci est lié à l'inertie thermique qui est ici très élevée dans cet entrepôt frigorifique, chargé avec 16 000 tonnes de produits. Après l'application de chaque effacement, la température de l'air revient à sa température initiale (avant effacement), au bout de quelques heures.

IV.1.2.2 Impact de l'effacement sur le produit




Figure 46 : Evolution de la température relative du produit à la surface et au cœur des palettes à l'intérieur d'un entrepôt frigorifique avec des effacements de 1 h, 2 h et 4 h

La figure 46 illustre l'évolution de la température moyenne du produit à la surface ainsi qu'au cœur des palettes. Comme cela a été déjà observé dans le cas de la chambre froide (voir la figure 37), la remontée de la température du produit à la surface apparaît immédiatement après application de l'effacement. En revanche, la redescente en température après chaque effacement n'apparaît qu'après 24 h. Il a été noté qu'après 4 jours d'essais la remontée de la température

relative atteint $0,3^{\circ}\text{C}$. Pour la température du produit au cœur de la palette, la remontée de la température a été progressive. Après 4 jours d'essais, la remontée de température atteint $0,5^{\circ}\text{C}$.

Pour cette configuration (entrepôt frigorifique) les mesures de la consommation électrique propres à la machine frigorifique n'ont pu être isolées de la consommation électrique globale de la chambre froide et n'ont donc pas pu être exploitées pour la validation.

Pour finir, un tableau qui compare l'élévation de la température de l'air dans le cas d'une chambre froide et dans le cas d'un entrepôt frigorifique est présenté.

Tableau 19 : Température de l'air maximale atteinte après application d'un effacement de 1 h et 2 h dans le cas d'une chambre froide et dans le cas d'un entrepôt frigorifique

$\Delta T_{\text{max_air}} (^{\circ}\text{C})$	1 ^{er} effacement– 1 h	2 ^d effacement– 2 h
Chambre froide ($T_{\text{ext.}} = 17^{\circ}\text{C}$ $T_{\text{consigne}} = -18^{\circ}\text{C}$)	3,8	6,3
Entrepôt frigorifique ($T_{\text{ext.}} = 16^{\circ}\text{C}$ $T_{\text{consigne}} = -18^{\circ}\text{C}$)	0,4	0,6

D'après le tableau 19, l'élévation de la température de l'air pour un effacement de 1 h et de 2 h est plus importante dans le cas de la chambre froide. Cela est dû au taux de chargement qui est plus important dans le cas d'un entrepôt frigorifique. Ce tableau met en relief l'importance de l'inertie thermique pour limiter la remontée de température de l'air à l'intérieur d'un système (soit à petite échelle, chambre froide ou bien à une grande échelle, entrepôt frigorifique).

IV.2 Conclusion sur les résultats expérimentaux

Ces études expérimentales ont permis de caractériser l'effacement dans une chambre froide laboratoire et un entrepôt industriel. Pour le cas de la chambre froide, l'influence de différents paramètres (chargement en produit, température de consigne, température extérieure) sur l'évolution thermique de l'air et le fonctionnement de la machine frigorifique a été analysée. Par ailleurs les essais réalisés (chambre froide et entrepôt frigorifique) mettent logiquement en avant l'importance du chargement pour diminuer l'amplitude de la remontée de température de l'air, et ainsi réduire l'impact de l'effacement sur les produits entreposés.

Il est à noter que la remontée de température à la surface des produits n'excède jamais 3°C – la valeur limite définie dans ce document - « Arrêt du 21 décembre 2009» [119] avec une fréquence d'un effacement par jours pendant 3 jours, dans les 2 configurations : chambre froide et entrepôt frigorifique.

En complément, ces résultats obtenus dans le cas des produits surgelés ne peuvent pas être généralisés aux produits frais. Pour ces derniers (stockés à une température positive), aucune tolérance particulière n'est prévue règlementairement quant à leur température de conservation.

IV.3 Approche boîte blanche

Le modèle boîte blanche (modèle Ademe Flexifroid (<https://flexifroid.irstea.fr>), permet de simuler et d'évaluer l'impact énergétique de l'effacement en termes de température (air et produit) et de consommation électrique dans deux configurations : chambre froide et entrepôt frigorifique.

En effet, ce modèle permet de simuler plusieurs types de configurations, architectures et chargements (chambre froide chargée ou vide, entrepôt frigorifique avec toutes ses spécifications).

L'objectif de cette section est de présenter une validation expérimentale du modèle boîte blanche, avant d'utiliser les résultats du modèle pour l'interaction boîte noire / blanche.

IV.3.1 Validation du modèle dans le cas de la chambre froide laboratoire

La validation du modèle boîte blanche sera effectuée sur dans le cas de la chambre froide vide et chargée.

IV.3.1.1 Validation sur la température de l'air

IV.3.1.1.1 Chambre vide




Figure 47 : Effacement 1h, température de l'air avec la prédiction de la boîte blanche et la référence expérimentale dans le cas de la chambre vide $T_{int}=-18^{\circ}\text{C}$ et $T_{ext}=17^{\circ}\text{C}$

La figure 47 présente la température de l'air en présence d'une période d'une heure d'effacement avec la prédiction de la boîte blanche et la référence expérimentale en chambre froide laboratoire. La courbe rouge sur le graphe représente la température de l'air prédite et la courbe bleue désigne sa référence expérimentale. Après l'arrêt du compresseur, la température de l'air augmente progressivement pour les deux cas à savoir, la prédiction de la boîte blanche et la référence expérimentale. Cela est due à la faible inertie thermique de l'air et la différence de température entre l'air et les parois de la chambre. Le deuxième pic ($t=3$ h) correspond à la période dégivrage. L'allure de la courbe prédite par le modèle boîte blanche est légèrement inférieure à la référence expérimentale.

Après la remise en route du compresseur, la température de l'air descend rapidement pour rattraper le fonctionnement normal avant l'effacement dans les deux cas. Cette descente est plus significative pour le modèle. Ceci s'explique probablement par le fait que le modèle boîte blanche est un modèle simplifié ne tenant pas compte des hétérogénéités de la température de l'air et des parois dans la chambre.

IV.3.1.1.1 Chambre chargée




Figure 48 : Effacement 1h, température de l'air avec la prédiction de la boîte blanche et la référence expérimentale dans le cas de la chambre chargée $T_{int}=-18^{\circ}\text{C}$ et $T_{ext}=30$ (scénario 4)

La figure 48 présente la température de l'air dans le cas de chambre laboratoire chargée obtenue avec le modèle boîte blanche et sa référence expérimentale pour un effacement d'une heure. La vitesse de remontée en température de l'air pour les deux cas (température du modèle et sa référence expérimentale) est moins importante dans le cas de la chambre froide chargée que dans le cas de la chambre vide. Ceci s'explique par l'inertie thermique liée en grande partie à la masse de produits présents dans la chambre. Comme cela était mentionnée dans la partie expérimentale (Cf. tableau 15), la remontée de température de l'air lors d'un effacement d'une heure en présence du chargement ne dépasse pas $4,5^{\circ}\text{C}$, alors que cette remontée est de $10,6^{\circ}\text{C}$ si la chambre est vide.

Le modèle boîte blanche prédit bien le comportement de la température de l'air dans sa globalité. Toutefois, l'allure de la courbe prédite est légèrement supérieure à la référence expérimentale, contrairement au cas précédent de la chambre vide. Ce qui s'explique probablement par une sous-estimation de transfert de chaleur entre le produit et l'air.

IV.3.1.1.2 Validation sur le produit




Figure 49 : Effacement 1 h, température du produit à la surface et au cœur avec la prédiction de la boîte blanche et la référence expérimentale dans le cas de la chambre chargée ; $T_{int} = -18^{\circ}\text{C}$ et $T_{ext} = 30^{\circ}\text{C}$ (scénario 4)

La figure 49 montre la température du produit à la surface et au cœur avec la prédiction boîte blanche et la référence expérimentale. À l'arrêt du compresseur, une augmentation de la température à la surface du produit pour les deux cas (température du modèle et sa référence expérimentale) a été observée. Cette augmentation correspond à l'augmentation rapide de la température de l'air (voir la figure 48). En outre, une lente modification de la température au cœur du produit a également été constatée dans le cas de la boîte blanche et la référence expérimentale. Les différences de vitesse de remontée s'expliquent par le fait que la surface du produit échange directement avec l'air froid à l'intérieur de la chambre par convection, alors que l'échange de chaleur avec le cœur ne se fait que par conduction. Le modèle boîte blanche prédit une remontée de température du produit à surface plus importante que la remontée expérimentale, ceci étant lié à la température de l'air prédite, qui elle-même est supérieure à la température expérimentale de l'air. La remontée de température à cœur est très faible dans les deux cas, le modèle sous-estimant légèrement les valeurs. En effet, l'amas de produit constitue un milieu poreux et l'échange de chaleur ne se fait pas uniquement par conduction (hypothèse du modèle), mais aussi par convection naturelle à l'intérieur de la palette.

IV.3.2 Validation du modèle le cas de l'entrepôt frigorifique

IV.3.2.1 Validation sur la température de l'air

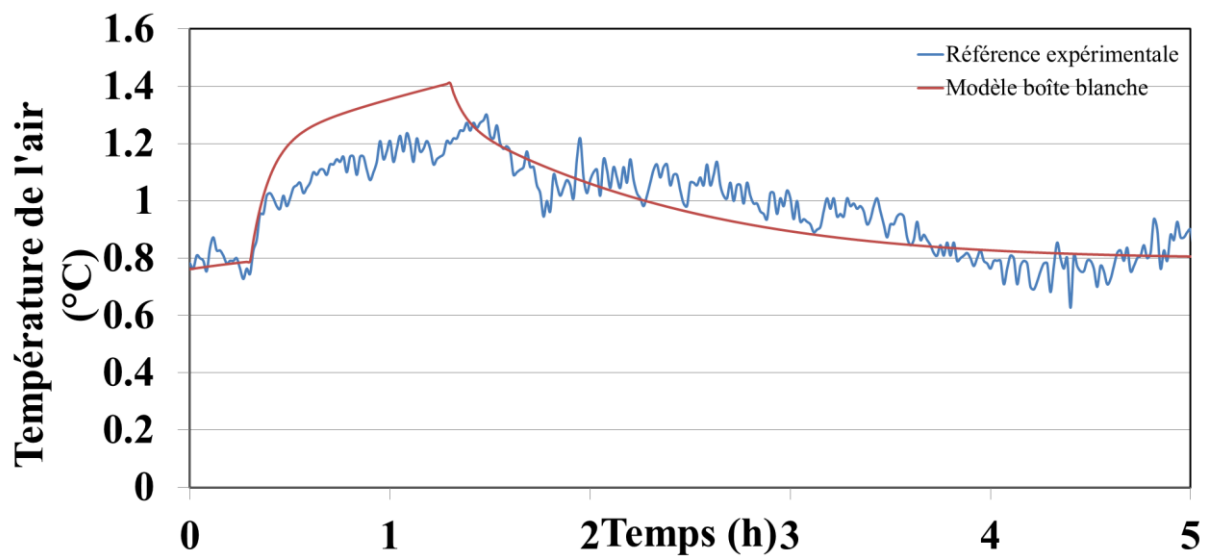


Figure 50 : Effacement 1 h, température de l'air avec la prédiction de la boîte blanche et la référence expérimentale dans le cas d'un entrepôt le 14 février 2019

La figure 50 compare la température relative de l'air prédite par le modèle boîte blanche et la référence expérimentale dans le cas d'un entrepôt frigorifique. La remontée de température dans le cas d'un entrepôt frigorifique chargé ne dépasse pas 1,5°C pour un arrêt d'une heure de l'installation frigorifique. En effet, dans le cas d'un entrepôt frigorifique, la masse des produits est beaucoup plus importante ce qui tend à minimiser cette remontée.

Comme dans le cas de la chambre froide, le modèle Flexifroid donne une bonne prédiction de la température de l'air dans le cas d'un entrepôt frigorifique, avec une légère surestimation de la température maximum atteinte lors de l'effacement.

IV.3.2.2 Validation sur le produit




Figure 51 : Effacement 1 h, température du produit à la surface et au cœur avec la prédiction de la boîte blanche et la référence expérimentale dans le cas d'un entrepôt le 14 février 2019

La figure 51 présente les températures du produit à la surface et au cœur avec le modèle boîte blanche et la référence expérimentale. À l'arrêt de l'installation frigorifique, il n'y a pas d'augmentation significative de température du produit à la surface ni au cœur pour le cas de la référence expérimentale. La mesure de température de surface a été effectuée à l'intérieur de la palette et non directement à la surface en contact avec l'air, ce qui explique en grande partie la différence avec le modèle qui prédit lui une légère remontée en température.

IV.4 Conclusion sur l'approche boîte blanche

Les résultats expérimentaux dans le cas de la chambre froide et d'entrepôt frigorifique ont validé le modèle boîte blanche. En effet, le modèle a prédit de manière satisfaisante le comportement thermique pour les deux systèmes (chambre froide et entrepôt).

Le modèle boîte blanche a été testé avec d'autres configurations (résultats non présentés dans ce manuscrit) : scénario de référence, scénario 1 et d'autres essais. Les résultats de ces tests indiquent que le modèle est capable de suivre différentes évolutions expérimentales.

IV.5 Approche boîte noire

L'approche boîte noire permet de prédire la température à l'intérieur de la chambre et la consommation électrique du compresseur avec plusieurs modèles *Deep Learning* (Convolutif, LSTM, LSTM – Convolutif, LSTM – Stacked et LSTM – Bidirectionnel).

Ces modèles seront testés pour répondre au mieux aux questions suivantes :

- 1) quel(s) modèle(s) d'apprentissage en profondeur est (sont) les plus adaptés à représenter nos données spécifiques : quel(s) modèle(s) est (sont) moins sensibles au comportement de la température et de la puissance électrique du compresseur et quel(s) modèle(s) est (sont) plus robuste(s) par rapport à la qualité des données (par exemple, le bruit du signal) ?
- 2) quel est l'influence du nombre d'entrées et de sorties sur les résultats de la prédiction des sorties souhaitées ?
- 3) quel est l'influence du pas de temps sur la prédiction des sorties ?

Comme présenté dans la partie « matériels et méthode boîte noire », afin d'évaluer les performances de prédiction de ces modèles, la comparaison se fait avec les données expérimentales issues de la chambre froide. Dans le cadre de cette étude, l'approche « boîte noire » n'a toutefois pas été appliquée à l'entrepôt frigorifique, par manque de données expérimentales disponibles pour cette configuration.

IV.5.1 Comparaison des performances des modèles développés

IV.5.1.1 Phase d'apprentissage

Dans cette partie, les résultats de la phase d'apprentissage des modèles *Deep Learning* seront discutés. Cela permet d'examiner si ces modèles ont bien « appris » les comportements dynamiques de la chambre froide liés aux applications de l'effacement. La figure ci-dessous présente le résultat de l'apprentissage obtenu par le modèle LSTM.




