

Apprendre à prédire avec des données

Introduction et exemples

David Makowski

INRA

david.makowski@inra.fr

- Principes généraux et exemples
- Zoom 1: Random forest et gradient boosting
- Zoom 2: Réseaux de neurones multi-couches et deep learning

Question → Données → Entraînement → Test

Statistical Modeling: The Two Cultures (Breiman, 2001)

$$y = f(x) + e$$

Approche 1 : Trouver le vrai $f(x)$

Approche 2 : Prédire le plus précisément possible y à partir de x

Statistical Modeling: The Two Cultures (Breiman, 2001)

$$y = f(x) + e$$

Approche 1 : Trouver le vrai $f(x)$

Approche 2 : Prédire le plus précisément possible y à partir de x

Statistical Modeling: The Two Cultures (Breiman, 2001)


$$y = f(x) + e$$

Approche 1 : Trouver le vrai $f(x)$

Approche 2 : Prédire le plus précisément possible y à partir de x


- **On compare plusieurs méthodes pour prédire y avec x**
- **La plus précise est choisie (pour un coût d'usage max. donné)**

Quoi de neuf ?




Des méthodes (très) flexibles


Arbre de régression



Forêt aléatoire



Réseau de neurones multicouches




Question → Données → Entraînement → Test

Place centrale des données et de l'évaluation

Question → **Données** → **Entrainement** → **Test**

Jeu de données indépendant

Validation croisée




Ex. 1. Prédiction des rendements

Comparison of regression techniques to predict response of oilseed rape yield to variation in climatic conditions in Denmark

Behzad Sharif^{a,*}, David Makowski^b, Finn Plauborg^a, Jørgen E. Olesen^a

Prediction of oilseed rape yields in Denmark



Sharif et al. (2017)

Prediction of oilseed rape yields in Denmark

$$\begin{aligned}\log(Yield_j) = & b_0 + b_1 \times YEAR_j + \sum_{i=1}^n b_{2i} \times TEMP_{ij} + \sum_{i=1}^n b_{3i} \\ & \times RAD_{ij} + \sum_{i=1}^n b_{4i} \times PREC_{ij} + \sum_{i=1}^n b_{5i} \times TEMP_{ij}^2 + \sum_{i=1}^n b_{6i} \\ & \times RAD_{ij}^2 + \sum_{i=1}^n b_{7i} \times PREC_{ij}^2 + b_8 \times SOIL_j + b_9 \times PreCROP_j \\ & + b_{10} \times Sowing_j + b_{11} \times Sowing_j^2 + \varepsilon_j\end{aligned}$$

Sharif et al. (2017)


Entraînement =
estimation des paramètres et sélection de variables

$$\sum_{i=1}^p \left(y_i - b_0 - \sum_{j=1}^q b_j \cdot x_{ij} \right)^2 + \lambda \sum_{j=1}^q |b_j|$$

Moindres carrés ordinaires


Terme de pénalisation de la
complexité

Prediction of oilseed rape yields in Denmark



Sharif et al. (2017)

Prediction of oilseed rape yields in Denmark




Sharif et al. (2017)

Ex. 2. Méta-modélisation: émissions de NH_3


Meta-modeling methods for estimating ammonia volatilization from nitrogen fertilizer and manure applications


Maharavo Marie Julie Ramanantenasa^{a,b}, Sophie Générmont^{a,*}, Jean-Marc Gilliot^a, Carole Bedos^a, David Makowski^{c,d}



Ramanantenasa et al., 2018


Arbre de régression ajusté sur les simulations de Volt'Air






Prédiction de la « forêt »

Relation entre le méta-modèle et le modèle mécaniste Volt'Air



Avantage du méta-modèle

- Moins de variables d'entrée
- Temps de calcul beaucoup plus faible



De nombreuses sources d'informations

- Données expérimentales
- Simulations
- Enquêtes


De nombreuses sources d'informations

- Données expérimentales
- Simulations
- Enquêtes

Mais aussi

- Mesures chez les agriculteurs
- Données extraites d'articles et de rapports
- Données issues d'avis d'experts
- Données climatiques/satellitaires
- Photos/Images

Ex. 3. Vers du deep learning en agriculture?





