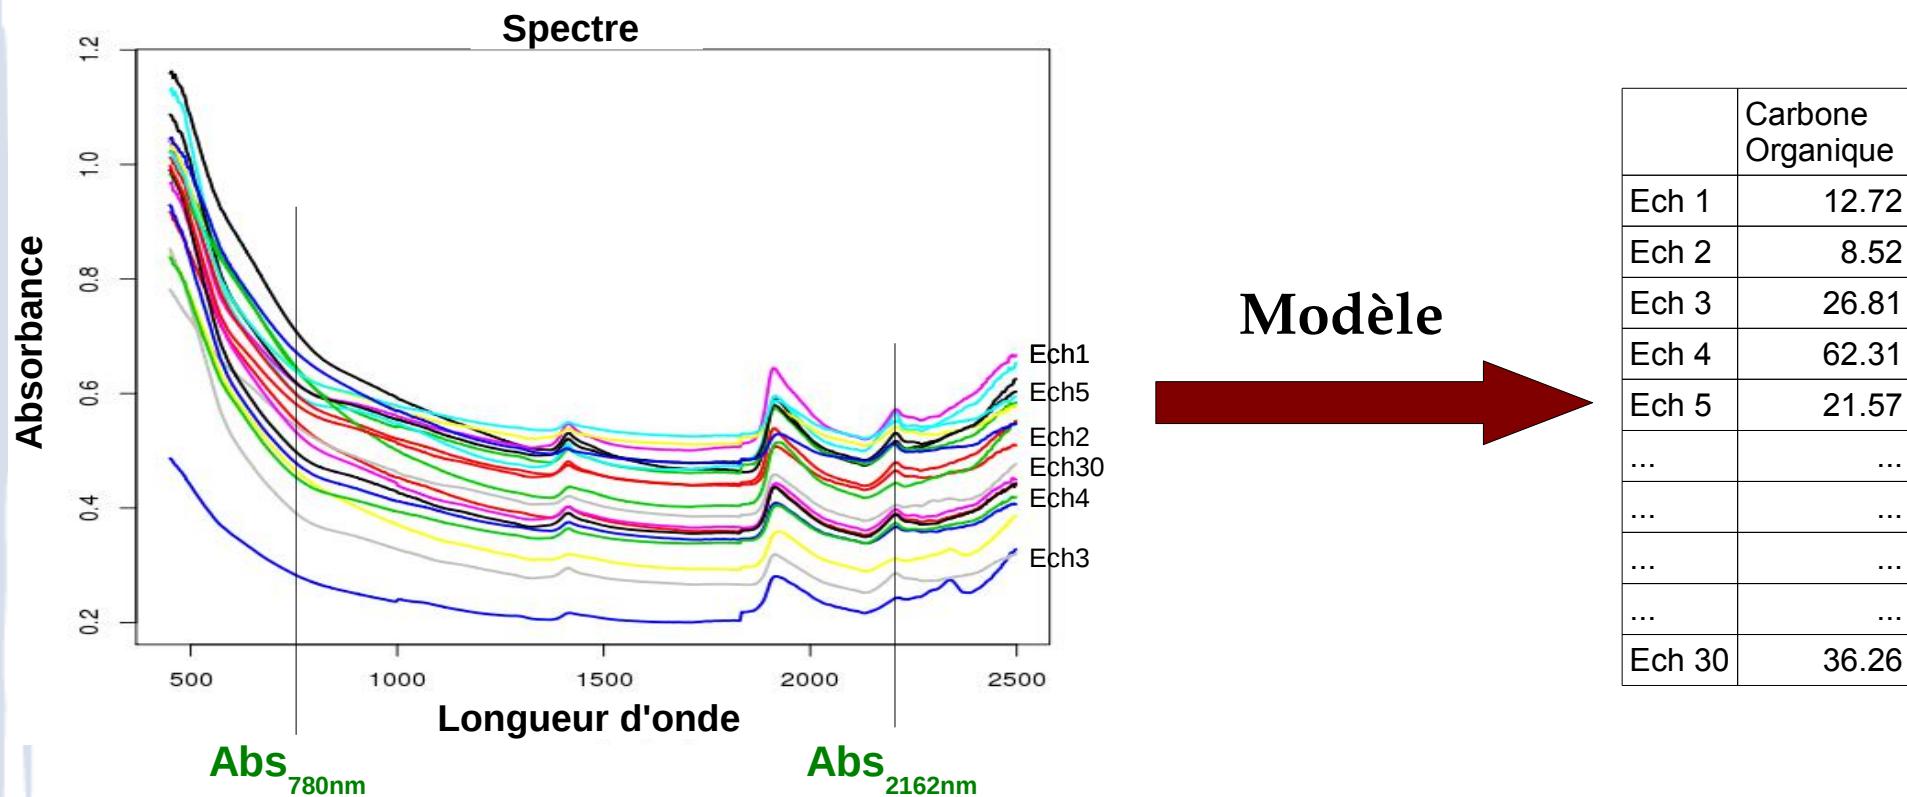


# Locally-Weighted Partial Least Squares Regression for Infra-red spectra analysis

- Spectrométrie infrarouge : intérêt en sciences du sol
  - Spectre IR: mesure rapide et peu couteuse
  - Mesure de référence lente et couteuse



# Spectrométrie Infra-rouge

- Objectif
  - Exprimer un constituant du sol en fonction de l'absorbance de l'échantillon de sol à chaque longueur d'onde

	Abs 1100 nm	Abs 1102 nm	Abs 1104 nm	Abs 1106 nm	...	Abs 2496 nm	Abs 2498 nm	Corg
Ech 1	0.3034	0.3031	0.3027	0.3024	...	0.3171	0.3174	12.72
Ech2	0.2856	0.2852	0.2848	0.2843	...	0.2941	0.2943	8.52
Ech3	0.3362	0.3358	0.3354	0.3349	...	0.3293	0.3297	26.81
Ech4	0.3375	0.3372	0.3369	0.3366	...	0.3458	0.3462	62.31
Ech5	0.4074	0.4071	0.4068	0.4065	...	0.4053	0.4056	21.57
...	...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...	...
Ech30	0.4878	0.4878	0.4877	0.4877	...	0.5380	0.5382	36.26

$$\text{Carbone organique} = a_{1100} \text{Abs}_{1100\text{nm}} + a_{1102} \text{Abs}_{1102\text{nm}} + \dots + a_{2498} \text{Abs}_{2498\text{nm}} + a_0$$

=> déterminer  $a_{1100}, a_{1102}, \dots, a_{2498}, a_0$