Figure 52 : l'apprentissage de la température de reprise de la série E4 avec le modèle LSTM à 10 entrées et 4 sorties

La figure 52 présente l'apprentissage de la température de reprise de la série E4 avec le système à 10 entrées et 4 sorties (Cf. tableau 10). La courbe bleue sur la figure 52 représente la courbe de référence expérimentale de la température de reprise pendant la phase d'apprentissage et la courbe noire indique son apprentissage par le modèle LSTM. D'après la figure 52, le modèle LSTM a bien appris le comportement de la température de reprise pendant la phase d'effacement. Néanmoins, un léger bruit est apparu sur la courbe noire (courbe d'apprentissage) pendant la période d'effacement.




Figure 53 : Puissance du compresseur de la série E4 pendant la période d'apprentissage avec le modèle LSTM à 10 entrées et 4 sorties

La figure 53 présente l'apprentissage de la puissance du compresseur de la série E4 avec le système à 10 entrées et 4 sorties. D'après cette figure, le modèle LSTM a bien appris le comportement de la puissance pendant la phase d'effacement. De plus, peu de bruit a été observé pendant la période d'effacement. Pour conclure, le modèle LSTM présente de bonnes performances d'apprentissage du comportement de la température de reprise à l'intérieur de la chambre et de la puissance du compresseur.

Tableau 20 : Performance des modèles par rapport à l'apprentissage de la température de reprise et de la puissance du compresseur dans la série E4 avec un système à 10 entrées et 4 sorties

Système à 10 entrées 4 sorties - série E4 apprentissage	Modèle Convolutif	Modèle LSTM	Modèle LSTM-Convolutif	Modèle LSTM-Stacked	Modèle LSTM-Bidirectionnel
Température de reprise	(Fit=55,4%, MAE=0,36)	(Fit=77,6%, MAE=0,23)	(Fit=65,6%, MAE=0,23)	(Fit=79,8%, MAE=0,24)	(Fit=70,0%, MAE=0,26)
Puissance du compresseur	(Fit=18,4%, MAE=0,69, CV=123,5)	(Fit=92,6%, MAE=0,05, CV=12,8)	(Fit=91,4%, MAE=0,07, CV=18,2)	(Fit=93,1%, MAE=0,08, CV=21,3)	(Fit=92,3%, MAE=0,12, CV=47,2)

Le tableau 20 montre la performance des modèles par rapport à l'apprentissage de la température de reprise et à la puissance du compresseur sur l'ensemble des données d'apprentissage (partie apprentissage de 126184 points) dans la série E4 avec un système de 10 entrées et 4 sorties. D'après ce tableau, l'utilisation du modèle LSTM et ses dérivées est très prometteuse grâce à leurs bonnes performances d'apprentissage. Pour rappel, dans la phase d'apprentissage, les données à la fois d'entrées et de sorties sont utilisées pour construire les modèles (calcul et optimisation des poids des neurones pour minimiser l'erreur de prédiction). Ensuite, dans la phase de validation, seules les données d'entrées sont utilisées pour la prédiction.

IV.5.1.2 Phase de validation - Performance des modèles sur un horizon de prédiction

Dans cette partie, la comparaison des performances des 5 modèles lors de la phase de validation, à savoir, Convolutif, LSTM, LSTM – Convolutif, LSTM – Stacked et LSTM – Bidirectionnel sera faite.

Ces modèles, dans cette section, utilisent les mêmes entrées et sorties (tableau 10) : 10 entrées et 4 sorties. Parmi les sorties, 3 températures de reprise et la puissance du compresseur seront prédites. Dans ce qui suit, une seule température de reprise sera présentée dans les résultats car les 2 autres températures de reprise ont des comportements très similaires.

Afin de comparer la prédiction des modèles, une petite partie de la période de test comprenant un effacement d'1 h est présentée sur les graphes. En effet, la période d'effacement correspondant aux plus grandes variations de température, représente la partie essentielle à prédire. Cependant, il est aussi nécessaire de vérifier que la prédiction obtenue par ces modèles donne également des résultats suffisamment précis sur les autres périodes (régime permanent, dégivrage...).

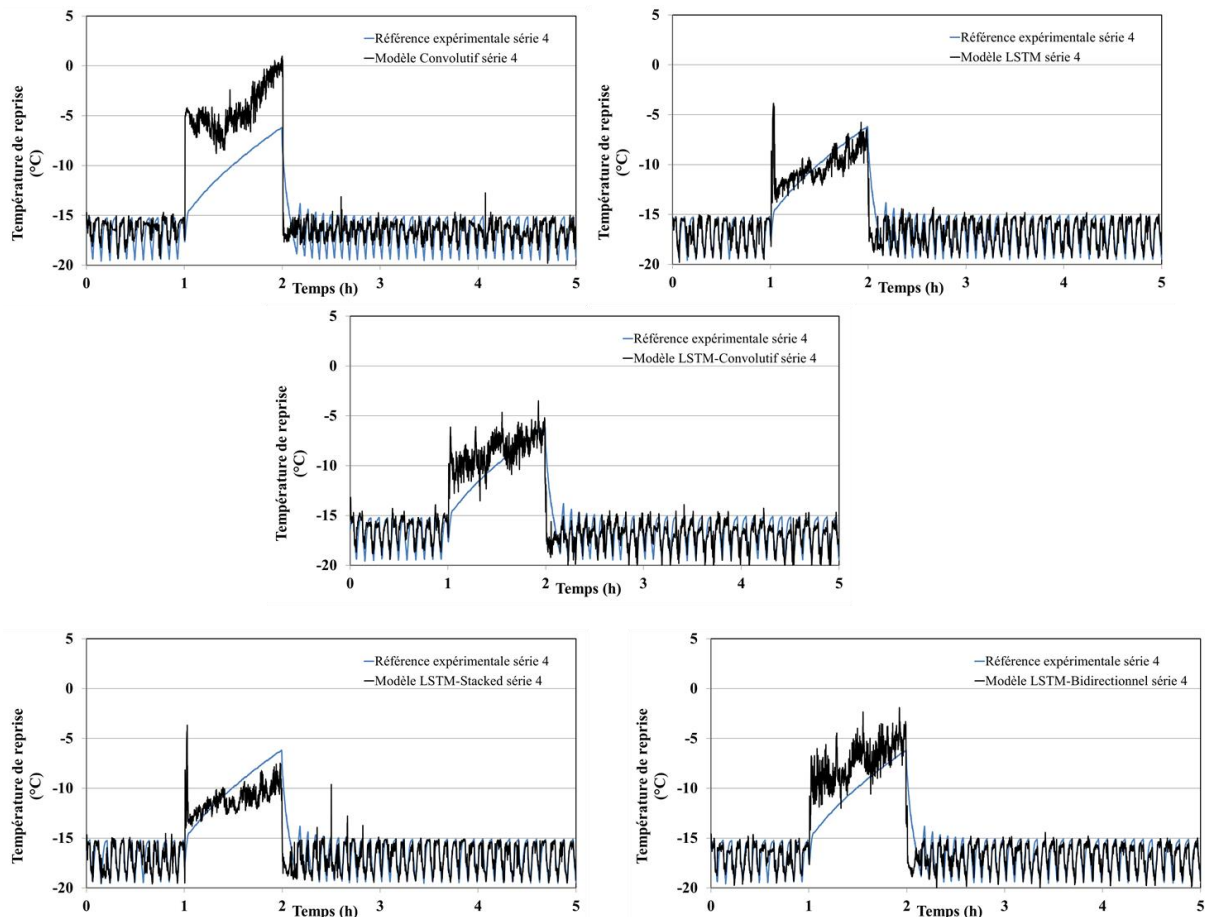


Figure 54 : Prédiction de température de reprise de la série E4 avec les 5 modèles (système à 10 entrées et 4 sorties)

La figure 54 présente la prédiction de la température de reprise de la série E4 avec les 5 modèles.

La courbe bleue sur la figure 54 représente la courbe de référence expérimentale de la température de reprise et les courbes noires indiquent sa prédiction par les différents modèles.

Tout d'abord, il apparaît que les 5 modèles détectent bien le début et la fin de l'effacement grâce à l'utilisation de l'indice de fonctionnement, qui est la variable binaire Dr [0,1] (effacement ou non). La prédiction diverge lors du début de l'effacement mais rejoint la valeur

mesurée à la fin de l'effacement, ce qui peut provenir du manque d'information, sur le comportement de la température, lors d'un effacement à l'entrée du modèle.

Il convient de noter la présence des fluctuations sur la courbe de prédiction (noire) pendant la période d'effacement, ce qui n'est pas le cas des données expérimentales (bleues) présentant une allure plus lisse. Ceci est dû au bruit blanc dans les données, qui est liée au fait que les données d'entrées ne sont pas moyennées et aussi au pas de temps d'acquisition petit (5 secondes). Cet effet de lissage des données grâce à l'utilisation des données moyennées sera examiné dans la section **Erreur ! Source du renvoi introuvable.**

La prédiction du comportement de la température de reprise dans la période d'effacement avec le modèle convolutif est assez médiocre, mais, l'utilisation du modèle LSTM et ses dérivées permet une meilleure prédiction. Il est donc intéressant d'analyser les résultats de prédiction de la puissance afin de vérifier si cette tendance se confirme.

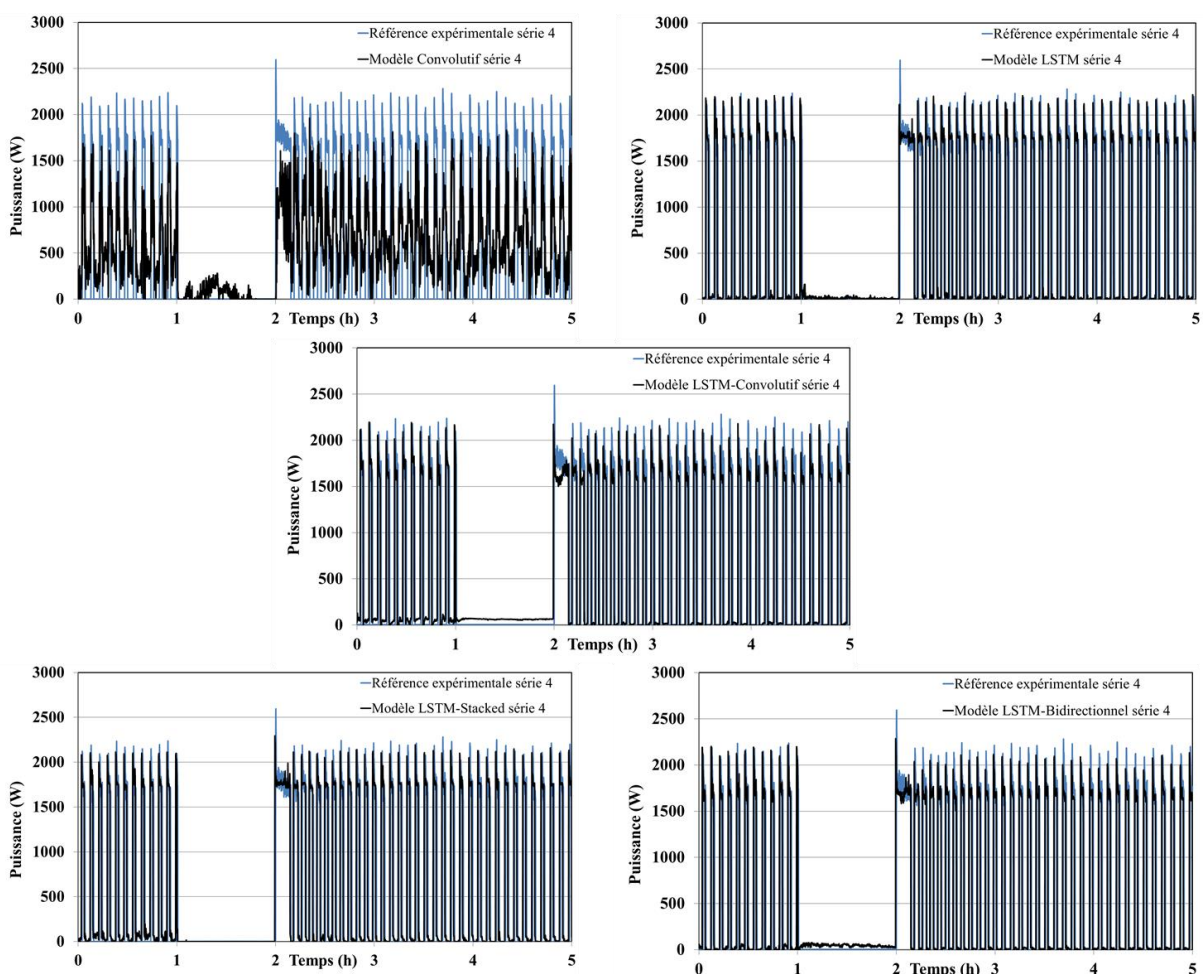


Figure 55 : Prédiction de la puissance du compresseur avec les 5 modèles (série E4, système 10 entrées 4 sorties)

Les résultats sur la figure 55 montre que, comme pour la température de reprise, la prédiction de la consommation du compresseur avec le modèle convolutif est moins performante que les autres modèles. Les résultats de la prédiction sur la puissance du compresseur avec les modèles LSTM donnent quant à eux de meilleurs résultats par rapport à la prédiction de la température, avec moins de bruit sur la période d'effacement. Il est à noter que pour tous les modèles étudiés, la prédiction de puissance a déjà une meilleure performance que celle de la température lors de la phase d'apprentissage. De plus, on remarque que le pic de rebond après le redémarrage du compresseur a bien été appris (ce qui n'est pas le cas du modèle convolutif). Cela tient au fait que les modèles LSTM prennent en compte la temporalité des données à traiter avec un pas de temps petit de 5 secondes.

On peut donc conclure que les modèles LSTM sont capables de prédire le comportement dynamique des séries temporelles, mais ils sont sensibles au bruit, ce qui est particulièrement remarquable sur la température de reprise pendant la période d'effacement.

La performance du modèle LSTM pour prédire la température de reprise et la consommation du compresseur d'un système à 10 entrées et 4 sorties peut être caractérisée en utilisant les critères suivants : le Fitting (Fit), la Mean Absolute Error (MAE), la Mean Squard Error (MSE), la Root Mean Squared Error (RMSE) et le Coefficient de Variation (CV). Dans cette étude, trois de ces critères, le Fitting (Fit), la Mean Absolute Error (MAE) et le Coefficient de Variation (CV, seulement pour la puissance) seront analysés.

Une meilleure performance de prédiction est démontrée par un pourcentage de Fit élevé proche de 100 et des valeurs de MAE et CV faibles proches de 0.