Ex. 4. Vers du deep learning en agriculture (bis)?

Deep learning based multi-temporal crop classification[☆]

Liheng Zhong^{a,*}, Lina Hu^b, Hang Zhou^c

Classification from Landsat surface reflectance in Yolo County, California



Une autre façon de résoudre des problèmes : les « data challenges »

www.datascience.net





Prédiction d'intervalles de températures

L'objectif est de prévoir les meilleurs intervalles de températures de la ville de Candelia à partir des données météorologiques sur cette ville des cinq jours précédents. La qualité est mesurée par la longueur moyenne des intervalles. Le livrable est un ensemble d'intervalles.

1 000 €

Ouvrir



Challenge **terminé**



Prévision de consommation d'électricité d'un site tertiaire

Le challenge consiste à proposer un modèle de prévision à moyen terme de la consommation d'électricité d'un site tertiaire d'un industriel, par tranche de 10 minutes.

1 000 €

Ouvrir



Challenge **terminé**

<http://cland.lsce.ipsl.fr/index.php/workshops/forecasting-crop-yields/33-data-challenge-in-french>

Crop Data Challenge 2018 : Prédiction des rendements agricoles

Quels sont les objectifs ?

- Comparer les performances de méthodes statistiques et d'apprentissage automatique pour prédire les rendements agricoles,
- Promouvoir les échanges de connaissances autour des méthodes de prédiction pour l'enseignement et les applications agricoles.

Une procédure simple :

- Choisir un challenge (deux challenges sont proposés, un sur le blé et un sur le maïs),
- Développer votre algorithme de prédiction à partir du jeu de données d'entraînement pour le blé et/ou le maïs,
- Soumettre vos prédictions en ligne pour le jeu de données « test » pour le blé et/ou le maïs avant le 16 novembre 2018.

Règlements :


- « Crop Data Challenge 2018 - Prédiction des rendements du maïs en France ».
- « Crop Data Challenge 2018 - Prédiction des pertes de rendement du blé en France »

Fichiers "entraînement" et "test" [ici](#)

14 participants

- Des méthodes très diversifiées
 - Régression logistique
 - Régressions pénalisées
 - Forêts aléatoires
 - Réseaux de neurones simple et multi-couches
 - Clustering

MAIZE



Benefits of data challenges

- Stimulate the development of shared datasets
- Allow rigorous comparison of methods
- Provide insights on pros and cons of different methods
- Useful to collect innovative ideas from outside
- Can be joined to a training session on machine learning

RMSE

2.949

1.26

0.928

0.851

0.849


0.848

0.8399

Zoom 1: Random forest and gradient boosting


Input: age, gender, occupation, ...

Like the computer game X




<https://xgboost.readthedocs.io/en/latest/tutorials/model.html>

Random forest approach



Gradient boosting approach




Application: prédire le rendement du maïs en France


> head(DATaY)

