

# Introduction

Damien Nouvel



# Plan

1. Généralités
2. Contexte général
3. Corpus et statistiques
4. Visées applicatives

# Séances et modalités de contrôle

## ▶ Séances

- 24 séances
- Chaque séance : **cours** et **exercices** sur machine
- Cours S2 : *apprentissage automatique*

## ▶ Modalités de contrôle

- Un **contrôle** (S1) ou un **projet** (S2) : 50%
- Un **examen final** : 50%

# Contenu du cours (prévisionnel)

## ► Progression

- Introduction
- (Programmer en Python)
- Éléments en théorie des probabilités et en statistiques
- Statistiques pour la linguistique
- Théorie de l'information et mesures d'entropie
- Statistiques pour l'évaluation
- Classification automatique
- Paramétrage de classifieurs

# Plan

1. Généralités
2. Contexte général
3. Corpus et statistiques
4. Visées applicatives

# Informatique et langage



- ▶ **Grace Hopper** : A0, premier langage compilé (1951)

# Traitement Automatique des Langues (TAL)

- ▶ Le langage
    - **Expressivité** (implicite, déductions)
    - **Générativité** / compositionnalité
    - **Modes d'expression** : oral, écrit, signes, etc.
    - **Evolution** par conventions sociales
  - ▶ L'informatique
    - **Calcul** binaire, entiers, flottants, etc.
    - **Procédures** par séquence d'instructions
    - **Copies exactes**
    - **Télécommunications** et essor des nouvelles technologies
- ⇒ **Discipline** issue de l'essor de l'utilisation de l'informatique pour que des **humains** manipulent le **langage** par d'**autres moyens** et à une **autre échelle**

# Plan

1. Généralités
2. Contexte général
3. Corpus et statistiques
4. Visées applicatives

# Un corpus : quelles données, pour quoi faire

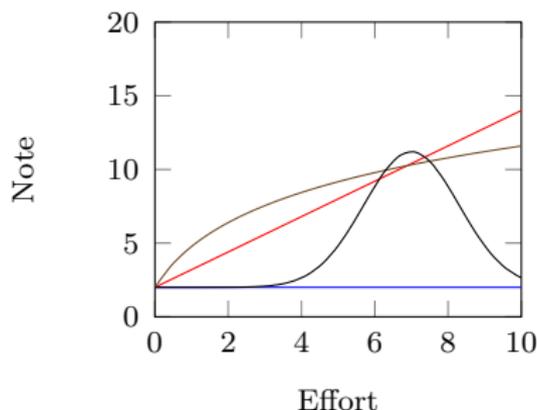
## ⇒ Ensemble de documents ...

- ▶ Un **contenu textuel encodé** (UTF8, PDF, Word, XML, etc.)
- ▶ Des *classifications* associées, par
  - Auteur(s) et éditeur
  - Langue
  - Date de publication
  - Style (roman, journal, publication, administratif, etc.)
  - Thèmes (science-fiction, politique, sport, technique, etc.)

## ⇒ Corpus comme collection de documents **indexés**

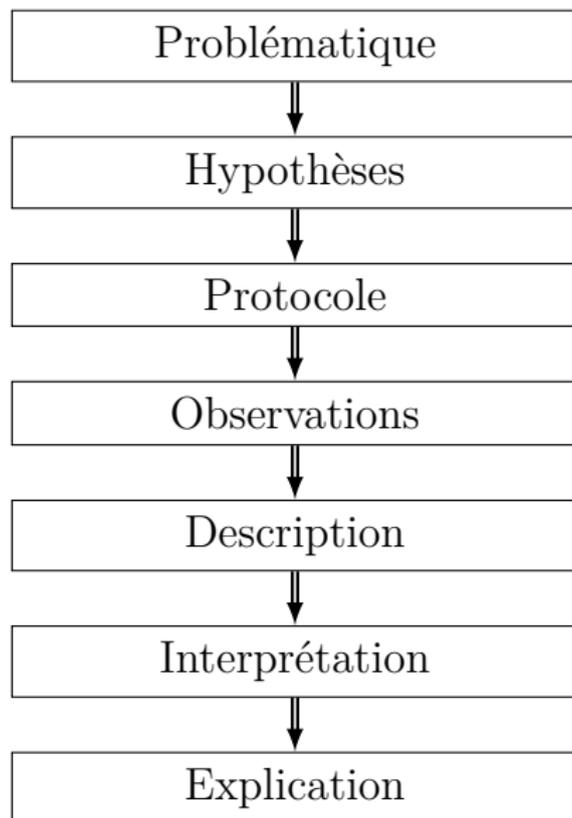
- ▶ Corpus comme **ressources** pour
  - Traitement du langage parlé
  - Traduction automatique
  - Études linguistique
  - Publications scientifiques (par ex. biomédical, sociologie)
  - etc.

