

# Cours MASH: Projets informatiques

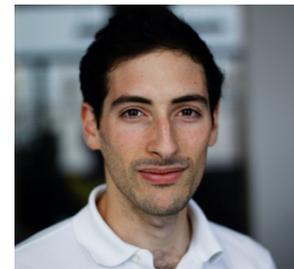
enseignant:

**Simon Lacoste-Julien**



TD / suivi par:

**Fajwel Fogel**



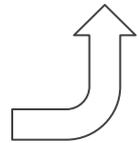
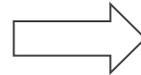
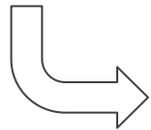
Équipe-Projet SIERRA, INRIA / ENS

# Je me présente...

**Simon Lacoste-Julien**

Chercheur CR

*Équipe-Projet SIERRA, INRIA –  
École Normale Supérieure*



## ► thèmes de recherche:

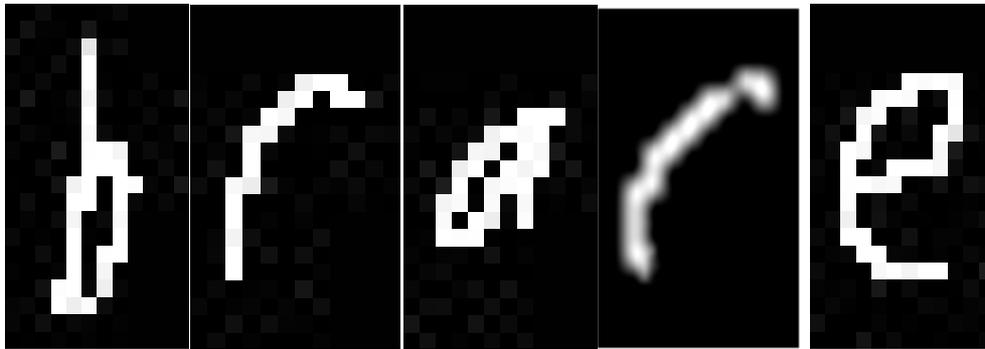
- prédiction structurée
- optimisation
- applications: vision, NLP, information retrieval, computational biology

**parenthèse:  
prédiction structurée**

# 1) Exploiter structure: motivation

---

- reconnaissance de mots



**brace**

- alignement de mots

bad — ? — mal

My  foot hurts  
Mon mauvais pied me fait

**le contexte  
aide!**

# Prédiction structurée:

---

Entrée

$x \in \mathcal{X}$

Sortie

$y \in \mathcal{Y}$

Reconnaissance de  
mots écrits

nombre exponentiel!

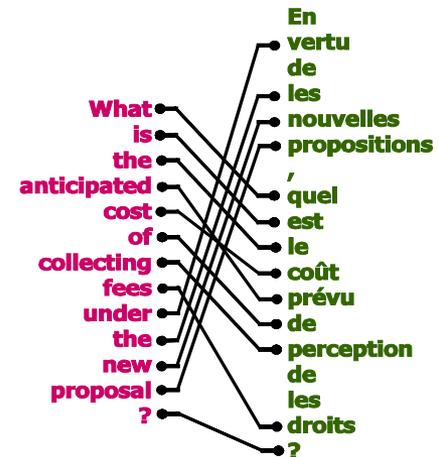


**brace**

Alignement  
de mots

What  
is  
the  
anticipated  
cost  
of  
collecting  
fees  
under  
the  
new  
proposal  
?

En  
vertu  
de  
les  
nouvelles  
propositions  
,  
quel  
est  
le  
coût  
prévu  
de  
perception  
de  
les  
droits  
?



# d'autres exemples...

fonction d'erreur  
structurée:  $\ell(y, y')$

Entrée  
 $\mathbf{x} \in \mathcal{X}$

Sortie  
 $y \in \mathcal{Y}$

Traduction  
automatique

'Ce n'est pas  
un autre  
problème de  
classification.'