Tableau 21 : Performance des modèles par rapport à la prédiction de la température de reprise et de la puissance du compresseur dans la série E4 avec un système à 10 entrées et 4 sorties

Système à 10 entrées 4 sorties - série E4 Validation	Modèle Convolutif	Modèle LSTM	Modèle LSTM-Convolutif	Modèle LSTM-Stacked	Modèle LSTM-Bidirectionnel
Température de reprise	(Fit=34,2%, MAE=0,36)	(Fit=55,1%, MAE=0,23)	(Fit=52,1%, MAE=0,23)	(Fit=53,6%, MAE=0,24)	(Fit=51,9%, MAE=0,26)
Puissance du compresseur	(Fit=14,0%, MAE=0,69, CV=123,5)	(Fit=91,2%, MAE=0,05, CV=12,8)	(Fit=88,2%, MAE=0,07, CV=18,2)	(Fit=85,3%, MAE=0,08, CV=21,3)	(Fit=67,0%, MAE=0,12, CV=47,2)

Le tableau 21 présente la performance des 5 modèles sur l'ensemble de l'horizon de prévision (partie de validation de 4,9 jours) par rapport à la prédiction de la température de reprise et de la puissance du compresseur dans la série E4 avec un système de 10 entrées et 4 sorties. Il est important de noter que l'horizon de prédiction de la série E4 est important (de 4,9 jours).

Un bon accord avec les résultats graphiques a été constaté. Le modèle convolutif simple ne donne pas de bons résultats pour les deux sorties (température de reprise et la consommation du compresseur), étant donné qu'il n'est pas adapté pour traiter les données de séries temporelles. De meilleurs résultats sont obtenus grâce à l'utilisation du réseau LSTM et ses dérivées.

Avec ce système à 10 entrées et 4 sorties, le modèle LSTM, qui est un modèle simple possédant une unique couche à 1024 cellules de mémoire, obtient de meilleures performances de prévision sur l'ensemble de l'horizon qui est de 4,9 jours. Ainsi, les techniques d'augmentation de la profondeur d'un réseau (LSTM-Stacked), de conservation des informations à la fois liées aux données passées mais aussi aux données futures (LSTM bidirectionnel) et de couplage des deux réseaux de neurones (LSTM-Convolutif) ne donnent pas de meilleurs résultats sur la prévision que le réseau simple (LSTM).

IV.5.2 Effet de réduire le nombre des entrées et des sorties sur la prédiction - Effet de moyennner des données d'entrées et de sorties

Afin de limiter le bruit, une réduction du nombre des variables d'entrées et de sorties en moyennant les 5 mesures de température extérieure et les trois mesures de température de reprise a été faite.

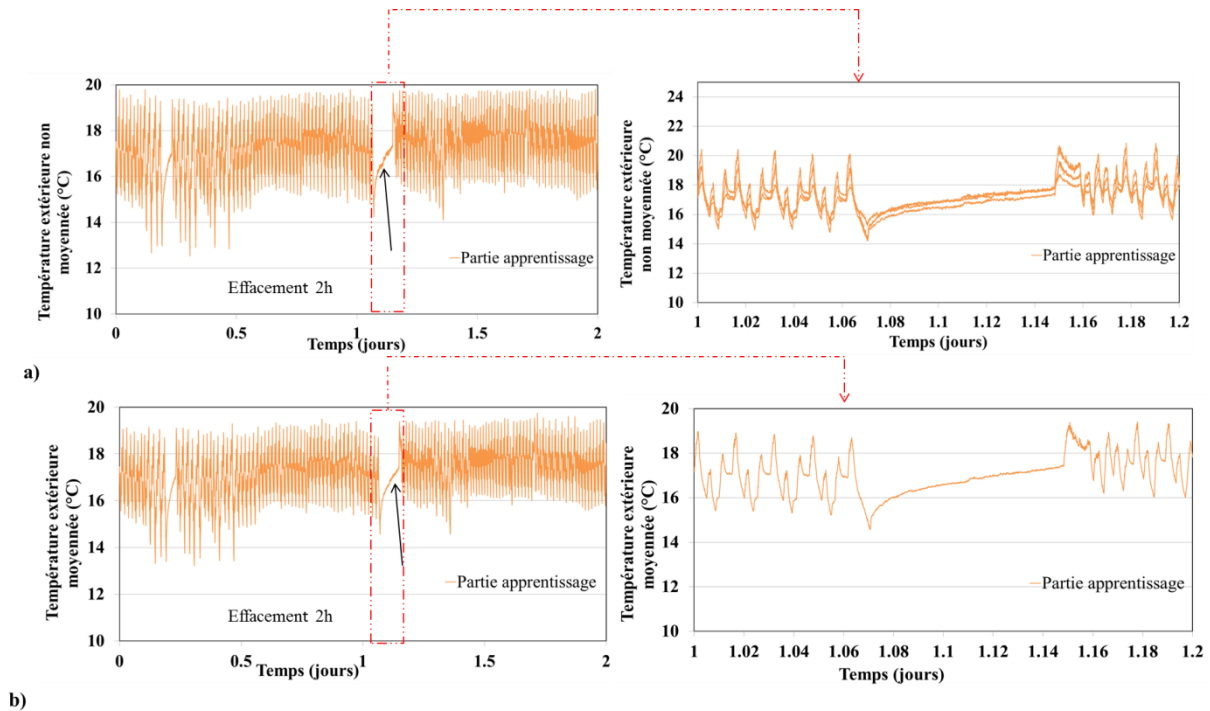


Figure 56 : Température extérieure mesurée pendant la phase d'apprentissage

- a) non moyennée
- b) moyennée

La figure 56 présente la température extérieure mesurée (figure 56.a, non moyennée et figure 56.b, moyennée) pendant la phase d'apprentissage. Il apparait que pendant la phase d'effacement, la courbe de la température extérieure non moyennée présente plus de bruit que celle de la température extérieure moyennée. Ainsi, le système à 10 entrées et 4 sorties devient un système à 6 entrées et 2 sorties (voir le tableau 22).

Tableau 22 : Réduction du nombre d'entrées et de sorties du modèle LSTM

Système à 10 entrées et 4 sorties	Nom	Description		Système à 6 entrées et 2 sorties	Nom	Description
Entrées	T_{ext} (°C)	5 mesures de température extérieure	⇒	Entrées	T_{ext} (°C)	1 mesure de température extérieure moyennée (la moyenne des 5 températures)
	Deg[0,1]	Dégivrage (Off / ON)			Deg[0,1]	Dégivrage (Off / ON)
	Dr [0,1]	Effacement (Off / ON)			Dr [0,1]	Effacement (Off / ON)
	Time Deg	Temps depuis le dernier dégivrage (× 5 secondes)			Time Deg	Temps depuis le dernier dégivrage (× 5 secondes)
	Time Dr	Temps depuis le dernier effacement (× 5 secondes)			Time Dr	Temps depuis le dernier effacement (× 5 secondes)
	Comp [0,1]	Compresseur (Off / ON)			Comp [0,1]	Compresseur (Off / ON)
Sorties	T_r (°C)	3 mesures de température de reprise	Sorties	T_r (°C)	1 mesure de température de reprise moyennée (la moyenne des 3 températures)	
	P (W)	Consommation du compresseur		P (W)	Consommation du compresseur	

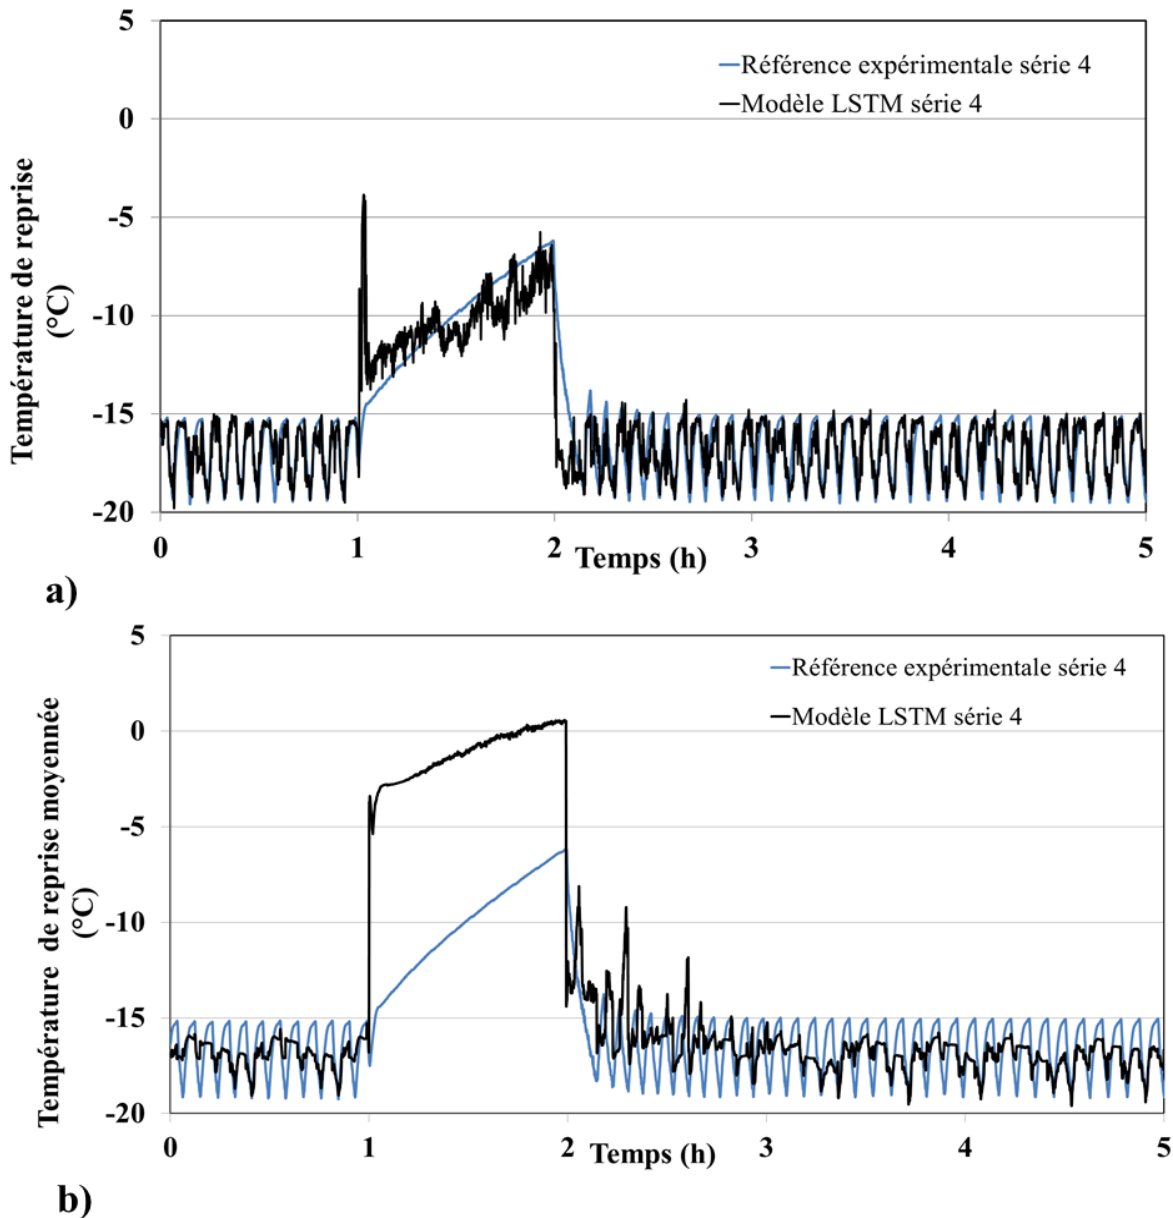



Figure 57: Prédiction de la température de reprise avec le modèle LSTM dans les deux systèmes : a) 10 entrées et 4 sorties, b) 6 entrées et 2 sorties


La figure 57 illustre la prédiction de la température de reprise obtenue avec le modèle LSTM pour les deux systèmes (système à 10 entrées et 4 sorties et système à 6 entrées et 2 sorties). D'après la figure 57b, le modèle LSTM semble avoir des difficultés à prédire le comportement de la température de reprise avec des données moyennées en comparaison aux résultats du système à 10 entrées et 4 sorties (figure 57a, données non moyennées). On constate en particulier une forte surestimation de la remontée de température lors de l'effacement. Ainsi, en moyennant les données d'entrées et de sorties, le modèle perd des informations importantes sur le comportement du système, ce qui explique les écarts entre la prédiction et les données

expérimentales. En revanche, le bruit est moins apparent sur la prédiction en moyennant les données (Cf. figure 56).

La figure 58 (a et b) compare la puissance du compresseur prédite par le modèle LSTM pour les deux cas (système à 10 entrées et 4 sorties et système à 6 entrées et 2 sorties). La prédiction de la puissance est moins affectée par cette modification des données. Le résultat montre aussi que le bruit qui est présent sur la figure 58a n'apparaît plus sur la courbe de prédiction (modèle LSTM) de la figure 58b. Cela se traduit par une courbe lisse au niveau de la période d'effacement. Cependant, les pics de puissance au début de chaque cycle de fonctionnement du compresseur ont aussi disparu pour le système utilisant des données moyennées, ce qui réduit la qualité de la prédiction.



a)



b)

Figure 58 : Prédiction de la puissance du compresseur avec le modèle LSTM dans les deux cas : a) 10 entrées et 4 sorties, b) 6 entrées et 2 sorties

IV.5.3 Influence des entrées sur la prédiction

Même s'il permet de réduire le bruit de la prédiction, le système à 6 entrées et 2 sorties présentent des résultats assez modestes par rapport à la prédiction de la température de reprise qui est obtenue avec un système à 10 entrées et 4 sorties. Afin de renforcer le modèle pour qu'il prédise mieux la courbe de température de reprise, une solution possible est d'ajouter aux entrées du système une information sur le comportement physique de la température à l'intérieur de la chambre froide laboratoire. Cela se fait en ajoutant la température de soufflage moyennée comme une entrée. De ce fait, le nouveau système devient cette fois-ci, un système à 7 entrées et 2 sorties (comme le montre le tableau 22). C'est le modèle d'apprentissage par renforcement.




Figure 59 : Température de soufflage et température de reprise pendant la période d'apprentissage

La figure 59 présente la température de soufflage et la température de reprise pendant la période d'apprentissage.

Tableau 23 : Entrées et sorties des deux systèmes :

- a) système à 6 entrées et 2 sorties
- b) système à 7 entrées et 2 sorties

Système à 6 entrées et 2 sorties	Nom	Description
Entrées	T_{ext} (°C)	1 Température extérieure moyennée (la moyenne des 5 températures)
	Deg[0,1]	Dégivrage (Off / ON)
	Dr [0,1]	Effacement (Off / ON)
	Time Deg	Temps depuis dernier dégivrage (× 5 secondes)
	Time Dr	Temps depuis dernier effacement (× 5 secondes)
	Comp [0,1]	Compresseur (Off / ON)
	Sorties	T_r (°C)
P (W)		Consommation du compresseur



Système à 7 entrées et 2 sorties	Nom	Description
Entrées	T_{ext} (°C)	1 Température extérieure moyennée (la moyenne des 5 températures)
	Deg[0,1]	Dégivrage (Off / ON)
	Dr [0,1]	Effacement (Off / ON)
	Time Deg	Temps depuis dernier dégivrage (× 5 secondes)
	Time Dr	Temps depuis dernier effacement (× 5 secondes)
	Comp [0,1]	Compresseur (Off / ON)
	T_{souf}	1 Température de soufflage moyennée (la moyenne des 3 températures)
Sorties	T_r (°C)	1 Température de reprise moyennée (la moyenne des 3 températures)
	P (W)	Consommation du compresseur




Figure 60 : Prédiction de la température de reprise moyennée avec le modèle LSTM (7 entrées et 2 sorties)

La figure 60 représente la température de reprise moyennée prédite par le modèle LSTM simple pour un système à 7 entrées et 2 sorties. Le résultat montre que les courbes de température de reprise moyennées prédites et de la référence expérimentale se superposent quasiment : le modèle LSTM simple à 7 entrées et 2 sorties a obtenu de meilleurs résultats par rapport au système avec 6 entrées et 2 sorties (voir la figure 57b). En effet, l'ajout de la température de soufflage moyennée donne au modèle plus d'information sur le comportement thermique de la chambre. Cependant, la présence de pics à la fin de l'effacement (absents des données expérimentales) est observée. Ceci est dû au fait que le modèle LSTM, qui est caractérisé pour conserver des informations à court terme et à long terme, a appris sur des périodes d'effacement où le dégivrage apparaît immédiatement à la fin de l'effacement.