- Outils chimiométriques
  - Régression des moindres carrés partiels (PLS)  
=> Méthode de construction de la matrice de composantes latentes

# Régression PLS - Données spectrales

	Abs 1100 nm	Abs 1102 nm	Abs 1104 nm	Abs 1106 nm	...	Abs 2496 nm	Abs 2498 nm	Corg
MPL1	0.3034	0.3031	0.3027	0.3024	...	0.3171	0.3174	12.72
MPL2	0.2856	0.2852	0.2848	0.2843	...	0.2941	0.2943	8.52
MPL3	0.3362	0.3358	0.3354	0.3349	...	0.3293	0.3297	26.81
MPL4	0.3375	0.3372	0.3369	0.3366	...	0.3458	0.3462	17.21
MPL5	0.4074	0.4071	0.4068	0.4065	...	0.4053	0.4056	31.65
MPL6	0.3334	0.3330	0.3325	0.3321	...	0.3271	0.3275	21.57
...	...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...	...
MPL94	0.4878	0.4878	0.4877	0.4877	...	0.5380	0.5382	46.81
MPL95	0.3215	0.3211	0.3207	0.3204	...	0.3248	0.3252	17.26
MPL96	0.3866	0.3863	0.3860	0.3857	...	0.3835	0.3838	11.21
MPL97	0.3076	0.3073	0.3070	0.3067	...	0.3264	0.3269	10.86
MPL98	0.2839	0.2834	0.2830	0.2826	...	0.2986	0.2986	15.23
MPL99	0.3393	0.3394	0.3394	0.3395	...	0.3681	0.3685	84.46
MPL100	0.3540	0.3537	0.3534	0.3530	...	0.3870	0.3874	62.31

