



**HAL**  
open science

## Estimation des proportions variétales de grains de blé par SPIR et imagerie hyperspectrale

Adrien Belny, Martin Ecartot, Timothée Flutre

► **To cite this version:**

Adrien Belny, Martin Ecartot, Timothée Flutre. Estimation des proportions variétales de grains de blé par SPIR et imagerie hyperspectrale. HelioSpir, Jun 2021, Montpellier, France. hal-03317724

**HAL Id: hal-03317724**

**<https://hal.inrae.fr/hal-03317724v1>**

Submitted on 7 Aug 2021

**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.



Distributed under a Creative Commons Attribution - NonCommercial - NoDerivatives 4.0  
International License

# Estimation des proportions variétales de grains de blé par SPIR et imagerie hyper- spectrale

HelioSpir, 29/06/2021


Adrien Belny<sup>1</sup>, Martin Ecartot<sup>2</sup>, Timothée Flutre<sup>1</sup>

1) **GQE**, Université Paris-Saclay - **INRAE** - CNRS - AgroParisTech, Gif-sur-Yvette

2) **AGAP**, Université de Montpellier, CIRAD, **INRAE**, L'institut Agro, Montpellier

The logo for INRAE, featuring the acronym in a bold, teal, sans-serif font.The logo for AgroParisTech, featuring a stylized green 'A' icon followed by the text 'AgroParisTech' in a bold, black, sans-serif font. Below the main text, there is a smaller line of text: 'INSTITUT DES SCIENCES ET INDUSTRIES DU VIVANT ET DE L'ENVIRONNEMENT' and 'PARIS INSTITUTE OF TECHNOLOGY FOR LIFE, FOOD AND ENVIRONMENTAL SCIENCES'.

# Introduction




Source des données : FranceAgriMer - Enquête répartition variétale des céréales /  
Agreste - Statistique agricole annuelle.  
Traitement : R. Perronne  
<http://moulon.inra.fr/optimix/>

- de plus en plus de blé semé en mélange
- intérêt agroécologique
- **problème** : on sait ce que l'on sème, pas ce que l'on récolte !
- problème des **débouchés**
  - problème en **recherche** (sélection sur l'aptitude au mélange)
- enjeu d'estimer les proportions des grains récoltés

# Grains : du champ au spectromètre


- **Projet Perfomix :**
  - **8 variétés** commerciales
  - 2 micro-parcelles par variété
- **Spectres sur grains individuels :**



*Micro-parcelles*, Le Moulon (© J. Enjalbert, 2020)