D'après la figure 61 ci-dessous, la prédiction de la consommation avec le système à 7 entrées et 2 sorties donne également de meilleurs résultats pour la prédiction de la puissance du compresseur.




Figure 61 : Prédiction de la puissance du compresseur avec le modèle LSTM simple (7 entrées et 2 sorties)

Les performances du modèle LSTM dans la prédiction de la température de reprise et la consommation dans les différents systèmes d'entrées et sorties sont présentées dans le tableau 24.

Tableau 24 : Performance du modèle LSTM par rapport à la prédiction de la température de reprise et de la puissance du compresseur dans la série E4 pour les 3 systèmes

Modèle LSTM Série E4 Phase de validation	Température de reprise	Puissance du compresseur
10 entrées 4 sortie	(Fit=55,1%, MAE=0,23)	(Fit=91,2%, MAE=0,05, CV=12,8)
6 entrées 2 sorties	(Fit=27,9%, MAE=0,41)	(Fit=87,1%, MAE=0,07, CV=19,3)
7 entrées 2 sorties	(Fit=73,4%, MAE=0,12)	(Fit=92,6%, MAE=0,05, CV=11,5)

Le tableau 24 représente la performance du modèle LSTM sur l'ensemble de l'horizon de prévision (partie de test de 4,9 jours) par rapport à la prédiction de la température de reprise et

de la puissance du compresseur. Comme observé précédemment dans les graphiques, le modèle LSTM est moins performant sur l'ensemble de l'horizon de prédiction quand les données moyennées sont utilisées (6 entrées 2 sorties). La performance du modèle LSTM est meilleure dans le cas du système à 7 entrées et 2 sorties. Par ailleurs, pour les 3 systèmes, le modèle LSTM se montre très efficace pour prédire la puissance sur l'ensemble de l'horizon de prévision qui contient des périodes d'effacement ; ceci se traduit par un nombre de Fitting élevé (Fit proche de 100%) et une erreur limitée.

IV.5.4 Influence du nombre de données des périodes d'effacement de la partie apprentissage sur la prédiction

Le nombre de données des périodes d'effacement utilisé dans la phase d'apprentissage peut constituer un paramètre influençant la qualité des modèles pour apprendre les changements de comportement liés à l'effacement. Cette quantité de données dépend du nombre de périodes d'effacement d'une part et du pas de temps d'autre part.

Afin d'étudier l'impact de ce paramètre sur la performance des modèles, les prédictions de température de reprise obtenues par les 2 séries suivantes sont comparées :

- E4, pas de temps d'acquisition de 5s, dans la partie apprentissage : 126184 points, 14 effacements pour une durée de 7,3 jours. Cette série a été utilisée dans les précédentes analyses,
- E5, pas de temps d'acquisition de 20s, dans la partie apprentissage : 10704 points, 14 effacements pour une durée de 2,5 jours.

Ces résultats proviennent du modèle LSTM-Stacked avec un système à 10 entrées et 4 sorties (tableau 10).

Comme montrée dans la figure 62, la prédiction du modèle LSTM-Stacked est légèrement meilleure dans le cas de la série E5 malgré un nombre total de points moins important. Par ailleurs, la courbe du modèle LSTM-Stacked présente moins de fluctuations dans le cas de la série E5 lors de la période d'effacement. En effet, les données avec un pas de temps de 20 secondes comportent moins de bruit par rapport à celles obtenues avec un pas de temps de 5 secondes de la série E4.

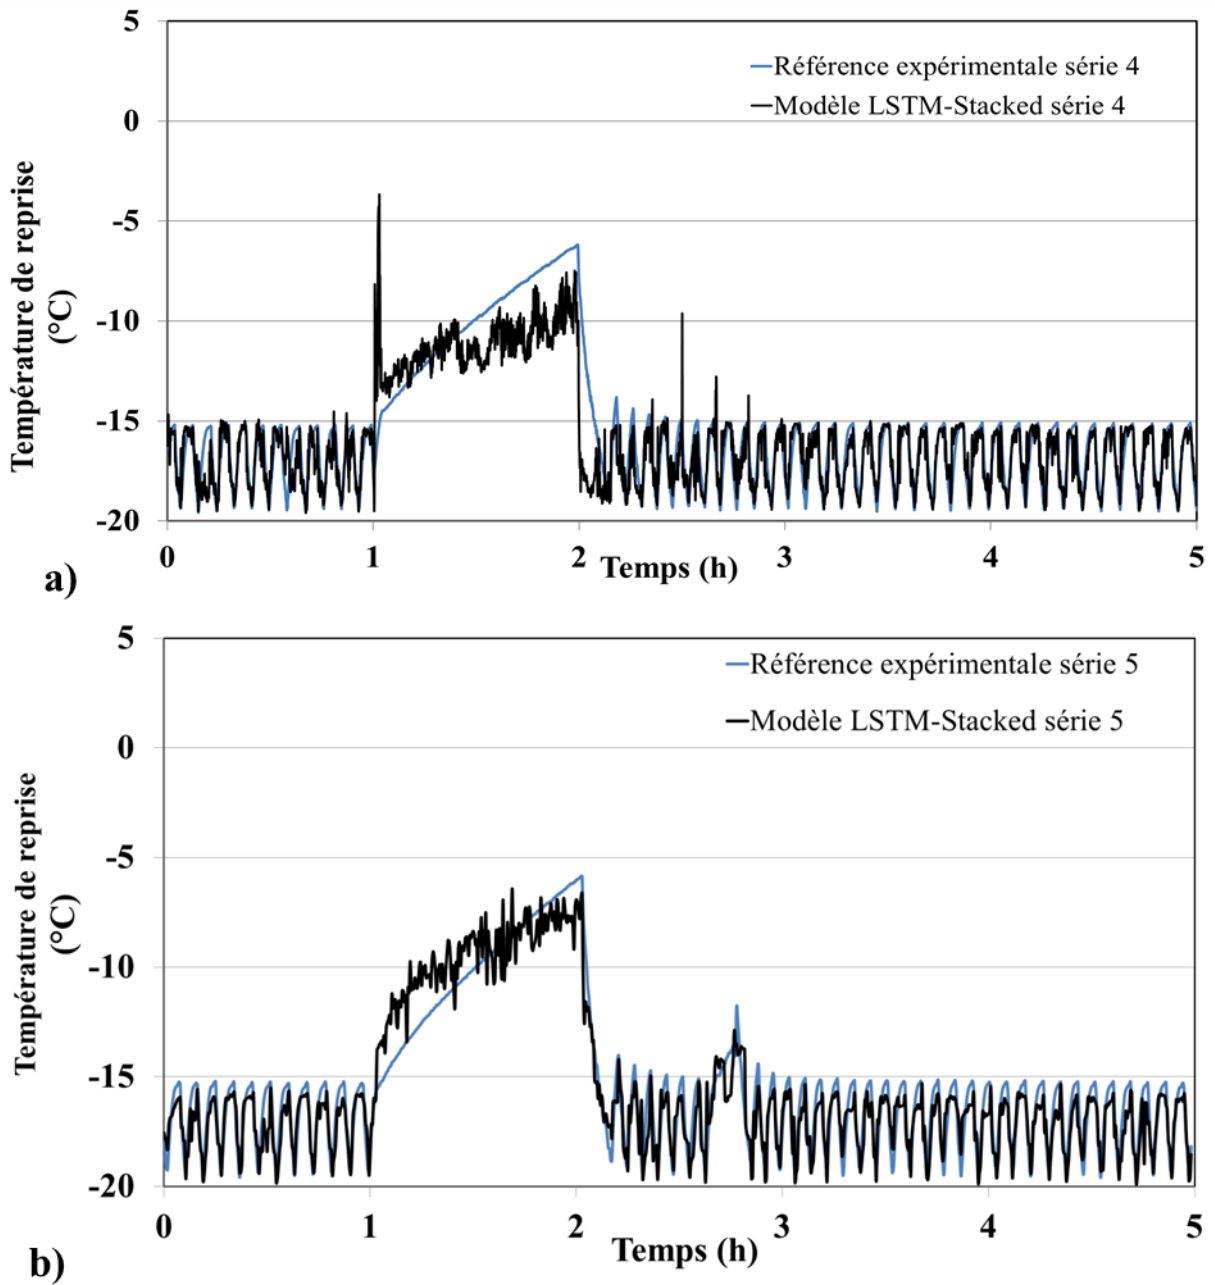




Figure 62 : Prédiction de la température de reprise avec le modèle LSTM – Stacked avec un système à 10 entrées et 4 sorties pour deux séries de données (Série E4 (5s) et Série E5 (20s))



a)



b)

Figure 63 : Prédiction de la puissance du compresseur avec le modèle LSTM dans les deux séries de données, série E4 (5s) et série E5 (20s),

D'après la figure 63, le modèle LSTM-Stacked prédit bien l'évolution de la puissance pour les deux séries de données E5 et E4. Cependant, dans le cas de la série E4, le modèle LSTM-Stacked arrive à mieux prédire la puissance pendant la période de l'effacement (puissance = 0): moins de bruit est observé. Ce résultat montre que la puissance est plus sensible au nombre de points total qui est plus grand dans le cas d'E4.

Tableau 25 : Performance du modèle LSTM par rapport à la prédiction de la température et de la puissance du compresseur avec les deux séries 4 et 5

Modèle LSTM-Stacked (10 entrées et 4 sorties)	Nombre d'effacements dans la partie apprentissage	Nb_eff_app / Nb_total_app % de ce rapport	Température de reprise	Puissance du Compresseur
Série E4 (pas de temps de 5 secondes)	14	20160 points / 126184 points 15,9%	(Fit=53,1%, MAE=0,23)	(Fit=85,3%, MAE=0,05, CV=12,8)
Série E5 (pas de temps de 20 secondes)	14	2520 points / 10704 points 23,54%	(Fit=61,1%, MAE=0,28)	(Fit=88,4 %, MAE=0,08, CV=18,6)

Nb_eff_app : nombre de points des périodes d'effacement dans la partie apprentissage

Nb_total_app : nombre total de points dans la partie apprentissage

Le tableau 25 compare la performance du modèle LSTM-Stacked pour la prédiction de la température de reprise et la puissance utilisant les séries E4 et E5. Il est important de mentionner que ces performances étaient calculées sur l'ensemble de l'horizon de prévision (partie de test) qui est de 4,9 jours pour la série E4 et 1,6 jours pour la série E5.

D'après le tableau 25, le modèle LSTM-Stacked obtient des performances légèrement meilleures pour la prédiction de la température de reprise dans le cas de la série E5. Cela s'explique par la densité des données liées aux périodes d'effacement, représentée par le pourcentage de nombre de points des périodes d'effacement par rapport au nombre de points total. Ce pourcentage est plus important dans le cas de la série E5, 23,54% contrairement à E4 avec une valeur de 15,9%.

Concernant la prédiction de la puissance, le modèle LSTM-Stacked se montre très efficace pour la prédiction de la consommation lors de l'application de l'effacement qui se traduit par un nombre de Fitting élevé (proche de 100%) et une erreur faible (proches de 0) pour les 2 séries. Cela est due au fait que le modèle a obtenu suffisamment d'informations par ses entrées concernant la puissance (compresseur Off / On). Pendant que le Fitting est meilleur dans le cas de la série E5, une erreur légèrement plus importante est observée pour la série E5 (MAE et CV plus

grands) que pour la série E4 ce qui montre la sensibilité de la puissance par rapport au nombre total de points.

Le paramétrage des modèles a été testé mais n'est pas présenté dans cette partie à savoir, le nombre d'itération pour apprentissage et le nombre de couches denses (le nombre de couches cachées). Les résultats obtenus ont montré, que dans notre cas, ces paramètres ont peu d'influence sur la prédiction des sorties.

IV.6 Conclusion sur l'approche boîte noire

Cette étude de l'approche boîte noire a permis de prédire le comportement thermique et énergétique lors d'un effacement. L'influence de plusieurs paramètres sur la qualité de la prédiction des sorties a été étudiée :

- choix des entrées et sorties du modèle. Le meilleur résultat de prédiction avec le modèle LSTM a été obtenu avec le système qui considère la température au soufflage - Tsouf comme entrée (Système à 7 entrées et 2 sorties). Ceci s'explique par l'influence de l'ajout de l'information sur le comportement de la température à l'intérieure de la chambre,
- choix d'un modèle par rapport à un autre : les meilleurs résultats ont été obtenus avec le modèle LSTM simple et ces dérivées pour tous les systèmes,
- besoin d'un volume de données suffisamment représentatif des différents comportements du système. Ces données serviront à l'apprentissage et à la validation. En effet, la meilleure prédiction a été obtenue dans le cas de la série E4 qui a un nombre de points le plus important. Ajoutant à cela, le choix de la nature des données (moyennées ou non moyennées),
- choix de l'horizon de prédiction qui joue un rôle important dans la précision de la prévision. En effet, pour les deux série E4 et E5 avec des horizons de prédiction important 4,9 jours et 1,6 jours respectivement, les résultats montrent que les modèles LSTM présentent des performance assez élevé (Fitting supérieur à 85% en puissance et supérieur à 50% en température de l'air, ainsi que l'erreur MAE inférieur à 0,3),
- l'analyse comparative des résultats des séries E4 et E5 a souligné l'importance de la densité de données liée aux périodes d'effacement (Cf. tableau 25) pour la prédiction de la température et de la puissance,

- paramétrage du modèle qui est un critère crucial dans la performance et l'optimisation du modèle.

Un avantage de l'utilisation de cet outil pour la prévision de charges est qu'il est généralisable, et peut être déployé en peu de temps sur plusieurs configurations de bâtiments, y compris des systèmes de grandes échelles.

En revanche, la difficulté à réaliser des essais d'effacement pour un système et la nécessité de disposer d'une quantité importante de données mesurées peuvent conduire à générer des données d'après une approche de modélisation boîte blanche afin de simuler plusieurs configurations, architectures et taux de remplissage d'un entrepôt ou d'une chambre froide.