	Yield	Year	IRR	ETP_1	ETP_2	ETP_3	ETP_4	ETP_5	ETP_6	ETP_7	ETP_8	ETP_9	PR_1	PR_2	PR_3	PR_4
1	-0.3862695	1959	3	0.480319	0.650041	0.952222	1.91736	2.72082	3.49425	4.28025	3.17082	1.75560	4.05646	0.0364394	4.80483	4.92613
2	0.1678717	1960	3	0.291583	0.577265	0.981122	2.12405	3.09640	3.57063	2.51640	2.39365	1.32290	3.49145	4.4775100	4.33698	0.96453
3	-0.2818916	1961	3	0.225639	0.573471	1.416320	1.55965	2.51640	3.24141	3.42725	2.86990	2.10262	3.48751	3.1553100	1.27740	3.88140
4	-0.8353380	1962	3	0.376123	0.402265	0.989877	1.85831	2.02216	3.92564	3.66216	3.68923	1.93872	3.72150	3.4689000	5.05512	3.17776
5	0.7080965	1963	3	0.201415	0.349833	0.920070	1.32144	2.47706	2.42592	3.32625	2.32699	1.29623	2.16936	3.6324400	4.63769	3.69405
6	-1.4500704	1964	3	0.235087	0.444469	0.510438	1.73645	2.41834	3.51096	4.41394	3.01169	1.94824	1.24272	1.5125900	5.31356	2.84759
	PR_5	PR_6	PR_7	PR_8	PR_9	RV_1	RV_2	RV_3	RV_4	RV_5	RV_6	RV_7	RV_8	RV_9	SeqPR_1	
1	1.31709	2.59149	1.116000	2.96198	0.933639	51.0494	103.1240	100.3250	156.393	212.716	239.995	266.448	220.982	150.517	0.341515	
2	1.82152	2.81858	4.092340	5.74437	7.676310	43.6871	72.6408	108.5880	180.077	222.952	234.407	186.702	176.072	123.731	0.416900	
3	1.79057	2.33787	4.041520	2.38588	0.642520	32.9697	73.4175	166.0900	137.571	204.488	225.688	233.286	206.122	156.286	0.627279	
4	3.04124	1.35275	0.676303	1.69645	3.138570	44.6328	73.7346	117.8080	168.202	168.662	277.445	240.403	247.275	158.200	0.510168	
5	2.26305	6.25565	1.989530	7.40782	2.212850	52.4708	75.2086	102.6840	125.133	199.030	180.159	233.137	175.962	121.204	0.468794	
6	2.15236	2.29069	1.000380	2.24094	2.327600	50.7146	72.1086	67.1326	148.749	187.654	231.976	276.754	203.253	153.330	0.196704	
	SeqPR_2	SeqPR_3	SeqPR_4	SeqPR_5	SeqPR_6	SeqPR_7	SeqPR_8	SeqPR_9	Tn_1	Tn_2	Tn_3	Tn_4	Tn_5	Tn_6		
1	0.0015528	0.317672	0.453623	0.292777	0.434420	0.255961	0.366760	0.269565	-1.334640	-1.567460	4.63960	5.51576	9.00653	12.9011		
2	0.4760120	0.477560	0.312319	0.311010	0.363043	0.430575	0.514727	0.571377	-2.365930	0.841286	3.65670	3.87700	9.73954	13.1460		
3	0.4274070	0.137097	0.567391	0.373773	0.510145	0.388850	0.280505	0.135870	-0.388616	2.692020	1.16167	7.85662	7.57757	12.7788		
4	0.3905280	0.458275	0.474638	0.527700	0.167391	0.356942	0.152174	0.286594	0.619777	-2.754220	-1.29949	3.74210	7.24426	10.7943		
5	0.4996120	0.601683	0.401449	0.360449	0.692391	0.422861	0.632188	0.358696	-7.751870	-5.703010	1.60362	5.56457	7.40275	12.5736		
6	0.3092200	0.553647	0.466667	0.441445	0.428623	0.229313	0.470196	0.334783	-3.062120	0.103191	1.75535	5.66051	10.01580	12.9838		
	Tn_7	Tn_8	Tn_9	Tx_1	Tx_2	Tx_3	Tx_4	Tx_5	Tx_6	Tx_7	Tx_8	Tx_9	DPT			
1	15.8822	13.3508	12.60090	4.458120	6.997290	12.34220	14.0660	18.5257	22.3311	26.4056	23.4798	22.0578	AIN			
2	12.1531	12.9508	9.08623	2.900720	8.175610	11.02550	13.2580	20.4857	22.5911	20.8484	21.1559	16.7304	AIN			
3	12.8329	12.2605	13.76390	3.879340	10.042700	12.18090	16.3347	16.2052	21.4233	22.5490	22.4748	24.6548	AIN			
4	12.9149	13.6179	10.29380	5.537650	3.681010	6.58445	12.8914	15.7882	20.8746	23.6048	25.8095	19.7318	AIN			
5	14.8594	12.0416	10.68060	-2.122810	0.232842	9.23221	13.4903	16.2551	20.0708	23.5810	20.3687	18.5353	AIN			
6	14.8936	12.3592	11.56320	0.187899	6.834210	7.26100	14.1535	18.9244	22.2869	26.1986	22.9112	20.6706	AIN			


N=5102

Précision des prédictions en fonction du nombre d'arbres (gradient boosting)