# Les outils statistiques



- ▶ Les outils statistiques aident à modéliser des **corrélations** entre des données selon des **paramètres à déterminer**
- ▶ Quelques notions de base
  - **Fréquence** : nombre d'occurrences
  - **Probabilité** : nombre compris dans  $[0, 1]$
  - **Loi** : distribution des probabilités

# Statistiques pour les sciences



# Corrélation n'est pas causalité

- ▶ Attention aux interprétations hasardeuses...
  - Parler russe / Boire de la vodka
  - Bricoler dans un garage / Devenir millionnaire
  - Acheter des glaces / Porter des tongs

# Épistémologie : règles logiques

► Expliquer un phénomène selon des **conditions**

- **Nécessaire** :  $\neg a \Rightarrow \neg b$
- **Suffisante** :  $a \Rightarrow b$
- **Nécessaire et suffisante** :  $a \Leftrightarrow b$

► **Règles logiques** pour l'inférence

- **Dédution** :

$$\frac{(a \Rightarrow b) \wedge a}{b}$$

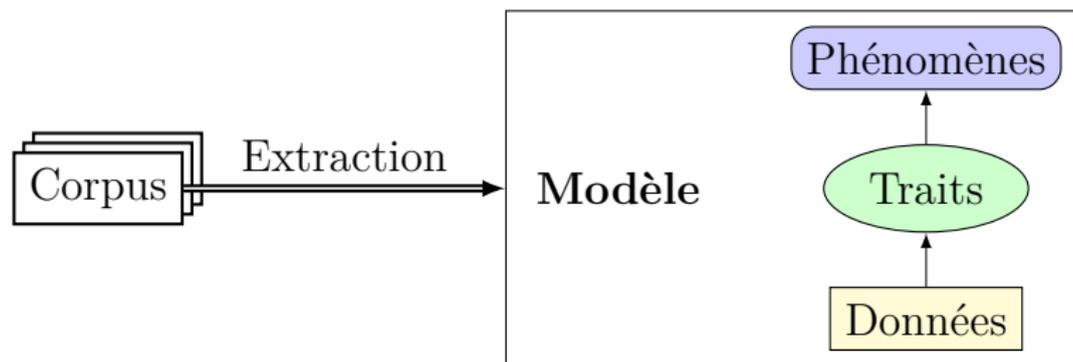
- **Abduction** :

$$\frac{(a \Rightarrow b) \wedge b}{a}$$

- **Induction** :

$$\frac{a \wedge b}{a \Rightarrow b}$$

# Corpus, modèle, tâche



- ▶ Les corpus permettent de **décrire des phénomènes**
  - **Paramétrage** du modèle (plus ou moins *supervisé*)
  - **Evaluation** du modèle sur un jeu de test
  - **Utilisation** du modèle avec d'autres données et tâches

⇒ Les **statistiques** permettent de **concevoir**, de **paramétrer** et d'**évaluer** l'adéquation du modèle pour une tâche donnée

# Plan

1. Généralités
2. Contexte général
3. Corpus et statistiques
4. Visées applicatives

# Exemples d'applications

- ▶ Niveaux de **représentation** du langage
  - Acoustique (oral)
  - Phonétique (oral)
  - Morphologie
  - Syntaxe
  - Sémantique
  - Pragmatique
- ▶ **Statistiques de corpus** pour
  - **Indexation** de documents et **recherche d'information**
  - Correction **orthographique** et **grammaticale**
  - **Reconnaissance** automatique de l'**écriture**
  - **Reconnaissance** automatique de la **parole**
  - **Traduction automatique**
  - ... (et bien d'autres)

# Pourquoi les statistiques en TAL

- ▶ **Historique** rapide et incomplet des **approches TAL**
  - **Symboliques** : automates, transducteurs
  - **Heuristiques** : logique, affectation manuel de poids de règles
  - **Numériques**, dont par exemple
    - Approches bayésiennes
    - Chaînes de Markov
    - Arbres de décision
    - Maximum d'entropie / régression logistique
    - SVM, CRF
    - Réseaux de neurones (DNN, LSTM, convolutions)

⇒ Plus de **numérique**, plus de **statistiques**
- ▶ Importance accrue des statistiques pour la linguistique
  - Mise à disposition d' **importants volumes** de textes
  - Exigence de **robustesse** des applications

⇒ Attention au paramétrages (baselines) !

# Quelques références

## ► Sites web

- Michèle Jardino <http://archives.limsi.fr/Individu/jardino/coursTCAN2005.pdf>
- Marti Hearst <http://courses.ischool.berkeley.edu/i256/f06/sched.html>
- Christopher Manning <http://web.stanford.edu/class/cs276b/>
- Peter Norvig <http://norvig.com/chomsky.html>
- Revue TAL <http://atala.org/~Revue-TAL->
- Revue CL <http://cljournal.org/>

## ► Livres

- Initiation aux méthodes de la stat. ling. (Muller, 1993)
- Modèles statistiques pour l'accès à l'information textuelle (Gaussier, Yvon, 2011)
- Statistique textuelle (Lebart, Salem, 1994)
- Foundation of Statistical NLP (Manning, Schütze, 1999)