Echantillons de calibration

MODELE PLS

Corg

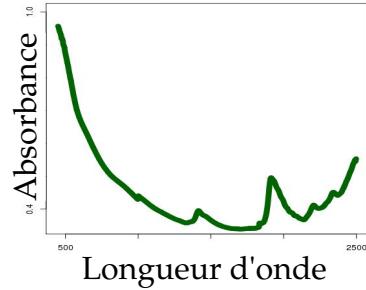
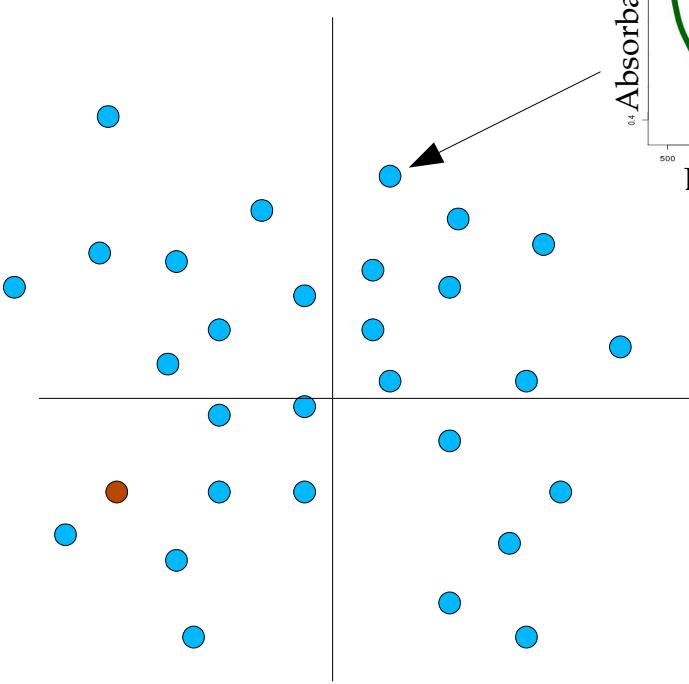
?

	Abs 1100 nm	Abs 1102 nm	Abs 1104 nm	Abs 1106 nm	...	Abs 2494 nm	Abs 2496 nm	Abs 2498 nm
ech1	0.3034	0.3031	0.3027	0.3024	...	0.3168	0.3171	0.3174
ech2	0.3362	0.3358	0.3354	0.3349	...	0.3289	0.3293	0.3297
ech3	0.3375	0.3372	0.3369	0.3366	...	0.3455	0.3458	0.3462
ech4	0.4074	0.4071	0.4068	0.4065	...	0.4049	0.4053	0.4056
ech5	0.3334	0.3330	0.3325	0.3321	...	0.3268	0.3271	0.3275
...	...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...	...
ech100	0.3540	0.3537	0.3534	0.3530	...	0.3866	0.3870	0.3874

