

Comparaison de méthodes de Machine Learning pour l'analyse de données spectroscopiques

Jordane Poulain-Lallemand, Sylvie Roussel

Ondalys - 4 rue Georges Besse, 34830 Clapiers, France

Tel : +33 (0)4 67 67 97 87

jlallemand@ondalys.fr - sroussel@ondalys.fr



Comparaison de méthodes de Machine Learning pour l'analyse de données spectroscopiques

Le Machine Learning : Qu'es aquò ??



Jordane Poulain-Lallemand, Sylvie Roussel

Ondalys - 4 rue Georges Besse, 34830 Clapiers, France

Tel : +33 (0)4 67 67 97 87

jlallemand@ondalys.fr - sroussel@ondalys.fr




Introduction – Le « Machine Learning » : Qu'és aquò ?

« Machine learning » : apprentissage automatique par ordinateur, grâce à des algorithmes basés sur l'expérience / les données


- Basées sur des données sans nécessiter une équation théorique prédéterminée
- Pas d'hypothèse forte sur la distribution des variables.

➔ Les méthodes classiques utilisées en chimométrie font partie du « machine learning »




Introduction – Le « Machine Learning » : Qu'és aquò ?

Different Types of Learning



Source :  MathWorks®

Introduction – Le « Machine Learning » : Qu'ès aquò ?




Source :  MathWorks®

Description du cas concret - Proof of Concept (PoC)



Composition chimique de la viande

- > Prédiction les plus précises
- > Prédiction les plus robustes



Source : <http://lib.stat.cmu.edu/datasets/tecator>

Echantillons de viande hachée




- > 172 échantillons d'étalonnage
- > 43 échantillons de validation
- > Composition : humidité, protéines et matières grasses





Spectroscopie proche infrarouge (NIR)

- > FOSS Tecator Infratec Food and Feed Analyzer
- > Mesures en Transmittance
- > Longueurs d'onde : [850-1050nm]



1. Résultats PLS

- Non-linéarité résiduelle bien visible
- Performances insuffisantes



Méthode	SEC	SECV	SEP
1. PLS	2.6	2.8	2.7

Software : PLS_Toolbox



Problématique des relations non-linéaires

Parfois, la relation entre les spectres et la propriété à prédire n'est pas linéaire

- La méthode PLS gère bien de petites non-linéarités, mais elle est insuffisante dans les cas plus complexes
- 2 solutions :
 - (i) Linéariser la relation entre les spectres et le paramètre à prédire
 - Ou
 - (ii) Utiliser des méthodes de Machine Learning capables de modéliser la non-linéarité

Transformation des variables

Une solution simple consiste à transformer les variables

- Transformer y : $\log(y)$, \sqrt{y}
 - ☹ Souvent la transformation inverse fait ressortir les erreurs
- ou
- Transformer X : ajout de carrés, de termes croisés, ...
 - ☹ augmente fortement le nombre de variables
 - ☹ certaines combinaisons ne sont pas prédictives et ajoutent du bruit
- Pour des données spectroscopiques (X) :
 - Faire une ACP et sélectionner k scores
 - Appliquer la transformation sur les scores
 - Sélection de variables les plus prédictives





Il est nécessaire de centrer et réduire les scores, surtout après transformation

2. Résultats PLS avec transformation des variables X

Sur [10 scores ACP + termes au carré + termes croisés] et sélection de 14 variables

- > → La non-linéarité a été prise en compte
- > → Les performances sont très nettement améliorées



Méthode	SEC	SECV	SEP
1. PLS	2.6	2.8	2.7
2. PLS sur X^2	0.7	0.9	0.9

Software : PLS Toolbox



Sommaire



- Introduction – Le « Machine Learning » : Qu'és aquò ?
- Description du cas concret
- Comparaison des résultats
 1. PLS
 2. PLS avec transformation des données
 - 3. Modèle local (LWR)**
 4. Support Vector Machine Regression (SVR)
 5. Artificial Neural Networks (ANN)
 6. Classification and Regression Tree (CART) / Random Forests

3. Modèles locaux

- Les modèles locaux ont plusieurs utilités
 - Regrouper dans une même base des spectres d'échantillons très divers
 - Réaliser des modèles « linéaires par morceaux » en fonction de la gamme du paramètre à prédire
 - ➔ Permet de gérer les non-linéarités
- Il existe divers algorithmes de régression locale (LOCAL, LWR, etc.)
- Principe de la Locally Weigthed Regression (LWR) :
 - 1 modèle différent est établi pour chaque échantillon à prédire
 - Sélection de k échantillons les plus proches spectralement (X) de cet échantillon
 - Possibilité de prendre en compte la distance à y en utilisant itérativement la prédiction
 - Réalisation d'un modèle linéaire (PLS) sur ces k échantillons

3. Modèles locaux : LWR

- > La non-linéarité a été prise en compte
- > Les performances sont proches du modèle PLS sur variables transformées