IV.7 Interaction entre les deux approches de modélisation

Cette section concerne le couplage des deux approches boîte noire et boîte blanche. Il est à rappeler que l'objectif est de proposer une méthode permettant de bénéficier des avantages des deux approches. D'une part, l'approche boîte noire peut présenter des performances de prédiction très élevées comme il a été vu précédemment, en particulier lorsque l'on utilise l'information sur la température de soufflage, et ne nécessite pas la connaissance des propriétés physiques du système à étudier ; néanmoins cette approche s'appuie sur un grand nombre de données expérimentales de référence en particulier pour la phase d'apprentissage. D'autre part, l'approche boîte blanche nécessite une connaissance précise des caractéristiques physiques du système ; en contrepartie, cette approche peut être validée sur un nombre réduit de données expérimentales. L'approche boîte blanche peut également générer un grand nombre de données en peu de temps qui peuvent ensuite être utilisées pour la phase d'apprentissage de l'approche boîte noire. Ainsi, l'interaction entre les deux approches pourrait permettre en théorie de palier un manque de données expérimentales, pas toujours disponible sur un site industriel (ex : la température de soufflage, entre autres, dans un entrepôt frigorifique), pour la phase d'apprentissage de l'approche boîte noire. Néanmoins, il est nécessaire d'évaluer la performance de ce type de couplage. En particulier, l'utilisation d'un modèle boîte blanche permet de générer des données sans « bruit » ce qui peut avoir un impact sur la performance d'apprentissage du modèle boîte noire. Enfin, le couplage boîte blanche / boîte noire pourrait être une solution pour se passer de l'utilisation de l'information sur la température de soufflage.

D'après les résultats obtenus dans la partie boîte noire, en utilisant les données expérimentales comme référence, le modèle LSTM et ses variantes ont donné les meilleures prédictions. Dans

ce qui suit, un seul modèle est présenté : le modèle LSTM-Convolutif. Le choix de présenter ce modèle par rapport à un autre a été fait en raison de ses critères de performance élevés (Fitting, MAE et CV). Dans cette partie, les données simulées par le modèle boîte blanche pour la chambre chargée seront utilisées comme référence afin de valider la prédiction avec le modèle *Deep Learning*.

Les résultats présentés ci-dessous représentent un premier inventaire de l'utilisation des données issues d'un modèle physique (boîte blanche avec 6 entrées, sans la température de soufflage, et 2 sorties) pour l'apprentissage d'un modèle boîte noire. Ces résultats préliminaires ont été obtenus sur un nombre réduit de période d'apprentissage et représentent donc une première étape dans la compréhension du couplage des approches boîte noire et boîte blanche.

IV.7.1 Phase d'apprentissage




Figure 64 : température extérieure pendant la phase d'apprentissage

La figure 64 présente la température extérieure pendant la phase d'apprentissage. La température extérieure change de comportement d'un effacement à un autre pour permettre au modèle de simuler différentes températures extérieures.




Figure 65 : l'apprentissage de la température de l'air avec le modèle LSTM-Convolutif (6 entrées et 2 sorties) série E6

La figure 65 présente l'apprentissage de la température de l'air par le modèle LSTM-Convolutif avec les données d'E6. La courbe bleue sur la figure 65 représente la courbe de référence obtenue du modèle boîte blanche et la courbe noire indique son apprentissage par le modèle LSTM-Convolutif. Les résultats obtenus montrent que le modèle de prédiction n'apprend pas bien le comportement de la température de l'air sur les données de la boîte blanche. En effet, la température prédite par le modèle LSTM-Convolutif présente un comportement proche de la température extérieure (Cf. figure 64).




Figure 66 : l'apprentissage de la puissance du compresseur avec le modèle LSTM-Convolutif (6 entrées et 2 sorties) série E6

La figure 66 présente l'apprentissage de la puissance du compresseur avec le modèle LSTM-convolutif. Les résultats montrent que le modèle LSTM-Convolutif n'a pas bien appris le comportement de la puissance du compresseur. Pour conclure, le modèle LSTM-Convolutif a des difficultés à apprendre sur des données simulées obtenus du modèle boîte blanche.

Tableau 26 : Critères de performance de prédiction pendant l'apprentissage - partie interaction

Système à 6 entrées 2 sorties - série E6 Phase d'apprentissage	Modèle Convolutif	Modèle LSTM	Modèle LSTM-Convolutif	Modèle LSTM-Stacked	Modèle LSTM-Bidirectionnel
Température de reprise	(Fit=46,9%, MAE=0,4)	(Fit=56,3%, MAE=0,3)	(Fit=51,2%, MAE=0,3)	(Fit=56,9%, MAE=0,3)	(Fit=55,8%, MAE=0,3)
Puissance du compresseur	(Fit=0,1%, MAE=0,1, CV=1393,5)	(Fit=1,4%, MAE=0,07, CV=1374,4)	(Fit=1,4%, MAE=0,08, CV=1374,6)	(Fit=1,4%, MAE=0,07, CV=1372,7)	(Fit=1,3%, MAE=0,08, CV=1372,7)

IV.7.2 Prédiction sur la température de l'air




Figure 67 : Prédiction de la température de l'air avec le modèle LSTM-Convolutif (6 entrées et 2 sorties) série E6

La figure 67 présente la prédiction de la température de l'air obtenue avec le modèle LSTM-Convolutif (système à 6 entrées et 2 sorties, Cf. tableau 13). La courbe bleue sur la figure 57 représente la courbe de référence obtenue du modèle boîte blanche et la courbe noire indique sa prédiction par le modèle LSTM-Convolutif. Les courbes montrent que le modèle LSTM-Convolutif prédit l'augmentation de la température de l'air lors de l'effacement sans la présence du bruit, contrairement à l'approche boîte noire avec uniquement apprentissage et validation sur les résultats expérimentaux (Cf. tableau 24). Ce résultat représente donc un premier intérêt du couplage boîte noire / boîte blanche. Toutefois, l'allure de la courbe obtenue par le modèle LSTM-Convolutif est légèrement différente de la référence boîte blanche, ce qui confirme que le modèle n'a pas suffisamment appris pendant la période d'apprentissage (10367 points correspondant à 1,6 jours) (Cf. figure 65), contrairement au cas où on utilise les données expérimentales, où la période d'apprentissage est plus importante (série E4 126184 points correspond à 7.3 jours) (Cf. figure 52).

Il est à noter également que le modèle LSTM-Convolutif semble avoir des difficultés à prédire les oscillations de la température de l'air dues aux cycles marche-arrêt du compresseur hors période d'effacement. Ceci montre donc que l'absence de bruit dans les données générées par

le modèle boîte blanche peut réduire la performance du modèle boîte noire. Ce résultat doit néanmoins être confirmé sur un temps d'apprentissage avec plus de données. Enfin, les résultats prédits par le modèle LSTM-Convolutif sont caractérisés par des changements brusques qui peuvent être expliqués par la nature des données d'apprentissage. En effet, ces données sont issues de la simulation d'un modèle boîte blanche, en particulier l'allure des variations de température extérieure (Cf. figure 64).

IV.7.3 Prédiction sur la puissance




Figure 68 : Préviation de la puissance du compresseur avec le modèle LSTM-Convolutif (6 entrées et 2 sorties) série E6

La figure 68 montre la prédiction de la puissance du compresseur obtenue par le modèle LSTM-Convolutif (système à 6 entrées et 2 sorties). Le modèle LSTM-Convolutif prédit bien le comportement de la puissance du compresseur lors de la période d'effacement (valeur = 0). Toutefois, en dehors de la période d'effacement, l'allure de la courbe prédit par le modèle LSTM-Convolutif est inférieure à la référence boîte blanche. Contrairement à ce qu'il a été observé dans le cas de l'utilisation des données expérimentales (Cf. résultats IV.5), les erreurs de prédiction ne peuvent pas être dues aux erreurs de mesure (en particulier le bruit de mesure), mais plutôt aux modèles eux-mêmes ou à leur couplage. Une des possibilités serait liée au fait que les valeurs utilisées pour les poids des neurones soient déterminées d'une manière autonome à chaque itération d'apprentissage dans ce type de modèle non supervisé (Cf. I.5.2.3).

Tableau 27 : Performance des modèles par rapport à la prédiction de la température de l'air, et de la consommation du compresseur dans la série E6 (système à 6 entrées et 2 sorties) avec l'utilisation des données d'entrées et sorties issues du modèle physique

Système à 6 entrées 2 sorties - série E6 phase de validation	Modèle Convolutif	Modèle LSTM	Modèle LSTM-Convolutif	Modèle LSTM-Stacked	Modèle LSTM-Bidirectionnel
Température de reprise	(Fit=45,7%, MAE=0,4)	(Fit=26,6%, MAE=0,5)	(Fit=54,6%, MAE=0,4)	(Fit=35,4%, MAE=0,5)	(Fit=34,8%, MAE=0,5)
Puissance du compresseur	(Fit=0,2%, MAE=0,2, CV=222,8)	(Fit=51,7%, MAE=0,05, CV=108,4)	(Fit=50,7%, MAE=0,07, CV=112,7)	(Fit=49,7%, MAE=0,06, CV=112,4)	(Fit=48,7%, MAE=0,7, CV=117,9)

Le tableau 27 présente la performance des 5 modèles sur l'ensemble de l'horizon de prévision (partie de test de 1,6 jour) par rapport à la prédiction de la température de l'air et de la puissance du compresseur pour la série E6.

Le modèle LSTM-Convolutif donne de meilleurs résultats pour les deux sorties (température de l'air et puissance du compresseur). Les modèle LSTM et ses variantes ont de meilleures performances par rapport au modèle convolutif sur l'ensemble de l'horizon qui est de 1,6 jours. Cependant, une meilleure prédiction de la puissance du compresseur a été obtenue en utilisant les données d'entrée et de sortie issues de la mesure expérimentale (Cf. tableau 21).

iv.8 Conclusion

Cette étude a montré la faisabilité de l'utilisation des données produites par un modèle « boîte blanche » pour l'apprentissage et la validation d'un modèle « boîte noire » afin de prédire le comportement de la chambre froide lors d'applications de l'effacement. Les résultats ont montré un potentiel prometteur de cette interaction des deux approches. Les résultats ont souligné que les erreurs de prédiction ne proviennent pas du bruit des entrées. Toutefois, les écarts de prédiction pourraient venir du modèle utilisé mais aussi du profil des données d'entrées, température extérieure en particulier et d'une possibilité de manque de données. Une meilleure prédiction a été obtenue avec le modèle hybride LSTM-Convolutif. Grâce à

l'utilisation de la boîte blanche, les données sont générées en peu de temps avec variation de différents paramètres d'entées à savoir, la température extérieure et la durée de l'effacement. Pour les futurs travaux, il serait intéressant de tester une base de données plus importantes et d'autres configurations, en particulier celle de l'entrepôt industriel.

Conclusion et perspectives

Les travaux présentés dans ce manuscrit ont permis d'étudier et de caractériser l'impact de l'effacement électrique sur des chambres froides et entrepôt frigorifiques. En effet, grâce à l'inertie thermique des produits entreposés, ces systèmes présentent un grand potentiel pour l'application de l'effacement.

Dans un premier temps, une synthèse bibliographique sur l'application de l'effacement dans différents secteurs a été réalisée afin de comprendre les méthodes utilisées et d'examiner l'impact de l'effacement en fonction du choix des méthodes de fonctionnement. Par ailleurs, un état de l'art des méthodes de modélisation physique - boîte blanche et data driven - boîte noire ainsi que leurs interactions a été réalisé afin de prédire l'état thermique et énergétique du système au cours d'un effacement.

L'approche boîte blanche décrit avec précision la dynamique du système à l'aide d'équations différentielles, modélisant les variations des propriétés physiques. Malgré leur sensibilité au bruit ou à la discontinuité des données, ce type de modèle est très intéressant pour l'identification de liens de causalité entre les paramètres. L'approche boîte noire, quant à elle, consiste à masquer ou à ignorer les équations en posant la question « quels types de relations » peut-il y avoir entre les données. C'est une approche focalisée sur les données et l'exploration des relations existantes entre elles, en apprenant à partir de leur comportement et non à partir des équations qui les décrivent. D'après l'analyse bibliographique, les modèles des réseaux de neurones de type « *Deep Learning* » semblent être les plus adaptés à notre problématique, qui est de prédire le comportement thermique et énergétique à l'intérieur de la chambre froide / l'entrepôt frigorifique. En effet, ces systèmes dynamiques présentent de fortes variations temporelles lors d'un effacement.

Dans le cadre de cette thèse, une étude expérimentale a été mise en œuvre pour étudier plusieurs scénarios d'effacement (durée, fréquence et conditions opératoires) et développer des indicateurs pour caractériser l'impact de l'effacement sur le comportement thermique et énergétique des systèmes frigorifiques. Cette étude a mis en avant l'importance de l'état de chargement pour limiter la remontée de température de l'air et réduire l'impact de l'effacement sur les produits entreposés. Les indicateurs ont montré que le taux de rebond et le temps de retour au fonctionnement normal après l'application de l'effacement dépendent de l'état de fonctionnement de la machine frigorifique. De plus, la variation de la consommation d'énergie

est influencée par différents paramètres à savoir, le chargement et le gradient de température entre l'intérieur et l'extérieur de la chambre froide. Dans certaines conditions, l'application de l'effacement peut amener à des réductions de consommation énergétique. Néanmoins, de futures campagnes de mesure sont nécessaires pour affiner ces résultats.

La suite de cette thèse est focalisée sur les approches de modélisation permettant de prédire le comportement de la chambre froide lors d'un effacement :

Pour la première approche « boîte noire », plusieurs modèles ont été développés (Convolutif, LSTM, LSTM – Convolutif, LSTM – Stacked et LSTM – Bidirectionnel). Un ensemble de séries temporelles de mesure issues de la chambre froide a été collecté afin d'alimenter ces modèles, pour l'apprentissage et la validation du modèle.

Les résultats obtenus sont prometteurs : les modèles *Deep Learning* de type LSTM ont permis de prédire le comportement de la température de l'air et de la puissance du compresseur sur un horizon assez important (jusqu' à 4,9 jours) avec une justesse satisfaisante (avec un critère de performance de prédiction « Fitting » supérieur à 85% en puissance du compresseur et supérieur à 50% en température de l'air). Par ailleurs, ces résultats ont montré l'influence de plusieurs paramètres sur la prédiction des sorties désirées (nature des données utilisées, nombre d'entrées et de sorties des modèles...).

La deuxième approche « boîte blanche » s'appuie sur un modèle physique développé dans le cadre du projet Ademe Flexifroid. Ce modèle permet de calculer les différentes charges thermiques présentes dans un entrepôt frigorifique industriel et une chambre froide de laboratoire. Des données issues de ces deux configurations ont été utilisées afin d'identifier les différents paramètres pour la construction du modèle et sa validation.

Les résultats obtenus avec le simulateur sont en bon accord avec les résultats expérimentaux. En effet, le modèle a prédit de manière satisfaisante le comportement thermique pour les deux systèmes (chambre froide et entrepôt).