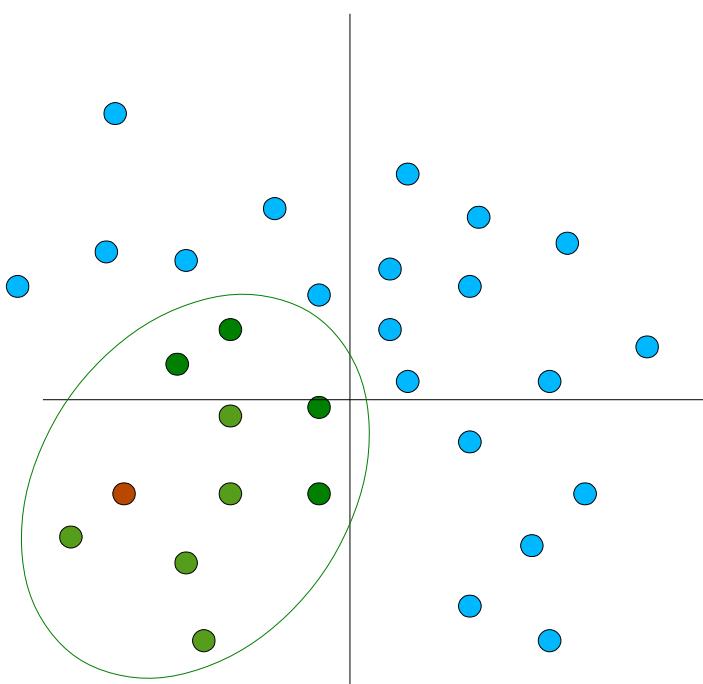
Echantillons à prédire

# Régression PLS

**GLOBAL**



**LOCAL**

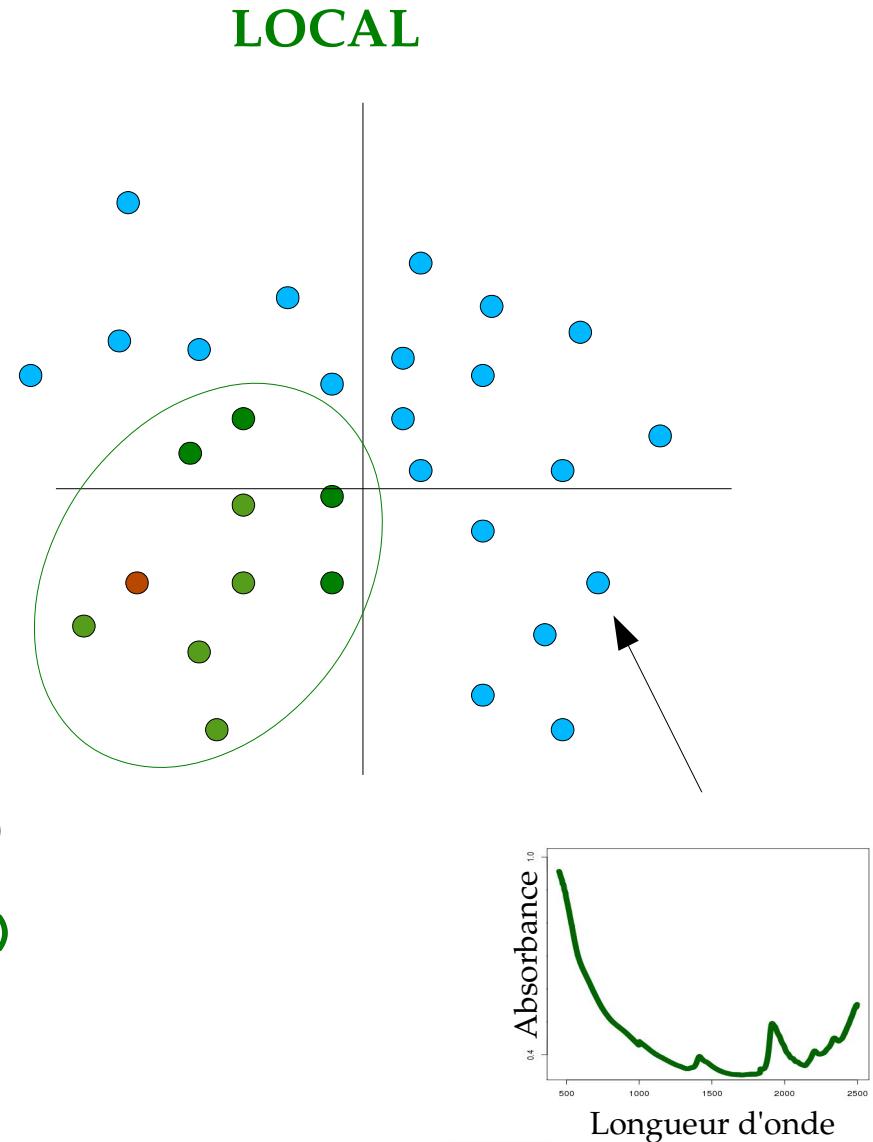


Tous les échantillons de calibration sont utilisés

Sélection des échantillons de calibration sur la base de la ressemblance spectrale

