

Génistat Conseils

POLYTECHNIQUE  
MONTREAL



# Statistique, Science des données, Intelligence artificielle : liens, différences, convergence

Bernard CLÉMENT, PhD

Société Statistique de Montréal : 26 avril 2018

# PLAN

- **Questions et Objectif**
- **Buzzwords et Terminologie**
- **Statistique Classique (SC)**
- **Science des Données (DS)**
- **Mégadonnées (Big Data) (BD)**
- **Apprentissage Machine (ML)**
- **Intelligence Artificielle (AI)**
- **Rôle du statisticien**
- **Réponses et Conclusions**

" I keep saying the **sexy job in the next ten years will be statisticians**  
People think I'm joking, but who would've guessed that computer  
engineers would've been the sexy job of the 1990s ? "

**Hal Varian, PhD, chief economist, Google**



" I keep saying the **sexy job in the next ten years will be statisticians**  
People think I'm joking, but who would've guessed that computer  
engineers would've been the sexy job of the 1990s ? "

**Hal Varian, PhD, chief economist, Google**



# Questions

**Q1 : quel est l'avenir de la science statistique ?**

**Q2 : le métier de statisticien est-il en train de changer ?**

**Q3 : comment doit-on former les futurs statisticiens ?**

**Q4 : l'inférence statistique a-t-elle encore une place à l'ère des mégadonnées ?**

**Q5 : quelle contribution la statistique peut-elle apporter dans le domaine de l'intelligence artificielle ?**

**Q6 : comment faire pour rehausser l'appréciation et la reconnaissance du rôle du statisticien dans la société ?**

**Q7 : .... vos questions ....**

**Objectif : proposer des éléments de réponse**

# Buzzwords - Terminologie

**DS : Data Science** ... ensemble des méthodes et outils orientés visant à apprendre avec les données et résoudre des problèmes ... compréhension / utilisation  
... science essentiellement **plusridisciplinaire**

**ML : Machine Learning** ... ensemble d'algorithmes, méthodes, outils, (apprentissage machine) pour développer des modèles visant à améliorer le processus d'apprentissage avec des données ... orientés **prédiction**

**DM : Data Mining** ... « *nontrivial process of identifying valid, novel, potentially useful, and ultimately understandable patterns in data* » G. Piatesky-Shapiro  
.... **DM** maintenant remplacé par **ML**

**AP : Analyse Prédictive** ... analyse pour prédire quelque chose  
méthode **pourrait être non statistique**

**BD : Big Data** ... données trop grosses en **taille** (à définir) et **complexité** (mégadonnées) nécessitant leur traitement informatique / statistique avec technologies sur des systèmes distribués en parallèle (Hadoop et autres)  
.... **BD** terme galvaudé trop emphase **quantité**  
pas assez sur la **qualité (véracité)**

# Buzzwords - Terminologie

**IA : Intelligence Artificielle** ... systèmes électronique qui ressemble à l'intelligence humaine d'une certaine manière  
.... différentes **interprétations** de ce qu'est **IA**  
test de A.Turin

voir "*Donner un sens à l'intelligence artificielle*" (rapport Cédric Villani)

## autres

---

apprentissage supervisé .... apprentissage non supervisé

données structurées ... données non structurées (images, textes,... )