Une proposition d'interaction entre les deux approches « boîte noire » et « boîte blanche » a été réalisée. Cette interaction est fondée sur l'utilisation des modèles *Deep Learning* pour la prédiction et l'emploi du simulateur « modèle physique » pour générer les données d'entrées et de sorties.

Les résultats ont montré le potentiel de ce type d'interaction entre les deux approches :

- l'utilisation d'un modèle boîte blanche « validé » peut remplacer des données expérimentales, souvent très coûteuses et difficilement accessibles pour un site industriel. En effet, l'utilisation d'un modèle boîte blanche permet de générer en peu de temps des données sans « bruit » pour alimenter les parties d'apprentissage et de validation des modèles *Deep Learning*, ce qui peut avoir un impact sur la performance d'apprentissage du modèle boîte noire.
- le couplage pourrait être une solution pour se passer de l'utilisation de l'information sur la température expérimentale de soufflage.
- le modèle hybride LSTM-convolutif donne davantage de meilleurs résultats de prédiction. Les écarts de prédiction pourraient venir du modèle utilisé mais aussi du profil des données d'entrées, température extérieure en particulier et d'une possibilité de manque de données.

En perspective de ces travaux réalisés sur plusieurs aspects (expérimental, modélisation boîte noire et boîte blanche et intégration entre les deux méthodes de modélisation), il serait intéressant de les enrichir en intégrant plusieurs démarches scientifiques :

Pour la partie expérimentale qui concerne la chambre froide laboratoire : il serait intéressant de tester plusieurs configurations de chargement. De plus, il faudrait voir l'influence des ouvertures des portes sur le comportement de la chambre froide. L'ajout de capteurs d'humidité pourrait être utile afin d'évaluer l'hygrométrie du milieu où les produits sont conservés et aussi afin de les ajouter comme données d'entrée pour les modèles prédictifs et physiques. Par ailleurs, les techniques de traitement de signaux peuvent être utilisées afin d'apporter davantage de clarifications sur la vitesse d'augmentation de la température de l'air et du produit, la corrélation avec la durée d'effacement et ainsi de mieux caractériser les effacements.

Concernant la modélisation « boîte noire », les premiers résultats obtenus sont également très prometteurs. En effet, malgré une architecture peu optimisée des modèles (un seul réseau par modèle), il a été démontré que les modèles *Deep Learning* sont robustes dans la prédiction du comportement thermique et énergétique lors d'application de l'effacement car les valeurs des critères de performance de prédiction sont satisfaisantes. De ce fait, pour de futurs travaux, il serait intéressant de tester et d'explorer les différentes techniques d'apprentissage par transfert afin d'obtenir un modèle général qui puisse traiter différentes configurations.

Enfin, une autre possibilité est de revoir la problématique du couplage des modèles comme une succession de deux étapes. Tout d'abord, une étape de classification serait nécessaire pour

apprendre au modèle à reconnaître plusieurs « modes » de fonctionnement d'un signal : effacement, régime établi ou dégivrage. Ces trois labels représenteraient les caractéristiques principales des données étudiées. Afin de réaliser cette étape, on peut s'appuyer sur le modèle boîte blanche pour générer une quantité massive et diversifiée de données et de faire le lien entre ces données et leur historique physique. Il serait intéressant de générer une base de données plus importante comprenant d'autres configurations, en particulier celle de l'entrepôt industriel. Par ailleurs, de futurs travaux sur d'autres méthodes de couplage, la boîte grise en particulier, pourront être envisagés.

Annexe

ANNEXE 1 : Modèles auto-régressifs

Modèle ARX (Auto Regressive eXogenous) : est un modèle auto-régressif qui inclut des entrées et un bruit blanc (processus stochastique qui possède la même densité spectrale de puissance à toutes les fréquences). Ce modèle a une structure simple élaborant une fonction auto-régressive. Il est souvent employé dans des études de recherche sur l'identification de systèmes, et est facilement utilisable dans le contrôle des plans des différents schémas HVAC. Pour autant, ce modèle ne peut pas prédire les relations entre les variables avec une grande exactitude. Ceci dit, ce modèle manque de propriétés en ce qui concerne les erreurs. Il est à noter que la majorité des travaux utilisant la structure ARX sont établis avec le système SISO / MISO [81]. Ce modèle est résumé par l'équation suivante :

$$\mathbf{ay}(t) = \mathbf{bu}(t) + \mathbf{e}(t) \quad (1)$$

Le bruit est directement couplé à la dynamique du modèle. Il est performant et pertinent si le ratio signal sur bruit est élevé (Signal to Noise Ratio SNR).

➤ OE (output error model)

$$\mathbf{ay}(t) = \frac{\mathbf{b}}{\mathbf{f}} \mathbf{u}(t) \quad (2)$$

Il permet une modélisation indépendante de la dynamique et du bruit.

Modèle ARMAX (Auto Regressive Moving Average eXogenous) : est un modèle auto-régressif qui présente des processus aléatoires (stochastiques), incluant une fonction de transfert en plus d'un bruit blanc utilisé dans les études hydrologiques. Ce modèle est remarquablement utilisé pour traiter de la performance dynamique des systèmes de conditionnement d'air et montre ainsi qu'il a une meilleure capacité de prévision des performances en utilisant les données du site. Ce modèle est capable de prendre en compte les perturbations du système ainsi que les bruits mesurés. Les paramètres du modèle sont déduits de la base des algorithmes des moindres carrés.

$$\mathbf{ay}(t) = \mathbf{bu}(t) + \mathbf{ce}(t) \quad (3)$$

La dynamique du modèle et le bruit sont couplés, bien qu'ils puissent être différents pour chaque entrée.

La construction des systèmes de commandes est faite par boucle fermée afin d'obtenir un mode de commande plus précis. Le signal de sortie $y(t)$ est retourné au bloc de commande et comparé avec la sortie désirée [81].

ARMAX est supérieur à ARX et OE (ARMAX englobe ARX et OE) car il intègre la série chronologique d'erreurs dans la structure du modèle qui est essentielle pour maîtriser l'erreur dynamique ainsi qu'un meilleur contrôle des performances.

Modèle ARIMA (Auto Regressive Moving Average) : est la généralisation d'ARMAX. Il est appliqué dans certains cas où les données montrent des preuves de non-stationnarité ainsi que dans l'analyse des séries chronologiques. Il est adapté au cas des séries temporelles et dans le cas de prédictions linéaires [120]

Modèle ARMA (Auto Regressive Moving Average) : permet de présenter un grand nombre de processus aléatoires stationnaires.

Il est plus adapté aux travaux numériques et possède d'excellentes qualités prévisionnelles (l'espérance est constante). Cependant, il n'est pas approprié aux boucles fermées des systèmes de contrôle pour cause d'absence des entrées $u(t)$, tel que présenté par l'équation suivante :

$$\mathbf{a}y(t) = \mathbf{c}e(t) \quad (4)$$

ARMA, ARIMA, ARMAX, ARIMAX sont les plus utilisés dans les méthodes des séries chronologiques classiques.

Modèle BJ (BOX-Jenkins Model) : présente des problèmes de robustesse à cause de problèmes de convergence de l'algorithme d'identification lors de l'apprentissage, à la réception de données au fur et à mesure de l'étude. Cela provient probablement des matrices au dénominateur, situation que l'on retrouve uniquement dans le modèle BJ [69].

C'est un modèle très flexible qui permet de paramétrer de manière indépendante la dynamique et le bruit, que ce soit au niveau des entrées ou des sorties.

$$\mathbf{y}(t) = \frac{\mathbf{b}}{\mathbf{f}}\mathbf{u}(t) + \frac{\mathbf{c}}{\mathbf{d}}\mathbf{e}(t) \quad (5)$$

Comme le modèle BJ est pourvu d'une structure complexe, une optimisation numérique plus compliquée est requise [81].


Modèle FIR (Finite Impulse Response) :

$$\mathbf{y}(t) = \frac{b}{a}\mathbf{u}(t) + \frac{1}{a}\mathbf{e}(t) \quad (6)$$

FIR, OE et BJ ne tiennent pas compte des sorties, tandis que AR et ARMA ne tiennent pas compte des entrées dans les équations reliant les entrées et les sorties, ce qui résulte que la construction du système de commande n'est pas construite en boucle fermée.

ANNEXE 2 : Performance de la machine frigorifique de la chambre froide

Relation entre le rendement global de la machine frigorifique de la chambre froide (coefficient de performance COP) et le ratio de pression du compresseur.



Ces valeurs ont été obtenues par mesure dans la chambre froide à 2 températures extérieures : 20 et 30 °C.

Valorisation

- *Article soumis*

Akerma, M., et al., *Experimental characterization of demand response for refrigerated cold room.* International Journal of Refrigeration.

- *Conférences*

Akerma, M., et al., *Demand response in refrigerated warehouse,* International Complex Systems and Logistics, Montreuil, France, avril 2018.

Akerma, M., et al., *Demand response in refrigerated warehouse,* International Smart Cities, Kansas city, USA, Septembre 2018.

Akerma, M., et al., *Application of demand response in cold room: evaluation of deep learning approach for modelling,* Montréal, Canada, août 2019.

Mellouli, N., Akerma, M.,Hoang,H-M., Leducq, D., Delahaye, A., *Deep Learning models in prediction of indoor temperature and energy consumption in the cold room,* 11th International conference on computational collective intelligence (ICCCI'19), Hendaye, France, Septembre 2019.

Mellouli, N., Akerma, M.,Hoang,H-M., Leducq, D., Delahaye, A., *Multivariate Time Series Forecasting with Deep Learning Proceedings in Energy Consumption,* 11th International joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management (KDIR'19), Vienne, Autriche, Septembre 2019.

- **Certificat**

Mellouli, N., Akerma, M.,Hoang,H-M., Leducq, D., Delahaye, A., Meilleur poster à Vienne.

Bibliographie

1. commission, E. *Cadre pour le climat et l'énergie 2030*. Disponible sur: https://ec.europa.eu/clima/policies/strategies/2030_fr, Dernier accès le: 04/17/2019.
2. legifrance. *Décret n° 2016-1442 du 27 octobre 2016 relatif à la programmation pluriannuelle de l'énergie*. le service public de la diffusion du droit, 2016; Disponible sur: <https://www.legifrance.gouv.fr/affichTexte.do?cidTexte=JORFTEXT000033312688&categorieLien=id>, Dernier accès le: 01/08/2020.
3. UFE. *Demand response, A promising Segment for the Flexibility of the Electricity System* 2018; Disponible sur: <https://ufe-electricite.fr/en/news/editorials/article/demand-response-a-promising-segment-for-the-flexibility-of-the-electricity>, Dernier accès le: 07/01/2019.
4. *La production d'électricité et l'effacement de consommation en France* 2014, Ministère de l'écologie et du développement durable et de l'énergie.
5. Coulomb, J.-L.D.D. and Pichard, A., *The role of refrigeration in the global economy*, in *29th Informatory Note on Refrigeration Technologies, International Institute of Refrigeration (IIR)*. 2015.
6. Evans, J.A., Foster, A.M., Huet, J.M., Reinholdt, L., Fikiin, K., Zilio, C., Houska, M., Landfeld, A., Bond, C., Scheurs, M., and van Sambeek, T.W.M., *Specific energy consumption values for various refrigerated food cold stores*. *Energy and Buildings*, 2014. **74**: p. 141-151.
7. Altwies, J.E. and Reindl, D.T., *Passive thermal energy storage in refrigerated warehouses*. *International Journal of Refrigeration*, 2002. **25**(1): p. 149-157.
8. Akinyele, D.O. and Rayudu, R.K., *Review of energy storage technologies for sustainable power networks*. *Sustainable Energy Technologies and Assessments*, 2014. **8**(0): p. 74-91.
9. Kalogirou, S.A., *Artificial neural networks in renewable energy systems applications: a review*. *Renewable and Sustainable Energy Reviews*, 2001. **5**(4): p. 373-401.
10. Mohanraj, M., Jayaraj, S., and Muraleedharan, C., *Applications of artificial neural networks for refrigeration, air-conditioning and heat pump systems—A review*. *Renewable and Sustainable Energy Reviews*, 2012. **16**(2): p. 1340-1358.

11. Li, Q., Meng, Q., Cai, J., Yoshino, H., and Mochida, A., *Predicting hourly cooling load in the building: A comparison of support vector machine and different artificial neural networks*. Energy Conversion and Management, 2009. **50**(1): p. 90-96.
12. Xu, C., Chen, H., Wang, J., Guo, Y., and Yuan, Y., *Improving prediction performance for indoor temperature in public buildings based on a novel deep learning method*. Building and Environment, 2019. **148**: p. 128-135.
13. Chen, C., Liu, Y., Kumar, M., Qin, J., and Ren, Y., *Energy consumption modelling using deep learning embedded semi-supervised learning*. Computers & Industrial Engineering, 2019. **135**: p. 757-765.
14. Mustafaraj, G., Lowry, G., and Chen, J., *Prediction of room temperature and relative humidity by autoregressive linear and nonlinear neural network models for an open office*. Energy and Buildings, 2011. **43**(6): p. 1452-1460.
15. Jaber, O., *Chambre froide*. 2013.
16. RTE, *Bilan Electrique*. 2018.
17. Youbi-Idrissi, M. *Les application du froid dans les AII* 2014; Disponible sur: http://www.iifiir.org/clientBookline/service/reference.asp?INSTANCE=E XPLOITATION&OUTPUT=PORTAL&DOCID=IFD_REFDOC_00125_72&DOCBASE=IFD_REFDOC&SETLANGUAGE=FR, Dernier accès le: 11/13/2019.
18. Ombelliscience. *Le développement de l'éolien et du solaire exige de rendre le réseau électrique plus intelligent*. 2018; Disponible sur: <https://www.echosciences-hauts-de-france.fr/articles/smart-grids-transition-energies-renouvelables>, Dernier accès le: 08/19/2019.
19. Kelly, N., Hong, J., Richardson, I., and Thomson, M., *he influence of thermal storage on microgeneration flexibility*, in *Proceedings of the 2nd International Conference in Microgeneration Technologies*. 2011: Glasgow, Scotland.
20. Wyse, B., *Investigation into the Time-Shifting Of Domestic Heat Loads*. Mémoire de master, University of Strathclyde, 2011. **92**.
21. Favre, B. and Peuportier, B., *Etude d'une stratégie d'effacement de la consommation électrique de pointe dans le bâtiment par l'application de la programmation dynamique* in *XXX^e Rencontres AUGC-IBPSA* 2012: Chambéry, Savoie.