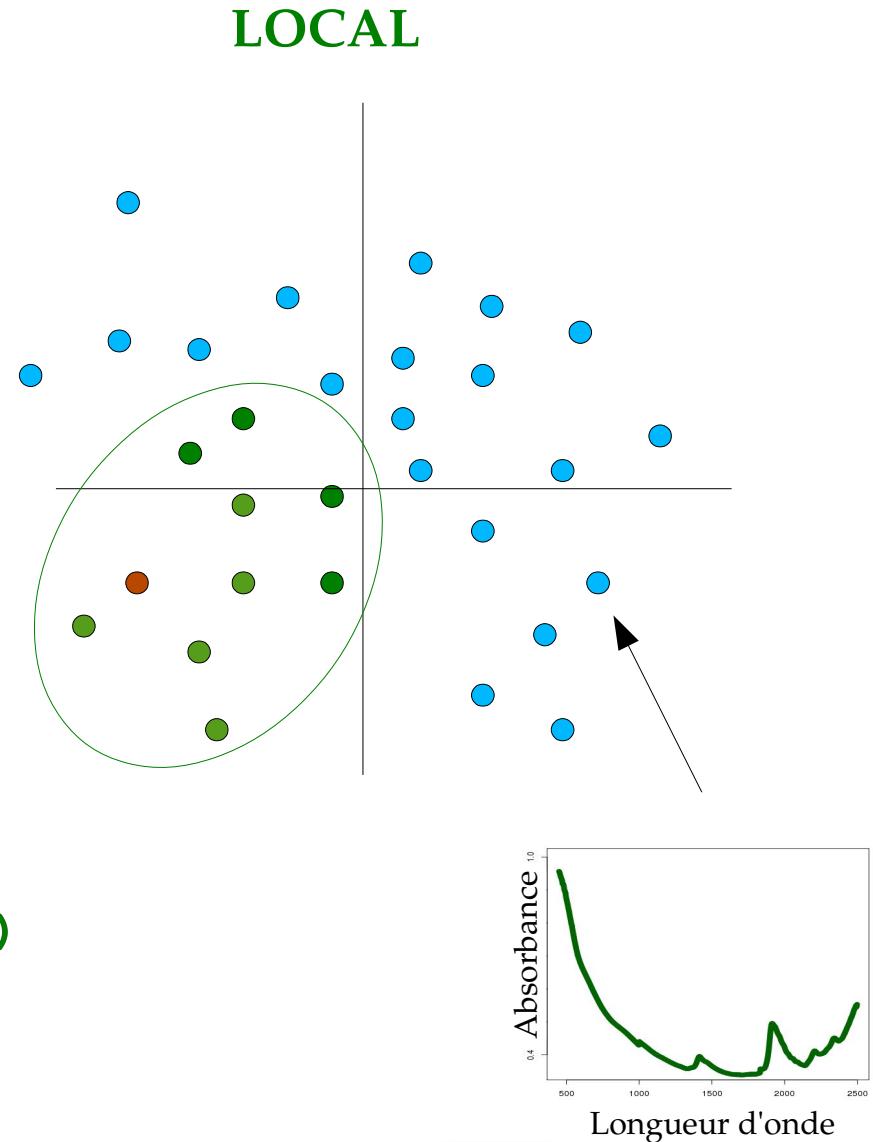
# Construction du modèle : calibration locale

- Calibration locale
  - Distance – `localCal( )`
    - $R^2$  ou  $H$
    - Distance limite `dlim` ou nombre de voisins `Nb.neigh`
    - Nombre minimum de voisins `Nmin`
  - Cluster : Méthode bayesienne – `DPcal( )`
    - Clustering basé sur Dirichlet Process - `DP( )`
    - Voisins = cluster



# Construction du modèle : calibration locale

- Calibration locale
  - Distance – `localCal( )`
    - $R^2$  ou  $H$
    - Distance limite `dlim`  
ou nombre de voisins `Nb.neigh`
    - Nombre minimum de voisins `Nmin`
  - Cluster : Méthode bayesienne – `DPcal( )`
    - Clustering basé sur Dirichlet Process - `DP( )`
    - Voisins = cluster



# PLS locale : Prédictions

- PLS locale - `lwPLS( )`
  - 1 modèle par échantillon  $z$  à prédire
  - Echantillons de calibration  $N_{spec}$  et valeurs de références associées  $N_{refcal}$
  -

PONDÉRATION ?