Importances des variables d'entrée (gradient boosting)



Réponses à des variables influentes (gradient boosting)




Méthode	RMSE (CV année par année)
Random Forest	0.71
Gradient boosting	0.70




Intervalles de prédiction (quantile random forest)

95% interval



80% interval



Zoom 2: Réseau de neurones multi-couches

Application : reconnaissance de chiffres

- 60000 images de chiffres disponibles pour l'entraînement
- Entraînement d'un algorithme prédictif
- 10000 images de chiffres disponibles pour le test de l'algorithme entraîné

Lecture des images

```
#Images  
x_train <- mnist$train$x  
#Etiquettes  
y_train <- mnist$train$y
```

Entrainement

```
#Images  
x_test <- mnist$test$x  
x_test_image <- mnist$test$x  
#Etiquettes  
y_test <- mnist$test$y
```

Test

Une image de x_train et son étiquette y_train

```
#Exemple chiffre  
plot(as.raster(x_train[26,,]), max=255)  
y_train[26]
```

```
> y_train[26]  
[1] 2
```



Une autre image de x_train et son étiquette y_train

```
#Exemple chiffre  
plot(as.raster(x_train[62,,]), max=255)  
image(1:28,1:28,NUM)  
y_train[62]
```

```
> y_train[62]  
[1] 4
```



```

> dim(x_train)
[1] 60000 28 28
> x_train[1,,]

```

	[,1]	[,2]	[,3]	[,4]	[,5]	[,6]	[,7]	[,8]	[,9]	[,10]	[,11]	[,12]	[,13]	[,14]	[,15]	[,16]	[,17]
[1,]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
[2,]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
[3,]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
[4,]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
[5,]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
[6,]	0	0	0	0	0	0	0	0	0	0	0	0	3	18	18	18	126
[7,]	0	0	0	0	0	0	0	0	30	36	94	154	170	253	253	253	253
[8,]	0	0	0	0	0	0	0	49	238	253	253	253	253	253	253	253	253
[9,]	0	0	0	0	0	0	0	18	219	253	253	253	253	253	198	182	247
[10,]	0	0	0	0	0	0	0	0	80	156	107	253	253	205	11	0	43
[11,]	0	0	0	0	0	0	0	0	0	14	1	154	253	90	0	0	0
[12,]	0	0	0	0	0	0	0	0	0	0	0	139	253	190	2	0	0
[13,]	0	0	0	0	0	0	0	0	0	0	0	11	190	253	70	0	0
[14,]	0	0	0	0	0	0	0	0	0	0	0	0	35	241	225	160	108
[15,]	0	0	0	0	0	0	0	0	0	0	0	0	0	81	240	253	253
[16,]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	45	186	253
[17,]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	16	93

```
# reshape
x_train <- array_reshape(x_train, c(nrow(x_train), 784))
x_test  <- array_reshape(x_test,  c(nrow(x_test), 784))
# rescale
x_train <- x_train / 255
x_test  <- x_test  / 255

y_train <- to_categorical(y_train, 10)
y_test  <- to_categorical(y_test, 10)
```


```
> dim(x_train)
[1] 60000 784
```


	[,129]	[,130]	[,131]	[,132]	[,133]	[,134]	[,135]	[,136]	[,137]	[,138]	[,139]
[1,]	0.0000000	0.0000000	0.0000000	0.0000000	0	0	0	0	0	0	0
[2,]	0.6235294	0.9921569	0.6235294	0.1960784	0	0	0	0	0	0	0
[3,]	0.0000000	0.0000000	0.0000000	0.0000000	0	0	0	0	0	0	0
[4,]	0.0000000	0.0000000	0.0000000	0.0000000	0	0	0	0	0	0	0
[5,]	0.0000000	0.0000000	0.0000000	0.0000000	0	0	0	0	0	0	0
[6,]	0.0000000	0.0000000	0.0000000	0.0000000	0	0	0	0	0	0	0


```
> dim(y_train)
[1] 60000 10
```

```
> head(y_train)
```