22. Berthou, T., Stabat, P., Salvazet, R., and Marchio, D., *Comparaison de modèles linéaires inverses pour la mise en place de stratégies d'effacement*, in *XXXe Rencontres AUGC-IBPSA*. 2012: Chambéry, Savoie.
23. Favre, B., *Étude de stratégies de gestion énergétique des bâtiments par l'application de la programmation dynamique*. 2013, École Nationale Supérieure des Mines de Paris. p. 275.
24. Ruud, M.D., Mitchell, J.W., and Klein, S.A., *Use of Building Thermal Mass to Offset Cooling Loads*. ASHRAE Transactions (American Society of Heating, Refrigerating and Air-Conditioning Engineers), 1990. **96(2)**.
25. Coniff, J.P., *Strategies for reducing peak air conditioning loads by using heat storage in the building structure*. ASHRAE Transactions 97 1991.
26. Morris, F.B., Braun, J.E., and Treado, S.J., *Experimental and simulated performance of optimal control of building thermal storage*. ASHRAE Transactions, 1994.
27. Keeney, K. and Braun., J., *A Simplified Method for Determining Optimal Cooling Control Strategies for Thermal Storage in Building Mass*. HVAC&R Research 2. 1996.
28. Xu, P., Haves, P., and Piette, M.A. *Peak Demand Reduction from PreCooling with Zone Temperature Reset in an Office Building*. 2004; Disponible sur: <https://buildings.lbl.gov/sites/all/files/55800.pdf>, Dernier accès le: 09/07/2019.
29. Sana, H. and Guay, M., *Minmax Dynamic Optimization over a Finite-time Horizon for Building Demand Control*, in *American Control Conference*. 2008: Seattle, WA, USA.
30. IIF. *Institute International du Froid, Le rôle du froid dans l'économie mondiale*. 2015; Disponible sur: http://www.iifiir.org/userfiles/file/publications/notes/NoteTech_29_FR.pdf, Dernier accès le: 10/10/2019.
31. Grein, A. and Pehnt, M., *Load management for refrigeration systems: Potentials and barriers*. Energy Policy, 2011. **39(9)**: p. 5598-5608.
32. S. Mudgal, B. Tinetti, J. Bain, R. Cervantes, and A. de Prado Trigo, *Preparatory Study For Eco-design Requirements for EuPs Lot 1. Task 2: Economic and Market Analysis*. 2011.

33. Godefroy, A., Perier-Muzet, M., and Mazet, N., *Thermodynamic analyses on hybrid sorption cycles for low-grade heat storage and cogeneration of power and refrigeration*. Applied Energy, 2019. **255**: p. 113751.
34. Koca, R.W. and Hellickson, M.L., *Energy saving in evaporator fan-cycled apple storages*. Applied engineering in Agriculture 1993. **9**: p. 533-560.
35. East, A.R., Smale, N.J., and Trujillo, F.J., *Potential for energy cost savings by utilising alternative temperature control strategies for controlled atmosphere stored apples*. International Journal of Refrigeration, 2013. **36**(3): p. 1109-1117.
36. Ambaw, A., Bessemans, N., Gruyters, W., Gwanpua, S.G., Schenk, A., De Roeck, A., Delele, M.A., Verboven, P., and Nicolai, B.M., *Analysis of the spatiotemporal temperature fluctuations inside an apple cool store in response to energy use concerns*. International Journal of Refrigeration, 2016. **66**: p. 156-168.
37. Brooks, R.W., Green, R.H., Cleland, A.J., and Senior, P., *The potential of refrigerated stored for electricity load managment in 20th International Congress of Refrigeration*. 1999: Sydney. p. 1289-1296
38. Cui, B., Wang, S., and Xue, X., *Effects and Performance of a Demand Response Strategy for Active and Passive Building Cold Storage*. Energy Procedia, 2014. **61**: p. 564-567.
39. Turner, K., *Rebound' effects from increased energy efficiency: a time to pause and reflect*, in *Stirling Economics Discussion Paper 2012-15*. 2012.
40. RTE. *Evaluation des économies d'énergies et des effets de bord associés aux effacements de consommation*. 2015; Disponible sur: http://www.rte-france.com/sites/default/files/rapport_report_complet_vdiff.pdf, Dernier accès le: 06/07/2019.
41. CRE. *La flexibilité de la demande - Smart Grids*. Disponible sur: <http://www.smartgrids-cre.fr/index.php?p=flexibilite-demande-definitions>, Dernier accès le: 06/07/2019.
42. Da Silva, D., *Analyse de la flexibilité des usages électriques résidentiels application aux usages thermiques* 2011.
43. Mustafaraj, G., Chen, J., and Lowry, G., *Development of room temperature and relative humidity linear parametric models for an open office using BMS data*. Energy and Buildings, 2010. **42**(3): p. 348-356.

44. Bertagnolio, s., *Evidence-based model calibration for efficient building energy services* 2012, University of Liège.
45. Nunes, J., Neves, D., Gaspar, P.D., Silva, P.D., and Andrade, L.P., *Predictive tool of energy performance of cold storage in agrifood industries: The Portuguese case study*. Energy Conversion and Management, 2014. **88**(0): p. 758-767.
46. Evans, J.A., Hammond, E.C., Gigieli, A.J., Foster, A.M., Reinholdt, L., Fikiin, K., and Zilio, C., *Assessment of methods to reduce the energy consumption of food cold stores*. Applied Thermal Engineering, 2014. **62**(2): p. 697-705.
47. Vicent, V., Ndoye, F.T., Verboven, P., Nicolai, B.M., and Alvarez, G., *Quality changes kinetics of apple tissue during frozen storage with temperature fluctuations*. International Journal of Refrigeration, 2018. **92**: p. 165-175.
48. Duret, S., Hoang, H.M., Flick, D., and Laguerre, O., *Experimental characterization of airflow, heat and mass transfer in a cold room filled with food products*. International Journal of Refrigeration, 2014. **46**: p. 17-25.
49. Hoang, M.L., Verboven, P., De Baerdemaeker, J., and Nicolai, B.M., *Analysis of the air flow in a cold store by means of computational fluid dynamics*. International Journal of Refrigeration, 2000. **23**(2): p. 127-140.
50. Nahor, H.B., Hoang, M.L., Verboven, P., Baelmans, M., and Nicolai, B.M., *CFD model of the airflow, heat and mass transfer in cool stores*. International Journal of Refrigeration, 2005. **28**(3): p. 368-380.
51. Chourasia, M.K. and Goswami, T.K., *Steady state CFD modeling of airflow, heat transfer and moisture loss in a commercial potato cold store*. International Journal of Refrigeration, 2007. **30**(4): p. 672-689.
52. Xie, J., Qu, X.-H., Shi, J.-Y., and Sun, D.-W., *Effects of design parameters on flow and temperature fields of a cold store by CFD simulation*. Journal of Food Engineering, 2006. **77**(2): p. 355-363.
53. Ho, S.H., Rosario, L., and Rahman, M.M., *Numerical simulation of temperature and velocity in a refrigerated warehouse*. International Journal of Refrigeration, 2010. **33**(5): p. 1015-1025.
54. Jose, d.C.S., Barbara, J.T.M., and Luiz, A.R., *Simulation of air flow in cold chambers using the openfoam computational fluid dynamics (CFD) software*. African Journal of Agricultural Research, 2014. **9**(1): p. 1-7.

55. Wang, H. and Touber, S., *Distributed dynamic modelling of a refrigerated room*. International journal of refrigeration, 1990. **13**(4): p. 214-222.
56. Laguerre, O., Duret, S., Hoang, H.M., Guillier, L., and Flick, D., *Simplified heat transfer modeling in a cold room filled with food products*. Journal of Food Engineering, 2015. **149**(0): p. 78-86.
57. Ben-Nakhi, A.E. and Mahmoud, M.A., *Cooling load prediction for buildings using general regression neural networks*. Energy Conversion and Management, 2004. **45**(13-14): p. 2127-2141.
58. Rabl, A., *Parameter Estimation in Buildings: Methods for Dynamic Analysis of Measured Energy use*. Journal of Solar Energy Engineering, 1988. **vol.110**: p. 52-66.
59. Li, Q., Meng, Q., Cai, J., Yoshino, H., and Mochida, A., *Applying support vector machine to predict hourly cooling load in the building*. Applied Energy, 2009. **86**(10): p. 2249-2256.
60. Evans, J., *Improving Cold storage Equipment in Europe ICE-E*. 2013: London South Bank University, Churchill Building, Langford, Bristol, BS4 5DU, United Kingdom.
61. Leducq, D., Guilpart, J., and Trystram, G., *Low order dynamic model of a vapor compression cycle for processes control design*. Journal of Food Process Engineering, 2003. **26**: p. 67-91.
62. Leducq, D., Guilpart, J., and Trystram, G., *Non-linear predictive control of a vapour compression cycle*. International Journal of Refrigeration, 2006. **29**(5): p. 761-772.
63. Glavan, M., Gradišar, D., Invitto, S., Humar, I., Juričić, Đ., Pianese, C., and Vrančić, D., *Cost optimisation of supermarket refrigeration system with hybrid model*. Applied Thermal Engineering, 2016. **103**: p. 56-66.
64. Li, B. and Alleyne, A.G., *A dynamic model of a vapor compression cycle with shut-down and start-up operations*. International Journal of Refrigeration, 2010. **33**(3): p. 538-552.
65. Cecchinato, L., Corradi, M., and Minetto, S., *Energy performance of supermarket refrigeration and air conditioning integrated systems*. Applied Thermal Engineering, 2010. **30**(14): p. 1946-1958.
66. Gouda, M.M., Danaher, S., and Underwood, C.P., *Building thermal model reduction using nonlinear constrained optimization*. Building and Environment, 2002. **37**(12): p. 1255-1265.

67. Yiu, J.C.-M. and Wang, S., *Multiple ARMAX modeling scheme for forecasting air conditioning system performance*. Energy Conversion and Management, 2007. **48**(8): p. 2276-2285.
68. Estrada-Flores, S., Cleland, A.C., and Cleland, D.J., *Prediction of the dynamic thermal behaviour of walls for refrigerated rooms using lumped and distributed parameter models*. International Journal of Refrigeration, 2001. **24**(3): p. 272-284.
69. Berthou, T., *Développement de modèles de bâtiment pour la prévision de charge de climatisation et l'élaboration de stratégies d'optimisation énergétique et d'effacement*, in *École doctorale n° 432-SMI : Science des Métiers de l'Ingénieur*. 2013, Ecole nationale supérieure des mines de Paris p. 228.
70. Akerma, M., H. M. Hoang, D. Leducq, P. Clain, and Delahaye, A., *Demand response in refrigerated warehouse*, in *4thIEEE International Smart Cities Conference*. 2018: Kansas City, USA
71. Cui, B., Wang, S., Yan, C., and Xue, X., *Evaluation of a fast power demand response strategy using active and passive building cold storages for smart grid applications*. Energy Conversion and Management, 2015. **102**: p. 227-238.
72. Chollet, F., *Deep Learning with Python* ed. M.A.N.N.I.N. G. 2018. 386.
73. Amasyalia, K. and El-Goharyb, N., *Building Lighting Energy Consumption Prediction*. 2016.
74. Benabderrahmane, S., Mellouli, N., Lamolle, M., and Paroubek, P., *Smart4Job: A Big Data Framework for Intelligent Job Offers Broadcasting Using Time Series Forecasting and Semantic Classification*. Big Data Research, 2017. **7**: p. 16-30.
75. Hagan, M. and Behr, S.M., *The Time Series Approach to Short-Term Load Forecasting*. 1987.
76. N.Amjady, *Short-term hourly load forecasting using time series modeling with peak load estimation capability*, in *IEEE Transactions on Power Systems*. 2001.
77. Taylor, J.W., de Menezes, L.M., and McSharry, P.E., *A comparison of univariate methods for forecasting electricity demand up to a day ahead*. International Journal of Forecasting, 2006. **22**(1): p. 1-16.

78. Aman, S., Frincu, M., Chelms, C., Noor, M., Simmhan, Y., and Prasanna, K.V., *Prediction Models for Dynamic Demand Response*, in *2015 IEEE International Conference on Smart Grid Communications (SmartGridComm)*. 2015.
79. Ali, T.B. and Dechemi, N., *Modélisation pluie-débit journalière par des modèles conceptuels et à boîte noire; test d'un modèle neuroflou / Daily rainfall-runoff modelling using conceptual and black box models; testing a neuro-fuzzy model*. *Hydrological Sciences Journal*, 2004. **49**(5).
80. Matthieu Lemoine, F.P., *introduction aux modèles espace état et au filtre de Kalman* hal-sciencespo.archives-ouvertes, 2014.
81. Yin Chi-Man, J., *Statistical Modelling and Forcastion Schemes For Air-conditioning System* 2008.
82. Ríos-Moreno, G.J., Trejo-Perea, M., Castañeda-Miranda, R., Hernández-Guzmán, V.M., and Herrera-Ruiz, G., *Modelling temperature in intelligent buildings by means of autoregressive models*. *Automation in Construction*, 2007. **16**(5): p. 713-722.
83. H.U. Frausto and J.G. Pieters, *Modelling greenhouse temperature using system identification by means of neural networks*. *Neurocomputing*, 2004. **56**: p. 423-428.
84. A. Doncescu. *Les réseaux de neurones artificiels*. 2019; Disponible sur: <https://docplayer.fr/3320253-Artificiels-andrei-doncescu.html>, Dernier accès le: 10/10/2019.
85. Wikipédia. *Fonction d'activation* 2019; Disponible sur: https://fr.wikipedia.org/wiki/Fonction_d%27activation, Dernier accès le: 12/06/2019.
86. Kramer, R., van Schijndel, J., and Schellen, H., *Simplified thermal and hygric building models: A literature review*. *Frontiers of Architectural Research*, 2012. **1**(4): p. 318-325.
87. Cilimkovic, M., *Neural Networks and Back Propagation Algorithm*. Institute of Technology Blanchardstown, Dublin 15, Ireland.
88. S. Karatasou, Santamouris, M., and Geros, V., *Prediction of energy consumption in buildings with artificial intelligent techniques and Chaos time series analysis*, in *International Workshop on Energy Performance and Environmental, Quality of Buildings*. 2006: Milos island, Greece.

89. He, W., *Load Forecasting via Deep Neural Networks*. Procedia Computer Science, 2017. **122**: p. 308-314.
90. Wikipedia. *Réseau neuronal convolutif*. 2019; Disponible sur: https://fr.wikipedia.org/wiki/R%C3%A9seau_neuronal_convolutif,
Dernier accès le: 10/30/2019.
91. S. Hochreiter and Jurgen Schmidhuber, *LONG SHORT-TERM MEMORY*. Neural Computation, 1997. **9(8)**: p. 1735-1780.
92. Sanjeevi, M. *LSTM (Long Short Term Memory) Networks with Math*. 2018; Disponible sur: <https://medium.com/deep-math-machine-learning-ai/chapter-10-1-deeplp-lstm-long-short-term-memory-networks-with-math-21477f8e4235>, Dernier accès le: 10/10/2019.
93. D. L. Marino, K. Amarasinghe, and M.. Manic, *Building energy load forecasting using Deep Neural Networks*, in *IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society*. 2016.
94. Ping-Huan, K. and Chiou-Jye, H., *A High Precision Artificial Neural Networks Model for Short-Term Energy Load Forecasting*, in *energies*. 2018.
95. Hermans, M. and Schrauwen, B., *Training and Analyzing Deep Recurrent Neural Networks*, in *Conference on Neural Information Processing Systems*. 2013.
96. Graves, A., Mohamed, A.-R., and Hinton, G., *Speech Recognition with Deep Recurrent Neural Networks*, in *International Conference on Acoustics, Speech and Signal Processing*. 2013: Canada.
97. U. Singh, S. chauhan, A. Krishnamachari, and L. Vig, *Ensemble of Deep Long Short Term Memory Networks for Labelling Origin of Replication Sequences*. 2015.
98. Sutskever, I., Vinyals, O., and Le, O.V., *Sequence to Sequence Learning with Neural Networks*. 2014.
99. Graves, A., Jaitly, N., and Mohamed, A.-R., *Hybrid speech recognition with Deep Bidirectional LSTM*, in *IEEE Workshop on Automatic Speech Recognition and Understanding*. 2013: Olomouc, Czech Republic.
100. Althelaya, K.A., El -Alfy, E.M., and Mohammed, S., *Evaluation of bidirectional LSTM for short-and long-term stock market prediction*, in *International Conference on Information and Communication Systems (ICICS)*. 2018: Irbid, Jordan.