Méthode	SEC	SECV	SEP
1. PLS	2.6	2.8	2.7
2. PLS sur X^2	0.7	0.9	0.9
3. LWR	0.5	0.9	1.0

Sommaire

- Introduction - Le « Machine Learning » : Qu'és aquò ?
- Description du cas concret
- Comparaison des résultats
 1. PLS
 2. PLS avec transformation des données
 3. Modèle local (LWR)
 - 4. Support Vector Machine Regression (SVR)**
 5. Artificial Neural Networks (ANN)
 6. Classification and Regression Tree (CART) / Random Forests

4. Support Vector Machines Regression (SVR)

Principe des Support Vector Machines (SVM)

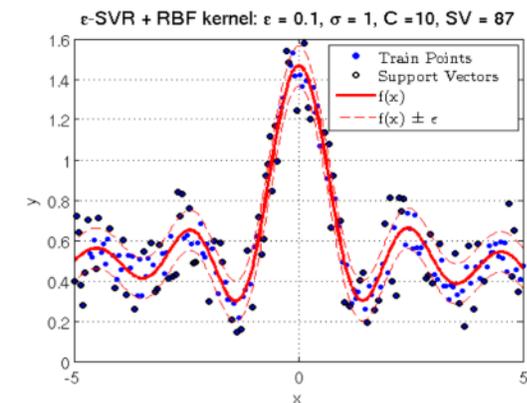
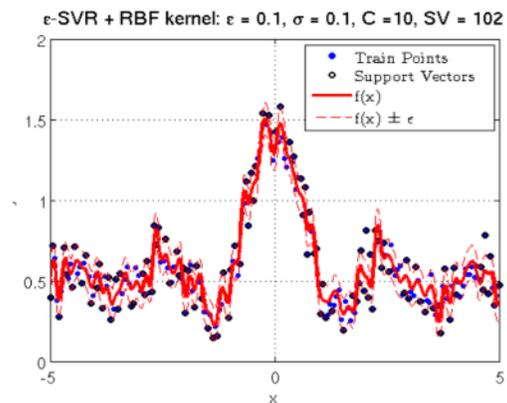
- Méthodes basées sur des frontières (SVM : Séparateurs à Vaste Marge)
- Seuls quelques échantillons participent à la construction du modèle final
= échantillons définissant les frontières = vecteurs supports

Gestion des non-linéarités

- Les non-linéarités peuvent être modélisées grâce une transformation des données via un noyau (kernel) exprimant la similarité entre échantillons
 - Kernel Gaussien : $K(x_i, x_j) = e^{-\gamma \|x_i x_j\|^2}$



Risque de sur-apprentissage : comment l'éviter ?

- Différents paramètres à ajuster : ϵ , σ , γ
- En spectroscopie :
 - **Prétraitements ++** 
 - Compression des données



4. Résultats des SVR

- La non-linéarité a été modélisée
- Les performances sont améliorées par rapport aux modèles précédents



Méthode	SEC	SECV	SEP
1. PLS	2.6	2.8	2.7
2. PLS sur X^2	0.7	0.9	0.9
3. LWR	0.5	0.9	1.0
4. SVR	0.4	0.5	0.5


Sommaire

- Introduction - Le « Machine Learning » : Qu'és aquò ?
- Description du cas concret
- Comparaison des résultats
 1. PLS
 2. PLS avec transformation des données
 3. Modèle local (LWR)
 4. Support Vector Machine Regression (SVR)
 - 5. Artificial Neural Networks (ANN)**
 6. Classification and Regression Tree (CART) / Random Forests

5. Réseaux de Neurones Artificiels (Artificial Neural Networks : ANN)

➔ « Shallow networks » vs « Deep learning »

- Principe du « perceptron multi-couches » (Multilayer Perceptron MLP) :
 - Basé sur la biologie (système nerveux) : réseau de neurones connectés en couches
 - Apprentissage des poids (*weights*) entre les neurones connectés
 - Fonctions d'activation non linéaires pour les neurones de la couche cachée



5. Réseaux de Neurones Artificiels (Artificial Neural Networks : ANN)





Risque important de surapprentissage. Comment l'éviter ?

- Réduire la taille du réseau / le nombre de poids à entraîner
 - Couche d'entrée : compresser les spectres (scores d'ACP ou PLS par ex)
 - 1 seule couche cachée généralement suffisante
- ➔ Principe de parcimonie : plus le réseau est simple, plus il est robuste
- *Stopped-learning* : limiter le nombre d'itérations d'apprentissage grâce à un jeu de validation externe
- Autres techniques : apprentissage par régularisation (*weight decay* – *Bayesian Regularization training* : minimisation de l'erreur et de l'amplitude des poids), élagage de neurones (*pruning*), introduction de bruit, etc

5. Résultats des ANN

Structure du réseau de neurones :