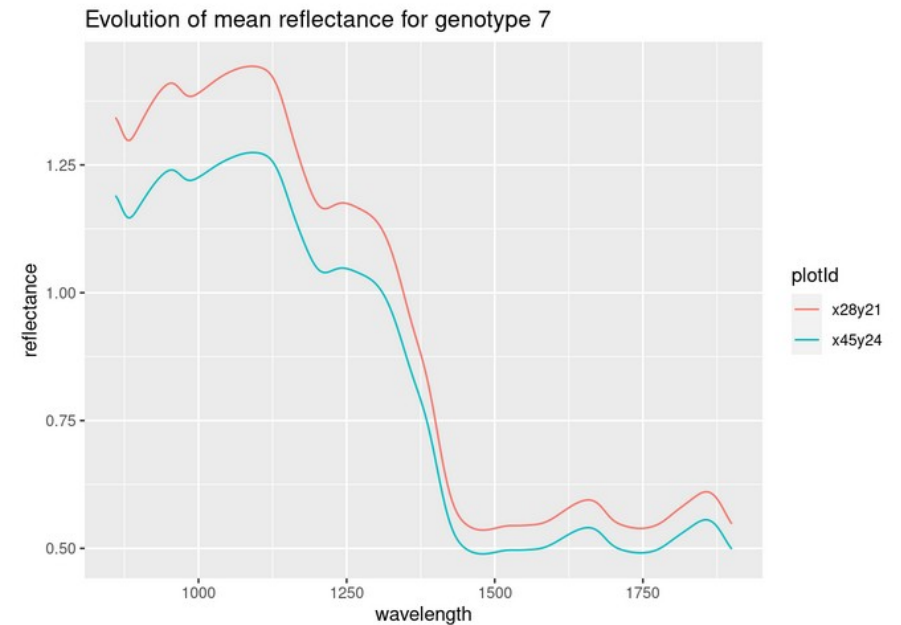
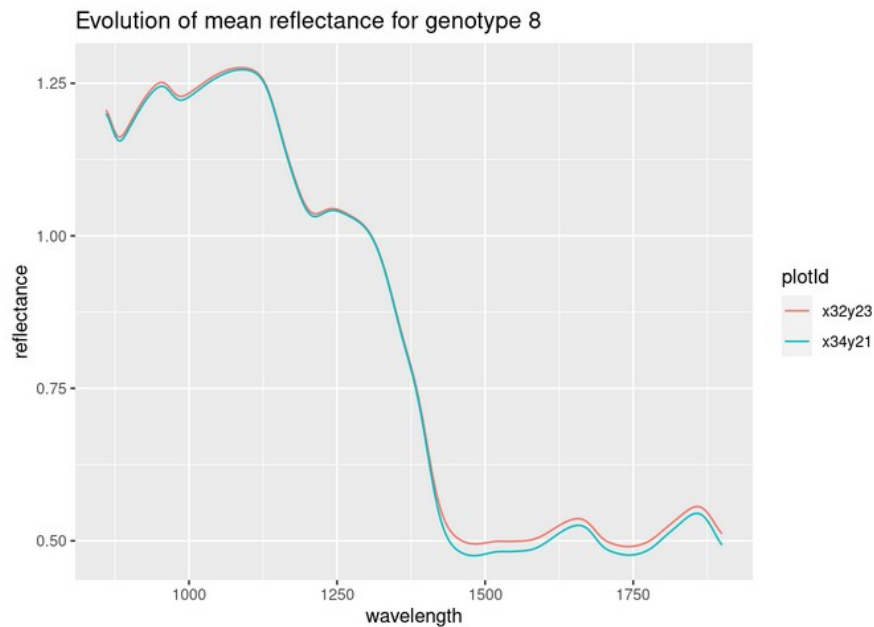


*Imagerie hyper-spectrale (IHS)*  
(400-1000 nm), UMR AGAP (© M. Ecartot, 2021)



*Spectrométrie proche infra-rouge (SPIR)*  
(900-1900 nm), UMR AGAP (© M. Ecartot, 2021)

# Variabilité environnementale (ex. SPIR)



Une ANOVA fonctionnelle a été effectuée sur les grains de 2 génotypes différents, chacun ayant été cultivé sur 2 micro-parcelles différentes

- **sensibilité environnementale au sein d'un même génotype possible**
- **l'ANOVA fonctionnelle révèle aussi qu'il n'y a pas toujours de différence inter génotypes**

# Evaluation des prédictions

Dataset ex : genos 3-7, prop 50-50



Méthode classique de cross-validation

```
$`3`  
[1] "x44y21" "x43y22"
```

```
$`7`  
[1] "x28y21" "x45y24"
```

Fold 1

Fold 2

Méthode de cross-validation par micro-parcelle

## Validation croisée externe :

- 5 folds (tirage aléatoire) → 5 reps
- 2 folds (micro-parcelles) → 4 reps pour faire toutes les combinaisons possibles de plots

## Validation croisée interne :

- **estimation des paramètres** du modèle (nombre de composantes pour la PLS, nombre de voisins du KNN etc), 5 folds dans tous les cas

