


Modélisation prédictive avec R dans un contexte de production - De l'extraction au déploiement




R à Québec 2019

Bienvenue

- Mettre nos noms, experiences, etc (pourrait être funny un peu les descriptions)




Objectifs de l'atelier



Informations

- Expliquer le concept du livre (ressource pour eux)
- Lien vers le repo GitHub de set up



Une première fois !

- Grande première planétaire




- On est pas orgueilleux! On veut du feedback.
- Disclaimer : Jeu de données simple (mais gros!)
 - Emphase sur le processus



Processus de modélisation

- Parler du concept de back-and-forth
- Pour atelier on va s'en tenir à une ligne toute tracée



BIXI



Problématique


- Pour des raisons inconnues, on nous demande :
 1. Quels utilisateurs sont susceptibles de revenir à la même station?
 2. Quelle sera la durée du trajet d'un utilisateur?





Définition de la tâche

Régression vs Classification


$$y \approx f(x)$$



Étapes à accomplir




Collectons !





Extraction de données

- Lau



Explorons !




Exploration des données



Objectifs

1. S'appropriier le jeu de données;
2. Suggérer des transformations pertinentes pour le prétraitement des données.



Appropriation


Pour chaque variable d'entrée...

1. Observer la distribution;
2. Observer la corrélation avec les autres variables d'entrée;
3. Observer l'effet unidimensionnel sur la variable réponse;
4. Observer les effets multidimensionnels avec les autres variables d'entrée sur la variable réponse.




Transformations

- Exclusion;
- Identité;
- Regroupements;
- Tout autre fonction.





Variables d'entrée

- Numérique;
- Catégorique;
- Temporelle;
- Spatiale.



Récits à implémenter




| | |
|---------------------|-------------------------|
| Nom du récit | Variables catégoriques |
| ID | 1 |
| Section | Exploration des données |

| Description |
|---|
| <p>Créer des visuels pour comprendre les distributions des variables d'entrée</p> <p><u>Packages proposés</u></p> <p>Agrégation des données :</p> <ul style="list-style-type: none"> • base • dplyr • data.table <p>Packages proposés pour les graphiques :</p> <ul style="list-style-type: none"> • base • ggplot2 • plotly • lattice |

| Entrée |
|--|
| <ol style="list-style-type: none"> 1. Données brutes 2. Données utilisées pour le prétraitement 3. Données externes |
| Sortie |
| <ol style="list-style-type: none"> 1. Certains des graphiques suivants : <ul style="list-style-type: none"> - Distribution - Corrélations - One-way - Interactions |



Récits à implémenter




| | |
|---------------------|-------------------------|
| Nom du récit | Variables temporelles |
| ID | 2 |
| Section | Exploration des données |

| Description |
|--|
| Créer des visuels pour comprendre les distributions des variables d'entrée |

| Entrée |
|--|
| <ol style="list-style-type: none"> 1. Données brutes 2. Données utilisées pour le prétraitement 3. Données externes |
| Sortie |
| <ol style="list-style-type: none"> 1. Certains des graphiques suivants : <ul style="list-style-type: none"> - Distribution - Corrélations - One-way - Interactions |



Récits à implémenter




| | |
|---------------------|-------------------------|
| Nom du récit | Variables spatiales |
| ID | 3 |
| Section | Exploration des données |

| Description |
|--|
| <p>Créer des visuels pour comprendre les distributions des variables d'entrée</p> <p><u>Packages proposés</u></p> <p>Création de cartes :</p> <ul style="list-style-type: none"> • ggmap • plotly • leaflet • tmap |

| Entrée |
|--|
| <ol style="list-style-type: none"> 1. Données brutes 2. Données utilisées pour le prétraitement 3. Données externes |
| Sortie |
| <ol style="list-style-type: none"> 1. Certains des graphiques suivants : <ul style="list-style-type: none"> - Distribution - Corrélations - One-way - Interactions |



Récits à implémenter




| | |
|---------------------|-------------------------|
| Nom du récit | Transformations |
| ID | 4 |
| Section | Exploration des données |

| |
|--|
| Description |
| Analyser des transformations potentielles suite à l'analyse des variables disponibles dans la collecte des données |

| |
|--|
| Entrée |
| <ol style="list-style-type: none"> 1. Données brutes 2. Données utilisées pour le prétraitement 3. Données externes |
| Sortie |
| <ol style="list-style-type: none"> 1. Certains des graphiques suivants : <ul style="list-style-type: none"> - Distribution - Corrélations - One-way - Interactions |



