

Les principes fondamentaux de la science des données

P. BOILY

UNIVERSITÉ D'OTTAWA | FACULTÉ DES SCIENCES | DÉPARTEMENT DES MATHÉMATIQUES ET DES STATISTIQUES
DATA ACTION LAB | IDLEWYLD ANALYTICS

Instructeur – Patrick Boily

Emploi


- Professeur Math/Stat [depuis '19, uOttawa]
- Président et conseiller principal [depuis '16, Idlewyld Analytics]
- Directeur et consultant principal ['12 - '19, CQADS, Carleton]
- Fonctionnaire GdC ['08 - '12, ASFC | StatCan | TC | TPSGC]
- 60+ cours universitaires ; 250+ jours d'atelier

Projets

- GAC ; NWMO ; CATSA ; etc.
- 40+ projets

Spécialisation

- Visualisation des données ; nettoyage des données (... malheureusement)
- Application d'un large éventail de techniques à tous les types de données
- Modélisation mathématique/statistique



Matériel de cours

Page Web du cours :

<https://data-action-lab.com/101-dse>

Contact :

pboily@uottawa.ca

Notes de cours :

<https://idlewyldanalytics.com>

Espace de travail Slack :

<https://dspdi.slack.com>

Description du cours

Ce cours offre aux participants l'occasion de maîtriser les connaissances et compétences fondamentales nécessaires à l'analyse des données.

Les participants seront initiés à diverses méthodes de préparation des données, à certaines limites intrinsèques des données et de l'analyse des données, ainsi qu'à des erreurs de pré-analyse facilement évitables.

Après le cours, les participants ont la possibilité de travailler sur un projet guidé, en recevant du feedback de l'instructeur.

Informations supplémentaires

Une exposition à la programmation et aux concepts introduits dans un premier cours universitaire de probabilités et de statistiques serait bénéfique (mais pas nécessaire).

Les participants sont encouragés à apporter un ordinateur portable/personnel sur lequel la version actuelle de R/Rstudio est installée (pour lequel ils peuvent avoir besoin d'une autorisation administrative pour installer des paquets).

Les participants au projet guidé doivent être familiers avec R et/ou Python.

Objectifs d'apprentissage

À la fin de ce cours, les participants seront en mesure de :

- sélectionner des méthodes appropriées pour préparer leurs données à l'analyse
- anticiper les défis et les limites inhérents aux données et aux résultats d'analyse souhaités
- appliquer des stratégies de nettoyage des données à leurs données
- effectuer des analyses simples
- construire de simples pipelines de science des données

Plan du cours

Les aspects techniques et non techniques des données

1. Les compétences quantitatives
- Les logiciels et les outils
- L'approche des "I" multiples
- Les rôles et les responsabilités
- Aide-mémoire

Les bases de la science des données

2. Les préliminaires
3. Les cadres conceptuels
4. L'éthique de la science des données
5. Le flux de travail analytique
6. Les données et les renseignements

Session 1

Session 2

Session 3

Session 4

Plan du cours

La préparation des données

7. La qualité et le traitement des données
8. Les valeurs manquantes
9. Les observations anormales
10. La dimensionnalité et les transformations de données

Miscellanea

11. L'ingénierie des données
12. La gestion des données

Session 1

Session 2

Session 3

Session 4

Problème des champignons vénéneux

Amanita muscaria

Habitat : bois

Taille des branchies : étroites

Odeur : aucune


Spores : blanc


Couleur du chapeau : rouge

Problème de classification :


L'*Amanita muscaria* est-elle comestible ou toxique ?







Habitat : bois
Taille des branchies : étroite
Odeur : aucune
Spores : blanc
Couleur du bouchon : rouge
Problème de classification :
comestible ou toxique



Habitat : bois


Taille des branchies : étroite

Odeur : aucune

Spores : blanc


Couleur du bouchon : rouge


Problème de classification :
comestible ou toxique



Habitat : bois
Taille des branchies : étroite
Odeur : aucune
Spores : blanc
Couleur du bouchon : rouge

Problème de classification :
comestible ou toxique





Habitat : bois

Taille des branchies : étroite

Odeur : aucune

Spores : blanc

Couleur du bouchon : rouge

Problème de classification :
comestible ou **toxique**

Discussion

Auriez-vous fait confiance à une prédiction "**comestible**" ?

D'où vient le modèle ?

Qu'auriez-vous besoin de savoir pour faire confiance au modèle ?

Quel est le coût d'une erreur de classification, dans ce cas ?