## Indicateur d'évaluation des prédictions:

- proportions de grains bien classés
- coefficient de Matthews


# Présentation des modèles utilisés

- **PLS (partial least squares)** → `rnirs`
  - PLS-DA avec `dis` (distance)
  - PLS-DA avec `lm` (modèle linéaire)
- **SVM (séparateurs à vaste marge)** → `rnirs` + `kernlab`
  - noyau gaussien
  - noyau polynomial
- **KNN (k plus proches voisins)** → `rnirs`
- **Réseaux de neurones** → `nnet`
  - 1 couche
- **Régression fonctionnelle multinomiale (mflm)** → `glmnet` + `wavethresh`

# Résultats avec SPIR et PLS

Model = plsda1m and valid = microplot

with overall Matthews coef = 0.5 with overall well-classified = 0.75 and nbReps = 4



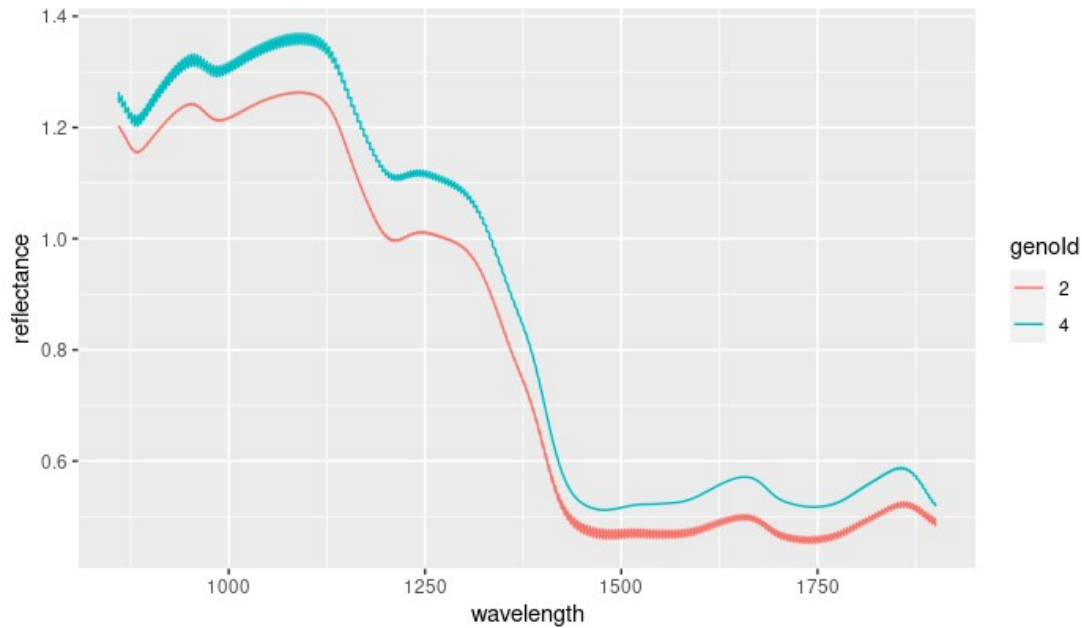
Prédiction des génotypes avec le modèle PLSDALM, coefficient de Matthews général = 0,5, pourcentage général de grains bien classés = 0,75, méthode de validation : microplot

→ PLS-DA 1m : prédictions satisfaisantes mais dégradation des résultats avec +2 variétés mélangées