Récits à implémenter



| | |
|---------------------|-------------------------|
| Nom du récit | Rapport de décision |
| ID | 5 |
| Section | Exploration des données |


| |
|---|
| Description |
| Créer un rapport de décision concernant les transformations suggérées afin que l'étape du prétraitement des données puisse incorporer l'information |

| |
|---|
| Entrée |
| 1. Les graphiques créés depuis le début de la section |
| Sortie |
| 1. Un rapport de recommandations |



Recommandations (1/2)

- Moments de la journée
 - Matin : 6h à 11h
 - Journée : 11h à 16h
 - Soir : 16h à 23h
 - Nuit : 23h à 6h
- Semaine/Fin de semaine
 - Semaine : Lundi, Mardi, Mercredi, Jeudi, Vendredi
 - Fin de semaine : Samedi, Dimanche




Recommandations (2/2)

- Regroupement des quartiers
 - Groupe 1 : Plateau-Mont-Royal
 - Groupe 2 : Ville-Marie
 - Groupe 3 : Ahuntsic-Cartierville, Villeray-Saint-Michel-Parc-Extension, Rosemont-La Petite-Patrie, Mercier-Hochelaga-Maisonneuve
 - Groupe 4 : Outremont, Côte-des-Neiges-Notre-Dame-de-Grâce, Westmount, Le Sud-Ouest, Verdun, LaSalle
 - Groupe 5 : Autre




Données externes à explorer

- Météo
- FSAs au lieu de quartiers
- Réseau de Métro
- Jours fériés
- Dates de festivals




Transformations à explorer



- Meilleur regroupement des moments de la journée
- Distance avec les autres quartiers
- Distance avec le fleuve (\approx distance avec la bordure de la carte des quartiers)




Récits à implémenter



Nettoyons !



Prétraitements de données




+



=




+



Objectifs

2 objectifs derrière le prétraitement de données:


1. Transformer les données dans un format compatible pour l'algorithme
2. Transformer les données de manière à faciliter l'apprentissage




Prétraitements en 3 étapes

1. Nettoyage de données
2. Réduction de données
3. Transformations de données





Séparation




Tout d'abord, il faut séparer notre jeu de données ...

Méthodes:



- Aléatoire
- Échantillonnage stratifié



Vu d'ensemble



Récits à implémenter





| | |
|---------------------|------------------------------|
| Nom du récit | Séparation du jeu de données |
| ID | 1 |
| Section | Prétraitements de données |

| Description |
|---|
| <p>Implémenter une procédure pour séparer les données en 2 ensembles :</p> <ul style="list-style-type: none"> ● Entraînement ● Test <p>Utiliser une séparation aléatoire (voir fonction `sample` de base R)</p> |

| Entrée |
|---|
| <ol style="list-style-type: none"> 1. Données brutes pour l'ensemble du jeu de données |
| Sortie |
| <ol style="list-style-type: none"> 1. Un vecteur d'index pour les observations d'entraînement 2. Sauvegarder les données test |



Récits à implémenter



Nettoyage des données




Imputations de données manquantes

1. Faire le **constat** sur la quantité de données manquante.
2. Identifier le mécanisme de non-réponse
3. Traiter les données manquantes



Constat sur les données manquantes

- Quelles variables ont des données manquantes?
- Quelle est la proportion de données manquantes par variable?



Mécanisme de non-réponse

- Données manquantes complètement au hasard (MCAR)
- Données manquantes au hasard (MAR)
- Données manquantes pas au hasard (NMAR)

Voir la section 5.1.1 du livre pour des exemples.