apprentissage profond ... réseaux de neurones

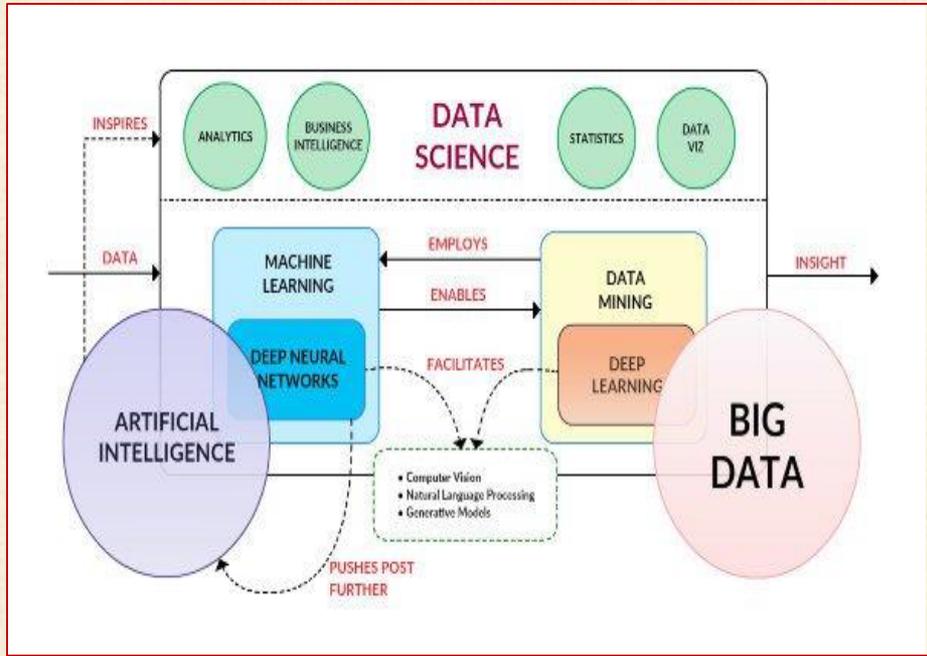
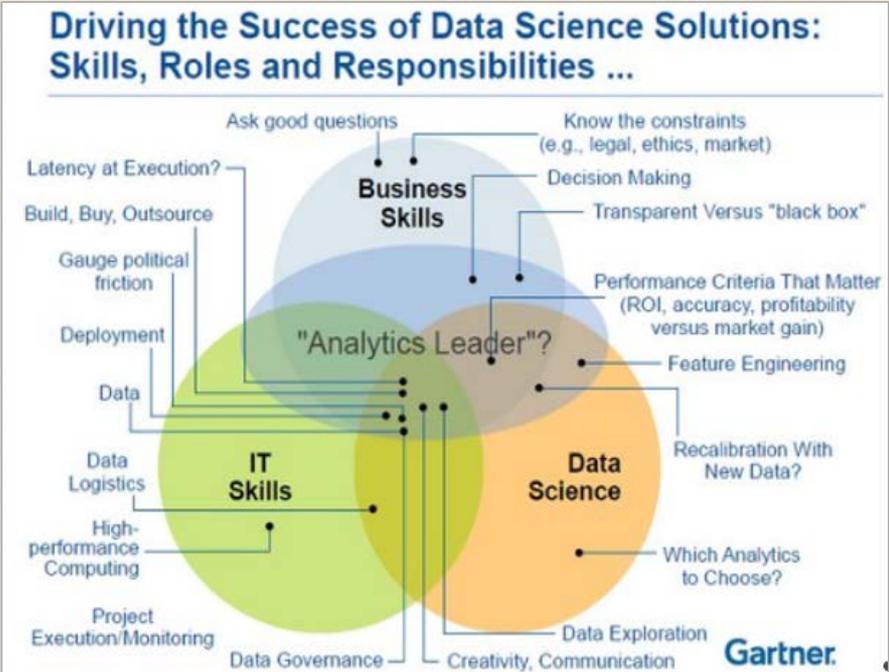
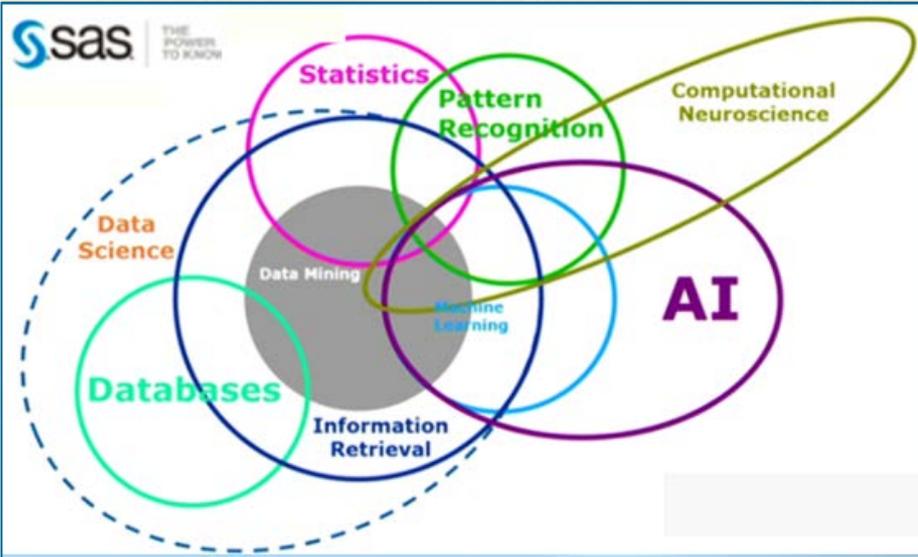
infonuagique ... systèmes distribués

IOT ... internet des objets ... réseaux de capteurs

open source software ... R , Python , ...