- Inputs : 10 scores d'ACP et 3 neurones dans la couche cachée
- Taille : $(10+1 \text{ biais}) \cdot 3 + (3+1 \text{ biais}) \cdot 1 = 37$ poids à modéliser avec 172 échantillons d'apprentissage
- ➔ 5 échantillons / poids à entrainer. **Attention au surapprentissage !** 
- La non-linéarité est modélisée
- Les performances sont similaires aux SVM



Méthode	SEC	SECV	SEP
1. PLS	2.6	2.8	2.7
2. PLS sur X^2	0.7	0.9	0.9
3. LWR	0.5	0.9	1.0
4. SVR	0.4	0.5	0.5
5. ANN	0.5	0.6	0.4

Copyright Ondalys - Confidentiel


Sommaire

- Introduction - Le « Machine Learning » : Qu'és aquò ?
- Description du cas concret
- Comparaison des résultats
 1. PLS
 2. PLS avec transformation des données
 3. Modèle local (LWR)
 4. Support Vector Machine Regression (SVR)
 5. Artificial Neural Networks (ANN)
 - 6. Classification and Regression Tree (CART) / Random Forests**

6. Classification and Regression Tree (CART) / Random Forests

- Principe de Classification and Regression Tree (CART) :

- Arbre fait de séparations dichotomiques successives des échantillons
 - A chaque nœud, 1 variable (1 longueur d'onde) est choisie pour séparer en 2 les données en fonction d'un seuil
 - ➔ 😊 Méthode simple et modèle interprétable
- Un arbre complet est réalisé = 1 échantillon par feuille
- Elagage des feuilles pour éviter le **fort risque de sur-apprentissage**
- Application de CART : un nouvel échantillon est soumis à l'arbre
 - Valeur prédite = moyenne des échantillons de la feuille terminale
 - ➔ 😞 prédictions en « escalier » = moyenne d'une feuille
 - ➔ 😞 Minoration des prédictions dans les valeurs hautes





- « Ensemble methods » : Forêts aléatoires / *Random Forests*

- Créer plusieurs prédicteurs CART « faibles »
- Les combiner pour augmenter la performance et la robustesse des modèles (moins surappris)

6. Résultat des Random Forests

Sur une sélection de longueurs d'onde

- > La non-linéarité a pu être partiellement modélisée
- > Les performances sont moins élevées que pour les SVM et ANN
- > Elles sont similaires à la transformation des variables et à la méthode locale



Méthode	SEC	SECV	SEP
1. PLS	2.6	2.8	2.7
2. PLS sur X^2	0.7	0.9	0.9
3. LWR	0.5	0.9	1.0
4. SVR	0.4	0.5	0.5
5. ANN	0.5	0.6	0.4
6. RF	0.6	1.1	1.0

Copyright Ondalys - Confidentiel

Take-home message !

Si vous voulez appliquer du ML à la spectroscopie ...

Méthode	Nb LVs	Etalonnage				Validation croisée				Test			
		SEC	SEC (%)	R ²	RPD	SECV	SECV (%)	R ²	RPD	SEP	SEP (%)	R ²	RPD
1. PLS	5	2.6	18.5%	0.958	5	2.8	20.2%	0.950	4	2.7	19.0%	0.958	5
2. PLS sur X transformé	5	0.7	5.3%	0.997	17	0.9	6.2%	0.995	15	0.9	6.6%	0.996	14
3. LWR	3	0.5	3.6%	0.998	25	0.9	6.5%	0.995	14	1.0	6.9%	0.995	13
4. SVR	-	0.4	2.6%	0.999	35	0.5	3.6%	0.998	25	0.5	3.4%	0.999	27
5. ANN	-	0.5	3.9%	0.998	23	0.6	4.5%	0.998	20	0.4	2.7%	0.999	34
6. RF	-	0.6	4.3%	0.998	21	1.1	8.2%	0.992	11	1.0	7.5%	0.994	12

→ En présence de non-linéarités

Méthode	Gestion non-linéarité	Performance	Complexité de mise en œuvre	Risques de sur-apprentissage
1. PLS	-	-	-	-
2. PLS sur X transformé	+	+	-	+
3. LWR	+	+	+	+
4. SVR	++	++	++	++
5. ANN	++	++	+++	+++
6. RF	+	+	+	++

Merci pour votre attention...



WITH  **ondalys**, MAKE SENSE OF YOUR DATA !



FOUNDED IN 2003

- > **French Leaders** in chemometrics
- > Located in Montpellier (34), France



Customers

- > 50% Pharma-biotech
- > 25% Chemistry
- > 15% Food/Agri
- > 10% Optical Equipment



Core business

- > Consulting / R&D
> **200 projects**
- > Training
> **1000 trainees**
- > Software retail
> **4 main chemometrics software**



Chemometrics - Machine learning

- > Data mining
- > Spectroscopic calibrations
- > Model robustness
- > Sensor fusion
- > Process monitoring (MSPC, BSPC)
- > Design of Experiments (DoE / QbD)



Multidisciplinary Team

- > Diverse application Backgrounds
- > Instrumentation / Data
- > Machine Learning



Software partners