**NON**

Tous les échantillons de calibration ont le même poids

`method = "LocalPLS"`  
`mvr( )` - package `pls`

**OUI**

Poids lié à la distance à l'échantillon cible  
=> les échantillons les plus proches spectralement ont plus de poids

`method = "LW-PLS"`  
`lm_pls( )` - package `plsRglm`

# PLS locale : Prédictions

- PLS locale - `lwPLS( )`

- 1 modèle par échantillon  $z$  à prédire
- Echantillons de calibration  $N_{spec}$  et valeurs de références associées  $N_{refcal}$
- 

PONDÉRATION ?



**NON**

Tous les échantillons de calibration ont le même poids

`method = "LocalPLS"`  
`mvr( )` - package `pls`

**OUI**

Poids lié à la distance à l'échantillon cible  
=> les échantillons les plus proches spectralement ont plus de poids

`method = "LW-PLS"`  
`lm_pls( )` - package `plsRglm`

- Nombre de composantes PLS à prendre en compte,  $n_{comp}$   
=> Agrégation des prédictions,  $aggreg$

# PLS locale : Agrégation des prédictions

- Agrégation
  - Agrégation des prédictions obtenues avec les modèles à 1, 2, 3,..., k composantes ( $ncomp = k$ )
  - Possibilité d'enlever les 1<sup>ères</sup> composantes ( $kmin$ )
  - Choix de la méthode d'agrégation
    - Moindres erreurs quadratiques ("RMS")  
(Shenk et al., 1997)
    - Méthode à poids exponentiels ("MSE")  
(Rigollet and Tsybakov. *Sparse estimation by exponential weighting. arXiv:1108.5116*)

Shenk, Berzaghi and Westerhaus (1997) *Investigation of a LOCAL calibration procedure for near infrared instruments. J. Near Infrared Spectrosc. 5:223-232*

# PLS locale : Agrégation des prédictions

- Agrégation

- Agrégation des prédictions obtenues avec les modèles à 1, 2, 3,..., k composantes ( $n_{comp} = k$ )
- Possibilité d'enlever les 1<sup>ères</sup> composantes ( $k_{min}$ )
- Choix de la méthode d'agrégation
  - Moindres erreurs quadratiques ("RMS")  
(Shenk et al., 1997)
  - Méthode à poids exponentiels ("MSE")  
(Rigollet and Tsybakov. *Sparse estimation by exponential weighting. arXiv:1108.5116*)

Nb.comp	Prediction	Poids
1.comp	26.89	0.0206
2.comp	30.13	0.1183
3.comp	31.05	0.1165
4.comp	27.36	0.1403
5.comp	23.56	0.0903
6.comp	20.67	0.0565
7.comp	24.32	0.0849
8.comp	15.53	0.0539
9.comp	16.17	0.0564
10.comp	18.33	0.0542
11.comp	15.53	0.0509
12.comp	17.13	0.0530
13.comp	14.33	0.0358
14.comp	11.82	0.0356
15.comp	9.54	0.0329

Valeur prédictive =  $\Sigma(\text{prediction} * \text{poids})$

Valeur prédictive = 22.61

# Routine PLS locale

Jeu de données (X)  
valeurs de références associées (y)

Nettoyage : outliers  
spectraux

Séparation  
Calibration/Validation

Set Calibration

Set Validation

PRE-TRAITEMENT (réduction, transformation)

BOUCLE DE PREDICTION

`plotSpec(X)`

`outSpec(X, k=3, n=7)`

`calvalSet(X, y, method = c("KS", "refval"),  
per.n = 0.25)`

`transSpec(X, trans = c("SNV", "deriv1", ...),  
Wmin=450, Wmax=2500, Wstep=4)`

PREDICTIONS

# Routine PLS locale

Set Calibration

Set Validation

PRE-TRAITEMENT (réduction, transformation)