Faire l'imputation

- Analyse des cas complets: Conserver uniquement les observations pour lesquelles toutes les variables sont présentes.
- Imputation par une mesure de centralité: Utiliser la moyenne, la médiane ou le mode pour remplacer les données manquantes.
- Imputation par régression: Remplacer les données manquantes par la prévision de modèle de régression entraîné sur les observations pour lesquelles cette variable est présente.
- Imputation par régression stochastique: Même chose que la méthode par régression, mais on ajoute un résidu aléatoire à la prévision.





| | |
|---------------------|---------------------------|
| Nom du récit | Implémenter l'imputation |
| ID | 2 |
| Section | Prétraitements de données |

| Description |
|--|
| <p>Implémenter l'imputation de données manquantes. Il faut diviser l'imputation en 2 sections:</p> <ol style="list-style-type: none"> 1. Une qui aura comme but de définir les valeurs d'imputations. 2. Une qui aura comme but d'appliquer ces valeurs aux données manquants. <p>Le 1. sera fait en entraînement seulement. Le 2. sera fait autant en entraînement qu'en inférence.</p> |

| Entrée |
|---|
| <ol style="list-style-type: none"> 1. Données brutes 2. Données brutes + liste de valeurs d'imputations |
| Sortie |
| <ol style="list-style-type: none"> 1. Liste de valeurs d'imputaiton 2. Données imputées |



Récits à implémenter



Traitement des données aberrantes

Pourquoi?: Effets importants dans le calcul des estimateurs

Comment?

- Plus ou moins 3 écarts-types de la moyenne
- Plus ou moins 1.5 EI (écarts interquartile)
- Partitionnement (*clustering*)



Données catégoriques

Identifier le type de données catégoriques:

- Attribut ordinal
- Attribut nominal

Le traitement n'est évidemment pas le même :

- Assigner une valeur numérique
- Encodage *un-chaud* (*one-hot encoding*)



Attribut ordinal

```
##      Id condition_station
## 1:    1          moyen
## 2:    2          mauvais
## 3:    3          excellent
## 4:    4             bon
```

```
##      Id condition_station
## 1:    1             1
## 2:    2             0
## 3:    3             3
## 4:    4             2
```

Super !



Attribut nominal

```
##      Id start_quartier
## 1:   1   Ville-Marie
## 2:   2     Verdun
## 3:   3   Westmount
## 4:   4     LaSalle
```

```
##      Id start_quartier
## 1:   1         1
## 2:   2         2
## 3:   3         3
## 4:   4         4
```

lssh ! ...



Attribut nominal

```
##      Id quartier_centre.ville quartier_plateau.mont.royal quartier_verdun
## 1:   1                        1                        0                0
## 2:   2                        0                        1                0
## 3:   3                        0                        0                1
## 4:   4                        0                        0                0
##      quartier_rosemont
## 1:                0
## 2:                0
## 3:                0
## 4:                1
```

Ahh c'est mieux ...



| | |
|---------------------|-----------------------------------|
| Nom du récit | Traitement des données aberrantes |
| ID | 3 |
| Section | Prétraitements de données |

| Description |
|---|
| <p>Implémenter une opération pour gérer les données abberantes.</p> <p>Choisir une méthode de détection de données aberrantes et appliquer un traitement pour ces données.</p> <p>Appliquer ce traitement dans le prétraitement des données d'entraînement seulement.</p> |

| Entrée |
|---|
| <ol style="list-style-type: none"> 1. Données brutes |
| Sortie |
| <ol style="list-style-type: none"> 1. Données brutes sans les données abberantes 2. "Print" du nombre de données traitées (fins de documentation) |



| | |
|---------------------|-----------------------------------|
| Nom du récit | Encodage des données catégoriques |
| ID | 4 |
| Section | Prétraitements de données |


| Description |
|---|
| <p>Implémenter une opération pour gérer les données catégoriques.</p> <ol style="list-style-type: none"> 1. Identifier les attributs catégoriques et déterminer leur type. 2. Faire l'assignation numérique pour les attributs ordinaux. 3. Lire la documentation de la fonction caret::dummyVars 4. Implémenter l'encodage <i>un-chaud</i> <p>Conseils: Il faut séparer l'encodage un-chaud pour l'entraînement et l'inférence. Prévoir un traitement pour les classes inconnus (défaut).</p> |

| Entrée |
|--|
| <ol style="list-style-type: none"> 1. Données brutes avec des catégories |
| Sortie |
| <ol style="list-style-type: none"> 1. Données sans catégories 2. Objets nécessaire pour faire l'encodage <i>un-chaud</i> |




Récits à implémenter



Séparation des données



Nettoyage des données



Transformation de données





Réduction de données



Fléau de la dimensionnalité

- Survient lorsque le nombre de dimensions est très élevée ($p \gg n$)
- Éloigne les données les unes des autres
- Rend l'apprentissage plus difficile



Fléau de la dimensionnalité

On suppose qu'on a un jeu de données avec $p = 1$ attribut de n observations où $x_1, \dots, x_n \stackrel{iid}{\sim} U(0, 1)$.
Combien d'observations en moyenne se trouveront dans l'intervalle $[0; 0.1]$?