	[,1]	[,2]	[,3]	[,4]	[,5]	[,6]	[,7]	[,8]	[,9]	[,10]
[1,]	0	0	0	0	0	1	0	0	0	0
[2,]	1	0	0	0	0	0	0	0	0	0
[3,]	0	0	0	0	1	0	0	0	0	0
[4,]	0	1	0	0	0	0	0	0	0	0
[5,]	0	0	0	0	0	0	0	0	0	1
[6,]	0	0	1	0	0	0	0	0	0	0








$$f\left(b3 + \sum_{k=1}^{10} w_{k,3} * X_{k,3}\right) * 10$$


$$f\left(b2 + \sum_{j=1}^{256} w_{j,2} * X_{j,2}\right) * 128$$

$$f\left(b1 + \sum_{i=1}^{784} w_{i,1} * X_{i,1}\right) * 256$$

$f = \text{RELU}$



$f=\text{softmax}$



Réseau de neurones multi-couches

```
model <- keras_model_sequential()
model %>%

  layer_dense(units = 256, activation = 'relu',
              input_shape = c(784)) %>%

  layer_dropout(rate = 0.4) %>%

  layer_dense(units = 128, activation = 'relu') %>%

  layer_dropout(rate = 0.3) %>%

  layer_dense(units = 10, activation = 'softmax')

summary(model)
```

```
> summary(model)
```


Layer (type)	Output Shape	Param #
dense_1 (Dense)	(None, 256)	200960
dropout_1 (Dropout)	(None, 256)	0
dense_2 (Dense)	(None, 128)	32896
dropout_2 (Dropout)	(None, 128)	0
dense_3 (Dense)	(None, 10)	1290


```
Total params: 235,146  
Trainable params: 235,146  
Non-trainable params: 0
```

```
model %>% compile(  
  loss = 'categorical_crossentropy',  
  optimizer = optimizer_rmsprop(),  
  metrics = c('accuracy')  
)
```

```
history <- model %>% fit(  
  x_train, y_train,  
  epochs = 30, batch_size = 128,  
  validation_split = 0.2  
)
```

```
plot(history)
```





```
##Evaluation  
results<- model%>%evaluate(x_test,y_test)  
results
```

```
> results  
$loss  
[1] 0.1017851  
  
$acc  
[1] 0.981
```


```
> Prediction<-model %>% predict_classes(x_test)
> #Exemple
> k<-780
> plot(as.raster(x_test_image[k,,], max=255))
> y_test[k,]
[1] 0 0 0 0 0 1 0 0 0 0
> Prediction[k]
[1] 5
```



Des applications de plus en plus nombreuses en agriculture

Deep learning based multi-temporal crop classification[☆]

Liheng Zhong^{a,*}, Lina Hu^b, Hang Zhou^c



Classification from Landsat surface reflectance

Comparison of several techniques:


- Multi-layer NN
- SVM
- Random forest
- Gradient boosting
- Deep learning

Datasets


- 1 221 396 pixels in the training dataset
- 431 920 pixels in the validation dataset (for the optimization of the hyper parameters)
- 415 251 pixels in the test dataset
- Inputs: Time series of Enhanced Vegetation Index of length 46 in each pixel (computed from Landsat surface reflectance)
- Output: 14 categories of crops

Deep learning based multi-temporal crop classification☆

Liheng Zhong^{a,*}, Lina Hu^b, Hang Zhou^c



Classification from Landsat surface reflectance



Classifier type	Input	Overall accuracy
MLP	Series only	83.81%
Conv1D-based	Series only	85.54%
LSTM-based	Series only	82.41%
XGBoost	Series only	84.12%
	Series + HANTS	84.17%
	Series + TIMESAT	84.09%
RF	Series only	83.38%
	Series + HANTS	83.25%
	Series + TIMESAT	83.26%
SVM	Series only	82.45%
	Series + HANTS	83.09%
	Series + TIMESAT	82.95%

Une démarche collective ... en petits groupes

Question → Données → Entraînement → Test

Porteurs d'enjeux

Experts en analyse de données

Scientifiques biotechniques

Responsables d'expérimentation

Gestionnaires de bases de données

Des défis

- Définir des questions prioritaires
- Capitaliser rapidement des données
- Développer des groupes projets sur des périodes courtes
- Veille méthodologique pour bénéficier des innovations