BOUCLE DE PREDICTION

for (i in 1 =nrow(SetVal)) {

*Selection des voisins spectraux*

*PLS Locale*

Non pondérée

ou

Pondérée

}

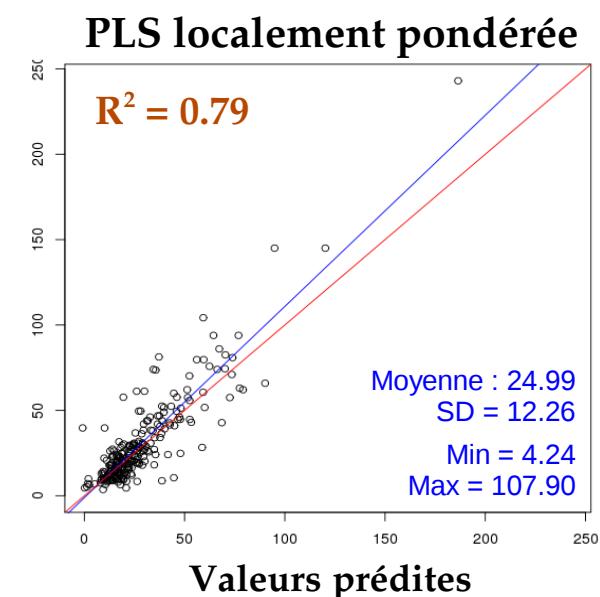
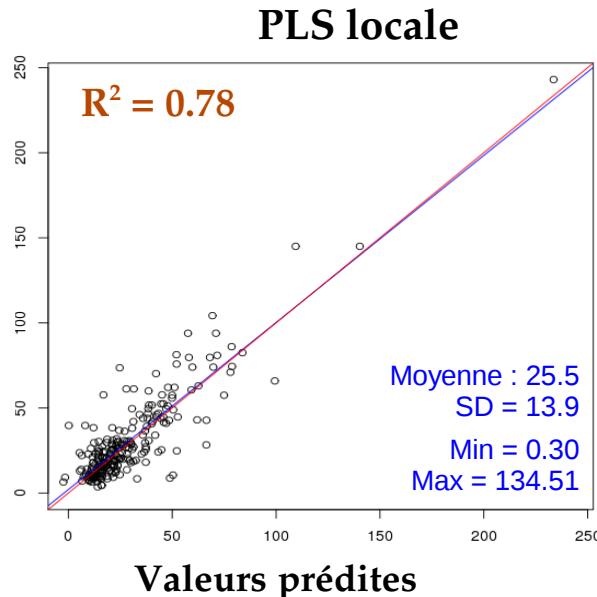
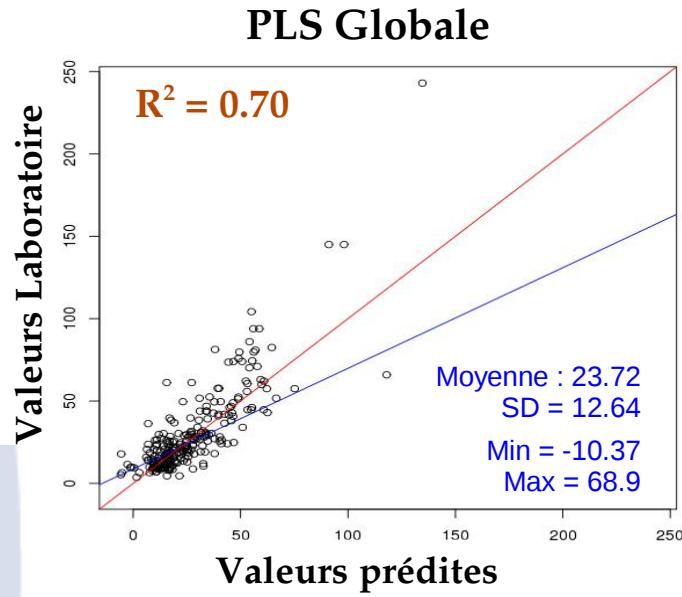
```
transSpec(X, trans = c("SNV", "deriv1", ...),  
          Wmin=450, Wmax=2500, Wstep=4)
```

```
localCal(z, X, Y, method=c("R2", "H"),  
          neigh=80, dlim=0.90, Nmin=50)
```

```
LwPLS (z, X, Y, weight=W, ncomp=20,  
        aggreg = c("RMS", "MSE"),  
        method = "LocalPLS"  
        method = "LW-PLS")
```

PREDICTIONS

# Application à la prédition du Carbone du Sol



Routine PLS disponible :  
[aurelie.thebault@supagro.inra.fr](mailto:aurelie.thebault@supagro.inra.fr)

Remerciements : Programme GESSOL - ADEME  
Bénédicte Fontez, Nicolas Verzelen & Damien Juery – INRA Montpellier