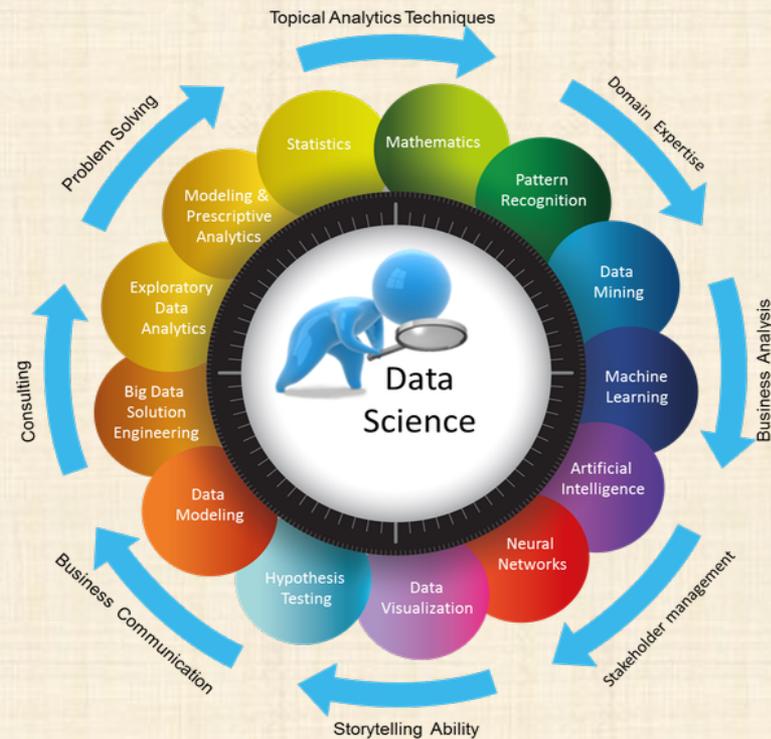
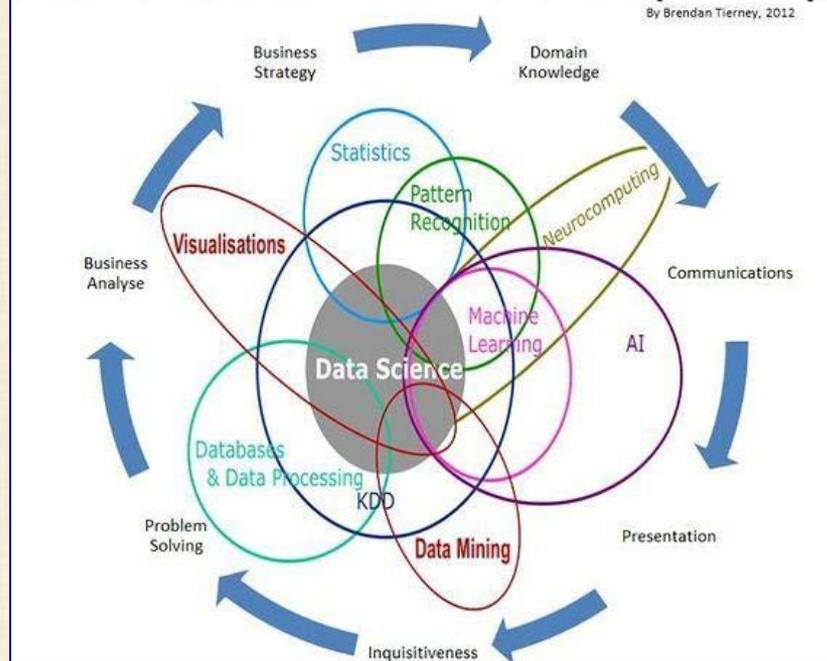
technologies ... GPU (puces graphiques traitement parallèle)

économie numérique ... **GAFAM** (Google Amazon Facebook Alibaba Microsoft)



# Data Science Is Multidisciplinary

By Brendan Tierney, 2012



?