101. Sgi, X., Chen, Z., Wang, H., and Yeung, D., *Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting*. 2015.
102. Brownlee, J. *CNN Long Short-Term Memory Networks*. 2017; Disponible sur: <https://machinelearningmastery.com/cnn-long-short-term-memory-networks/>, Dernier accès le: 20/10/2019.
103. T-Y. Kim and S-B. Cho, *Predicting the Household Power Consumption Using CNN-LSTM Hybrid Networks*, in *International Conference on Intelligent Data Engineering and Automated Learning*. 2018.
104. Ping-Huan, K. and Chiou-Jye, H., *An Electricity Price Forecasting Model by Hybrid Structured Deep Neural Networks*. 2018.
105. H.U Frausto, J. G. Pieters, and J. M.Deltour, *Modelling Greenhouse Temperature by means of Auto Regressive Models*. Biosystems Engineering, 2003. **84**(2): p. 147-157.
106. Coakley, D., Raftery, P., and Keane, M., *A review of methods to match building energy simulation models to measured data*. Renewable and Sustainable Energy Reviews, 2014. **37**: p. 123-141.
107. ROBILLART, M., *Étude de stratégies de gestion en temps réel pour des bâtiments énergétiquement performants*. 2015.
108. Tian, S., Shao, S., and Liu, B., *Investigation on transient energy consumption of cold storages: Modeling and a case study*. Energy, 2019. **180**: p. 1-9.
109. Mercier, S. and Uysal, I., *Neural network models for predicting perishable food temperatures along the supply chain*. Biosystems Engineering, 2018. **171**: p. 91-100.
110. Mokrani, M., Leducq, D., Alvarez, G., Negro, D., and Damas, A., *Developing Cryogenic Energy Storage at Refrigerated Warehouses as an Interactive Hub to Integrate Renewable Energy in Industrial Food Refrigeration and to Enhance Power Grid Sustainability*. 2017.
111. Urquiola, A., Alvarez, G., and Flick, D., *Frost formation modeling during the storage of frozen vegetables exposed to temperature fluctuations*. Journal of Food Engineering, 2017. **214**: p. 16-28.
112. ASHRAE, *2010 ASHRAE HANDBOOK*, ed. S. Edition. Vol. Refrigeration 2010.

113. Akerma, M., *Modélisation et transfert de chaleur et de matière au sein d'un milieu poreux congelé et formation de givre dans un entrepot frigorifique* 2016.
114. Y. Simmhan, S. Aman, A. Kumbhare, R. Liu, S. Stevens, Q. Zhou, and Prasanna, v., *Cloud-based software platform for data-driven smart grid management*. 2013.
115. Simmhan, Y. and Noor, M.U., *Scalable Prediction of Energy Consumption using Incremental Time Series Clustering*, in *IEEE International Conference on Big Data*. 2013.
116. Freire, R.Z., Oliveira, G.H.C., and Mendes, N., *Development of regression equations for predicting energy and hygrothermal performance of buildings*. *Energy and Buildings*, 2008. **40**(5): p. 810-820.
117. Dong, B., Cao, C., and Lee, S.E., *Applying support vector machines to predict building energy consumption in tropical region*. *Energy and Buildings*, 2005. **37**(5): p. 545-553.
118. Edwards, R.E., New, J., and Parker, L.E., *Predicting future hourly residential electrical consumption: A machine learning case study*. *Energy and Buildings*, 2012. **49**: p. 591-603.
119. Legifrance. *Arrêté du 21 décembre 2009 relatif aux règles sanitaires applicables aux activités de commerce de détail, d'entreposage et de transport de produits d'origine animale et denrées alimentaires en contenant*. le service public de la diffusion du droit, 2009; Disponible sur: <https://www.legifrance.gouv.fr/affichTexte.do?cidTexte=JORFTEXT000021573483&categorieLien=id>, Dernier accès le: 07/26/2019.
120. Afram, A. and Janabi-Sharifi, F., *Review of modeling methods for HVAC systems*. *Applied Thermal Engineering*, 2014. **67**(1–2): p. 507-519.

Table des matières

Nomenclature	19
Introduction	25
Chapitre I :Etat de l'art général	31
I.1 Définition et rôle de l'effacement.....	33
I.2 Application de l'effacement dans le secteur du bâtiment.....	34
I.2.1 Application de l'effacement en hiver	34
I.2.2 Application de l'effacement en été.....	36
I.3 Application de l'effacement dans le secteur du froid	37
I.4 Evaluation de l'impact énergétique de l'effacement	40
I.5 Méthodes de modélisation	41
I.5.1 Approche boîte blanche.....	42
I.5.1.1 Comportement thermique des entrepôts frigorifiques et chambres froides	42
I.5.1.2 Système de réfrigération et modélisation des charges de refroidissement..	43
I.5.2 Approche boîte noire	46
I.5.2.1 Séries temporelles	48
I.5.2.2 Modèles linéaires	49
I.5.2.2.1 Modèles d'espace d'état	49
I.5.2.2.2 Modèles autorégressifs	50
I.5.2.3 Modèles non linéaires	51
I.5.2.3.1 Modèle de réseau de neurones convolutif	57

I.5.2.3.2	Modèle de réseau récurrent à mémoire court et long terme (LSTM)	58
I.5.2.3.3	LSTM-Stacked (Enchaîné)	60
I.5.2.3.4	LSTM Bidirectionnel.....	61
I.5.2.3.5	LSTM Convolutif	62
I.5.2.4	Bilan sur les modèles boîte noire	63
I.5.2.5	Interaction des deux approches de modélisation	65
I.6	Conclusion	67
Chapitre II :Etude expérimentale de l’effacement dans une chambre froide et dans un		
entrepôt frigorifique.....		69
II.1	Développement d’un dispositif expérimental – Chambre froide laboratoire	70
II.1.1	Chargement de la chambre	72
II.1.2	Instrumentation.....	73
II.1.3	Protocole expérimental.....	74
II.1.4	Configurations et paramètres étudiés	75
II.1.5	Développement des indicateurs pour caractériser les impacts de l’effacement .	77
II.1.5.1	Impact de l’effacement sur le comportement thermique de l’air et du chargement	78
II.1.5.2	Impact de l’effacement sur les performances de la machine frigorifique...	79
II.1.5.3	Impact de l’effacement sur la consommation du système frigorifique.....	81
II.2	Etude expérimentale dans un entrepôt frigorifique	82
II.2.1	Présentation de l’entrepôt.....	82
II.2.2	Protocole de mesure	83

Chapitre III :Modélisation boîte noire et boîte blanche
..... **85**

III.1 Approche boîte blanche 86

 III.1.1 Pertes par transmission à travers les parois 89

 III.1.2 Infiltration d’air par ouverture des portes 90

 III.1.3 Chargement et déchargement des produits..... 91

 III.1.4 Dégivrage 91

 III.1.5 Eclairage..... 91

 III.1.6 Ventilation..... 91

 III.1.7 Machines diverses 91

 III.1.8 Personnel 92

 III.1.9 Echange de chaleur avec le produit..... 92

 III.1.10 Bilan thermique sur l’air-liste des paramètres 93

III.2 Approche boîte noire..... 95

 III.2.1 Modèles Deep Learning développés et leurs caractéristiques..... 96

 III.2.1.1 Réseau de neurones convolutif (CNN) 97

 III.2.1.2 Réseau récurrent à mémoire court et long terme (LSTM) 99

 III.2.1.3 LSTM–Stacked (Enchaîné)..... 100

 III.2.1.4 LSTM Bidirectionnel 101

 III.2.1.1 LSTM Convolutif..... 102

 III.2.2 Paramétrage des modèles 103

 III.2.3 Séries de données pour l’apprentissage et la validation des modèles 103

III.2.4	Ensemble des variables d'entrée et de sortie.....	106
III.2.5	Analyse de corrélation (étude des indépendances des variables d'entrée et de sortie)	108
III.2.6	Systèmes étudiés	109
III.2.7	Critères pour évaluer les performances des modèles	112
III.3	Interaction entre les deux approches –Boîte noire et Boîte blanche.....	113
III.3.1	Série de données pour l'apprentissage et la validation des modèles.....	114
III.3.2	Variables d'entrées et de sorties.....	115
III.4	Conclusion	116
Chapitre IV :Résultats		
et		
discussion		
.....		117
IV.1	Résultats expérimentaux	118
IV.1.1	Cas chambre froide laboratoire	118
IV.1.1.1	Régime permanent	118
IV.1.1.1.1	Influence des produits	118
IV.1.1.1.2	Influence de la température de consigne.....	120
IV.1.1.1.3	Influence de la température extérieure.....	120
IV.1.1.2	Période d'effacement	121
IV.1.1.2.1	Impact d'un effacement sur le comportement thermique de l'air et des produits	121
IV.1.1.2.1.1	Impact sur la température de l'air.....	121
IV.1.1.2.1.2	Impact sur la température de produit.....	123
IV.1.1.2.1.2.1	Anticipation sur l'effacement	130
IV.1.1.2.2	Impact de l'effacement sur les performances de la machine frigorifique	131

IV.1.1.2.3	Impact de l'effacement sur la consommation du système frigorifique .	135
IV.1.2	Cas d'un entrepôt frigorifique	136
IV.1.2.1	Impact d'un effacement sur la température de l'air	136
IV.1.2.2	Impact de l'effacement sur le produit	137
IV.2	Conclusion sur les résultats expérimentaux	138
IV.3	Approche boîte blanche	139
IV.3.1	Validation du modèle dans le cas de la chambre froide laboratoire.....	139
IV.3.1.1	Validation sur la température de l'air	140
IV.3.1.1.1	Chambre vide	140
IV.3.1.1.1	Chambre chargée.....	141
IV.3.1.1.2	Validation sur le produit	142
IV.3.2	Validation du modèle le cas de l'entrepôt frigorifique	143
IV.3.2.1	Validation sur la température de l'air	143
IV.3.2.2	Validation sur le produit	144
IV.4	Conclusion sur l'approche boîte blanche	144
IV.5	Approche boîte noire.....	145
IV.5.1	Comparaison des performances des modèles développés.....	145
IV.5.1.1	Phase d'apprentissage	145
IV.5.1.2	Phase de validation - Performance des modèles sur un horizon de prédiction	148
IV.5.2	Effet de réduire le nombre des entrées et des sorties sur la prédiction - Effet de moyenner des données d'entrées et de sorties.....	153
IV.5.3	Influence des entrées sur la prédiction	158

IV.5.4	Influence du nombre de données des périodes d'effacement de la partie apprentissage sur la prédiction	162
IV.6	Conclusion sur l'approche boîte noire	166
IV.7	Interaction entre les deux approches de modélisation	167
IV.7.1	Phase d'apprentissage	168
IV.7.2	Prédiction sur la température de l'air	171
IV.7.3	Prédiction sur la puissance	172
IV.8	Conclusion	173
Conclusion et perspectives		175
Annexe		179
	ANNEXE 1 : Modèles auto-régressifs	180
	ANNEXE 2 : Performance de la machine frigorifique de la chambre froide	183
Valorisation		184
Bibliographie		185

Mahdjouba AKERMA

**Impact énergétique de l'effacement dans un entrepôt frigorifique -
Analyse des approches systémiques :
boîte noire / boîte blanche**

Résumé

Les entrepôts frigorifiques et chambres froides forment, de par l'inertie thermique de la masse des produits, une source importante de stockage thermique rapidement accessible et fortement attractive pour répondre aux besoins d'effacement électrique. Cependant, le risque pour le produit lors des fluctuations de température liées aux périodes d'effacement et la crainte d'une surconsommation énergétique, limitent le recours aux effacements par les industriels et acteurs du froid alimentaire. Cette thèse vise à caractériser l'effacement électrique des entrepôts en apportant un éclairage sur le comportement thermique d'un système, en termes de fluctuation de température et de consommation électrique. Une étude expérimentale a été mise en œuvre afin d'étudier plusieurs scénarios d'effacement (durée, fréquence et conditions opératoires) et de développer de nouveaux indicateurs pour caractériser l'impact de l'effacement sur le comportement thermique et énergétique des systèmes frigorifiques. Cette étude a mis en avant, l'importance de l'état de chargement pour limiter la remontée de température de l'air, et réduire l'impact de l'effacement sur les produits entreposés. Par ailleurs, le potentiel d'application de l'effacement dans le cas d'un entrepôt frigorifique ou d'une chambre froide a été évalué, en s'appuyant sur le développement des deux approches de modélisation « boîte noire » (apprentissage automatique par des réseaux de neurones artificiels de type *Deep Learning*) et « boîte blanche » (physique). Une possibilité d'interaction entre ces deux approches a été proposée. Elle est fondée sur l'utilisation des modèles boîte noire pour la prédiction et l'emploi du modèle boîte blanche pour générer les données d'entrée et de sortie.

Mots-clés : Effacement, chambre froide, consommation électrique, indicateur, apprentissage automatique, *Deep Learning*, modèle physique

Abstract

Refrigerated warehouses and cold rooms, mainly used for food conservation, constitute available storage cells; they can be considered as a network of "thermal batteries" ready to be used and one of the best existing solutions to store and delay electricity consumption. However, the risk related to temperature fluctuations of products due to periods of *demand response* - DR* and the risk of energy overconsumption limit the use of this strategy by industrials in food refrigeration. The present PhD thesis aims to characterize the electrical DR of warehouses and cold rooms by examining the thermal behavior of those systems, in terms of temperature fluctuation and electrical consumption. An experimental set-up was developed to study several DR scenarios (duration, frequency and operating conditions) and to propose new indicators to characterize the impact of DR periods on the thermal and energy behavior of refrigeration systems. This study has highlighted the importance of the presence of load to limit the temperature rise and thus to reduce the impact on stored products. The potential for DR application in the case of a cold store and a cold room was assessed, based on the development of two modeling approaches: "black box" (*Machine Learning* by artificial neural networks using *Deep Learning* models) and "white box" (physics). A possibility of interaction between these two approaches has been proposed, based on the use of black box models for prediction and the use of the white box model to generate input and output data.

*Demand response – DR (effacement): periods during which the power consumption of an electric utility customer is modified (mainly by reduction or even stopping) to better match its demand for power with the electricity supply's capacity.

Keywords: *Demand response*, cold room, electrical consumption, indicator, *Machine Learning*, *Deep Learning*, physical modelling