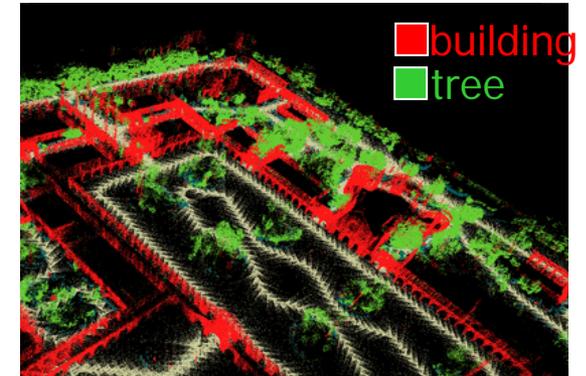
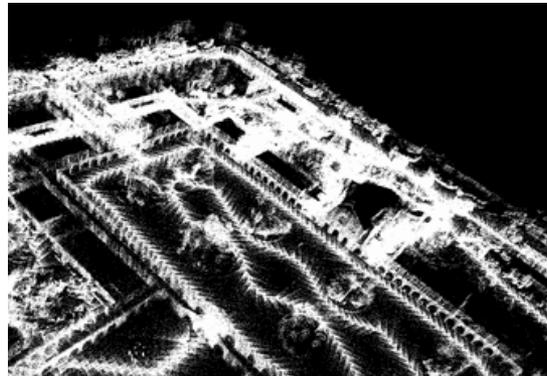


'This is not just  
another  
classification  
problem.'

Reconnaissance  
objet 3D



télémètre laser



**(fin de la parenthèse!)**

# Sujet du cours

- ▶ cours pratique!
  - but: mettre en pratique les techniques d'apprentissage automatique sur des **vraies données**
  - se familiariser avec les outils informatiques (python, scikit-learn)
  - **\*\* PROJET \*\***

# Structure du cours



- ▶ projet en équipe de 2 (max)
- ▶ « office hour » (OH) par Fajwel Vogel
  - en général (+ exceptions): les lundis de 10h–12h  
–> avec système de réservation
- ▶ remise du projet mardi 29 mars
- ▶ toutes les infos sur site web:

<http://www.di.ens.fr/~slacoste/teaching/projet-MASH-2015/>

# Plan de cours + jalons

- ▶ cours: lundi 9 & 23 nov. 10–12h: TD python / scikit-learn par Fajwel
- ▶ lundi 30 novembre:
  - jalon: avoir formé son équipe + choisi son projet + envoie par mail 1 page résumé de projet
  - OH obligatoire: rendez-vous avec Fajwel
- ▶ [OH optionnelle commence lundi 14 décembre et continue le 4 janvier et continue chaque semaine (avec exceptions)]
- ▶ lundi 18 janvier & 15 février:
  - JALONS: présentation de 10 minutes devant la classe pour chaque équipe sur l'état du projet (problème, approche, résultats)
- ▶ **mardi 30 mars – évaluation finale**
  - remettre un rapport écrit sur le projet d'environ 5 pages
  - session poster (8 pages A4); 10 minutes de présentation évaluée

# Choix de projet

- ▶ suggestions de projet sera disponibles sur le site web pour le 16 novembre
  - principalement [Challenge Data](#)
  - aussi possibilité kaggle
- ▶ vous pouvez suggérer votre propre projet:
  - quelles sont les données?
  - quelle est la tâche? les sorties désirées?
  - quel est la \*métrique d'évaluation\*?
- ▶ critères pour projet:
  - défi / votre intérêt / vous faire apprendre!
  - pour évaluation: feedback individualisé pour savoir ce que vous devriez accomplir...



# challengedata.ens.fr



HOME CHALLENGES PARTNERS CONTACT MY SPACE

## Our challenge

All the challenges offered by the platform since its creation.

> Challenge Data 2015-2016  
21/10/2015 - 01/07/2016

### Challenge Data 2015-2016



Predict the aesthetic score of a photograph

*Given a picture, we want to predict an aesthetic score between 1 (very unpleasant image) and 100 (very pleasant image), so as to surface the most beautiful pictures in a photo gallery.*



Attentional Selection in a Cocktail Party

*Use electroencephalography (EEG) data to identify which speaker a person is paying attention to.*



Machine Learning for Sensors Reduction in Body Posture Tracking

*The body posture tracking can be done with 10 inertial sensors placed on the body. We want to explore a new approach where the tracking can be done with a smaller number of sensors (in this project on*