# Ex. de spectres (2-4 et 3-7)

Evolution of mean reflectance for genotype 2 & 4



Les courbes ne se chevauchent pas → facile de discriminer les génotypes

Evolution of mean reflectance for genotype 3 & 7




Les courbes se chevauchent → difficile de discriminer les génotypes

# Résultats avec IHS et PLS

Model = plsda1m and valid = cv

with overall Matthews coef = 0.94 with overall well-classified = 0.97

index Mcc WellClassif



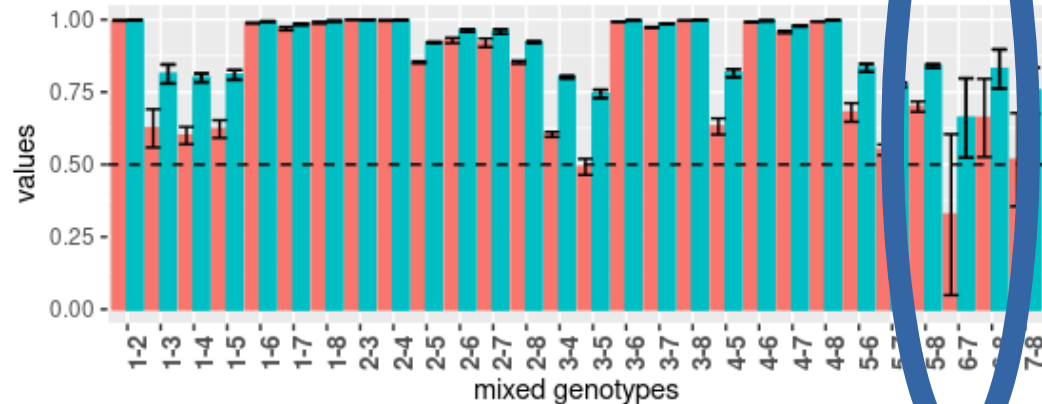
Prédiction des génotypes avec le modèle PLSDALM, coefficient de Matthews général = 0,94, pourcentage général de grains bien classés = 0,97, méthode de validation : cv classique

Tb à part quelques génos (ex 6-7)

Model = plsda1m and valid = microplot

with overall Matthews coef = 0.8 with overall well-classified = 0.9


index Mcc WellClassif



Prédiction des génotypes avec le modèle PLSDALM, coefficient de Matthews général = 0,8, pourcentage général de grains bien classés = 0,9, méthode de validation : microplot

# IHS vs SPIR


well classif NIRS vs well classif HSI for each mix



1 point par rep pour chaque modèle pour chaque mélange (ici CV classique, 2 variétés)

# Comparaison de modèles

(mix de 2 variétés, proportions 50/50)




La hiérarchie des modèles est conservée entre SPIR et IHS.

**KNN**, **réseau de neurones**, **PLS-DA** lm & qda et **SVM** avec noyau polynomial sont des modèles **robustes**.

**Temps de calcul** : les méthodes **PLS** sont les **plus rapides** !

# Estimation des proportions




**Estimation de proportions pour PLS-DA lm, cv classique, SPIR, 5 reps**


$$\hat{p}_i = \frac{\text{nb of grains predicted to be from genotype } i}{\text{total number of grains}}$$

# Proportions non-équiprobables

PLS-DA Im, SPIR, 2 var, cv classique



PLS-DA Im, IHS, 2 var, cv classique



5 reps pour chacune des 28 combinaisons possibles de mélange (5\*28 points)

L'utilisation de l'**IHS** permet de **bonnes estimations**.  
Quand les **proportions** deviennent très **déséquilibrées**, le **biais augmente** !

# Autres résultats et perspectives

- mélanges ternaires (annexe) et quaternaires
- caractéristiques morphologiques (IHS)
- corrélation spatiale avec la teneur en azote des grains (annexe)
- Calcul de l'intervalle de confiance autour de proportions
- prédiction sur des grains issus de parcelles en mélange, et effet de l'année
- Rédaction d'un article pour publication

# Remerciements

- Collègues de GQE : Jérôme Enjalbert, Meije Gawinowski, Gaël Vieceli, Didier Tropée, Tatiana Randrianarisoa, A. Hospital et M. Colas
- Collègues d'AGAP : Frédéric Compan
- Financement : INRAE (projet PerfoMix)



# Merci de votre attention !

**Je recherche actuellement une thèse/un emploi  
autour de la SPIR et de la génétique quantitative**

[adrien.belny@agroparistech.fr](mailto:adrien.belny@agroparistech.fr)

[adrien.belny@inrae.fr](mailto:adrien.belny@inrae.fr)