La réponse : $\frac{n}{10}$ observations.


Maintenant, supposons que notre jeu de données est plus complexe et possède $p = 10$ attributs au lieu d'un seul attribut. Les observations suivent toujours une loi uniforme où $x_1, \dots, x_n \stackrel{iid}{\sim} U([0, 1]^{10})$.
Combien d'observations en moyenne se trouveront dans l'intervalle $[0; 0.1]^{10}$?

La réponse : $n\left(\frac{1}{10}\right)^{10}$ observations.





Méthodes de réduction de dimension

- Analyse en composantes principales
- Positionnement multidimensionnel
- Analyse factorielle
- Calcul de scores



ACP






Transformation de données



Normalisation

- Les échelles des attributs peuvent être différents
- Peut avoir un impact important dans certains algorithmes basés sur des distances (*k*-PPV, *clustering*)
- Permet de ramener les données autour d'une distribution plus "standard"



Méthodes de normalisation

- Normalisation centrée réduite
- Normalisation *min-max*
- Normalisation par décimation



Discrétisation et nouveaux attributs

- Communément appelé le *feature engineering*
- Grouper des observations à l'intérieur de *buckets* ou *bins*
- Transformer des attributs existants pour en créer des nouveaux



| | |
|---------------------|--------------------------------|
| Nom du récit | Création de nouveaux attributs |
| ID | 5 |
| Section | Prétraitements de données |


| Description |
|---|
| <p>Implémenter le code qui permet de créer les nouveaux attributs pour le modèle. Utiliser les connaissances acquises lors de l'exploration de données.</p> <p>Créer une liste de variables à conserver dans le modèle.</p> <p>Conseils d'attributs:</p> <ul style="list-style-type: none"> - Grouper des quartiers - Moment de la journée - Fin de semaine versus semaine |

| Entrée |
|--|
| <ol style="list-style-type: none"> 1. Données brutes |
| Sortie |
| <ol style="list-style-type: none"> 1. Données avec nouveaux attributs 2. Liste de variables à conserver dans le modèle lors de l'inférence |



Récits à implémenter


Séparation des données





Nettoyage des données



Transformation de données



Modélisons !



Construction de modèles




Objectifs

1. Objectif de modélisation :

Prédire la réponse y pour de nouvelles données x

2. Objectif global :

Fournir un objet R à utiliser avec `predict`




Modélisation en 3 étapes

1. Choix des modèles (on y a déjà pensé!)
2. Estimation des paramètres
3. Sélection du modèle final

Concepts clefs

entraînement/validation/test fonction de perte régularisation*
hyper-paramètres biais/variance validation croisée ...



Mais avant...

Un peu old school ça...

$$(\mathbf{X}|\mathbf{y}) = \left(\begin{array}{ccc|c} x_{11} & \dots & x_{1d} & y_1 \\ x_{21} & \dots & x_{2d} & y_2 \\ \vdots & & \vdots & \vdots \\ x_{n1} & \dots & x_{nd} & y_n \end{array} \right) \left. \begin{array}{l} \} \\ \} \\ \} \end{array} \right\} \begin{array}{l} \xrightarrow{\approx 1/2} (\mathbf{X}_{\text{train}}|\mathbf{y}_{\text{train}}) \\ \xrightarrow{\approx 1/4} (\mathbf{X}_{\text{val}}|\mathbf{y}_{\text{val}}) \\ \xrightarrow{\approx 1/4} (\mathbf{X}_{\text{test}}|\mathbf{y}_{\text{test}}) \end{array}$$

Optionnel

| Entrée | Sortie |
|--------------|-----------------------------------|
| Données test | Données validation + Données test |




Description d'un modèle

Un peu de statistique...

ε


$$f(x) = \beta_0 + \beta_1 x_1 + \cdots + \beta_d x_d$$



Formulation d'un modèle



Classification...

ε





Choix des modèles

Déployons !




Déploiement

- Jé the man !



Misson accomplie !



Mot de la fin