- clôture académique: fin février
- clôture challenge: 30 juin

# Exemples de challenges:

Créateur du challenge	Titre du projet	Type de données	Type de problème
Dreem	Classification des états du sommeil	Série temporelle (EEG)	Classification
Sonoscanner	Détéction de bounding box en échographie obstétrique	Images	Regression
Cardiologs	Détection d'inversion d'électrodes	Série temporelle (ECG)	Classification
Shihab Lab	Classification d'EEG du cortex auditif	Série temporelle (EEG)	Classification
Criteo	Prédiction de clicks publicitaires	Données non structurées	Classification
Regaind	Prédiction de la qualité d'une photo	Images	Régression
Quantmetry / SNCF	Prédiction de pannes sur les trains SNCF	Données non structurées	Classification
Plume Labs	Prédiction de la pollution atmosphérique	Série temporelle	Régression
Capital Fund Management	Prediction du volume des transactions financières	Série temporelle	Régression
Université de Toulon	Projet Bird : classification de chants d'oiseau	Audio	Classification
Dassault Systèmes 3DS	Sensor reduction	Série temporelle	Regression
Reminiz	Reconnaissance de visages dans les films	Images	Classification
Oze-Energies	Prédiction de la consommation énergétique dans un immeuble	Série temporelle	Régression

\*\* séances de présentation des challenges les vendredi 13, 20 et 27 novembre en amphi Rataud à l'ENS entre 11h30 et 13h30 (optionnelles)

# Quelques étapes en analyse de données (apprentissage automatique appliqué)

- 1) Définition du problème
- 2) Télécharger données
- 3) Exploration données: résumer, visualisation
- 4) Data processing: sous-échantillonner, nettoyage, standardisation, transformation, définir « features »
- 5) Choix modèle / algorithme
- 6) Évaluer les résultats [répéter 3-5!]
- 7) Présenter solution / résultats

# Kind of features [Statistics terminology]

- a) Nominal qty.: distinct symbols with no ordering  
e.g.  $\text{color} \in \{\text{red, blue, green}\}$
- b) Ordinal qty.: values can be ordered  
e.g. for temperature:  $\text{cool} < \text{mild} < \text{hot}$
- c) Interval qty.: fixed units, but no scale [no absolute  $0$ ]  
e.g.  $p$  = position in space of an object;  $2p$  doesn't make sense  
but  $p_2 - p_1$  does
- d) Ratio qty.: absolute zero gives meaningful scale  
e.g. mass of object; frequency of words in document, ...

# scikit-learn...

(cours les lundi 9 et 23 novembre)

# Suggestion approche pour projet

- ▶ Commencer avec méthodes / modèles simples
- ▶ Étudier où ça brise!
- ▶ Modifier features / méthode / modèle en conséquence
- ▶ Répéter!

# Quelques ressources

## ▶ Logiciels:

- SciKit Learn (Python): <http://scikit-learn.org>
- Weka (Java): <http://www.cs.waikato.ac.nz/ml/weka/>
- RapidMiner (nicer GUI?): <http://rapid-i.com/>

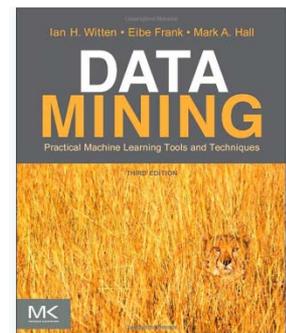
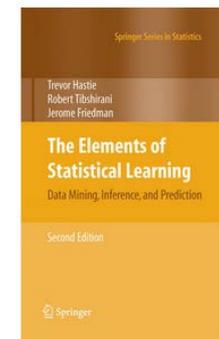
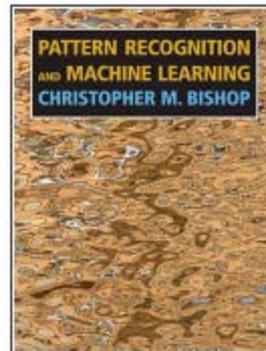
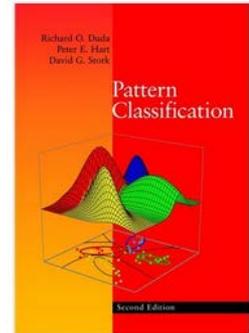
## ▶ Livres:

- Pattern Classification (Duda, Hart & Stork)
- Pattern Recognition and Machine Learning (Bishop)
- **Data Mining** (Witten, Frank & Hall)
- The Elements of Statistical Learning (Hastie, Tibshirani & Friedman)

## ▶ Cours en python:

- cours cs188 de Dan Klein à

Berkeley: <http://inst.eecs.berkeley.edu/~cs188/fa10/lectures.html>



# Action points!

- ▶ Former vos équipes (pour le 30 novembre)  
+ commencer à réfléchir à projets (voir site web)
- ▶ Avant cours du 9 novembre:
  - installer [Anaconda Python](#)
  - faire tutoriel Python / scikit-learn (info par mail)