**data science = statistique**

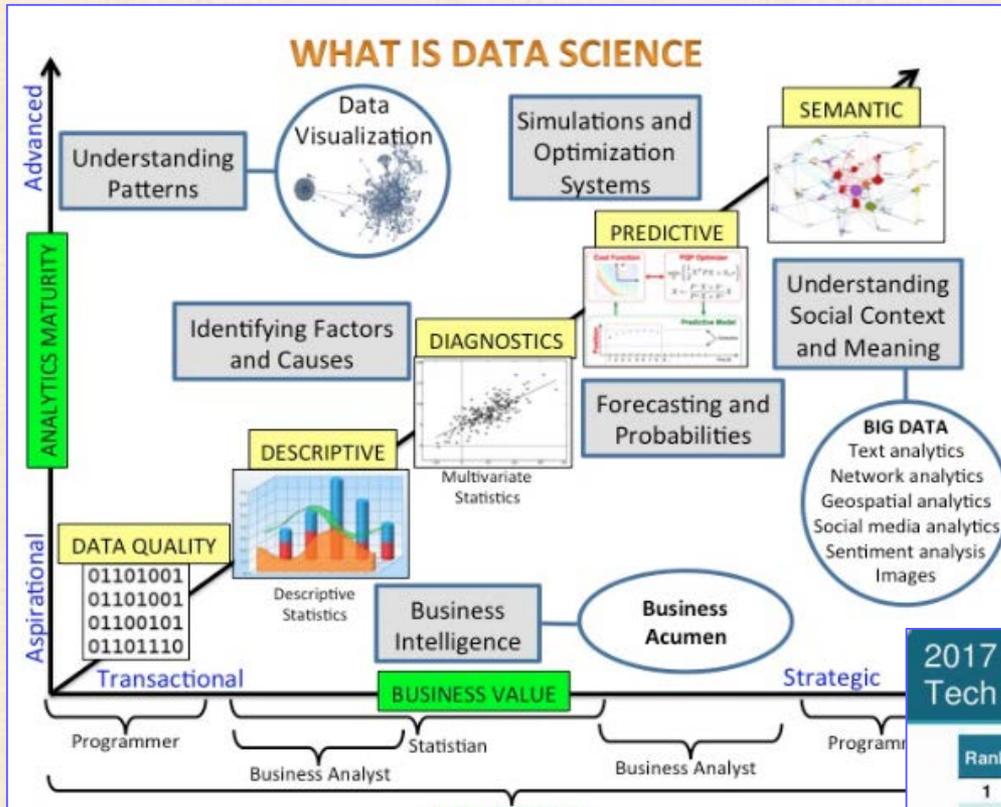
**réponse = O U I !!!**

## Statistique

science de d'apprentissage / compréhension d'un système avec des données en leur donnant du sens et en mesurant et contrôlant l'incertitude.

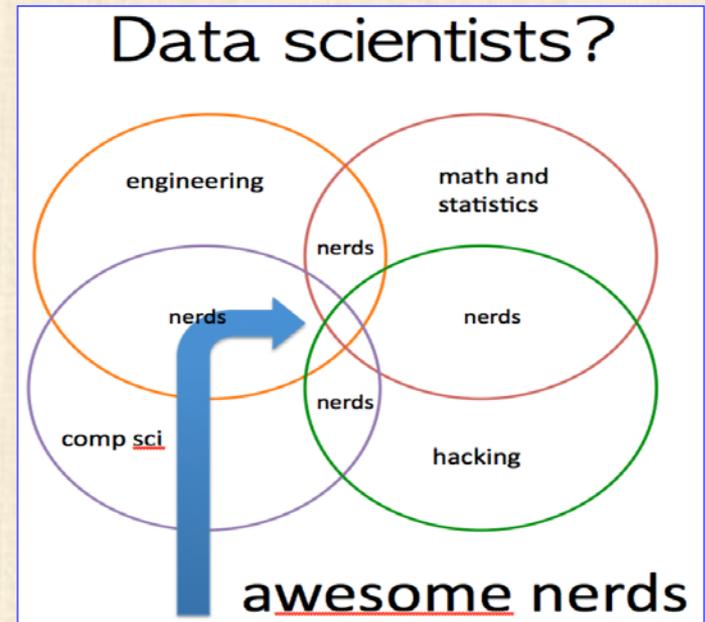
**L'incertitude est mesurée en unités de probabilité (= monnaie de l'incertitude)**

# Data Science



**STATISTICIEN**

**G  
A  
F  
A  
M**



**2017 Global Market Capitalization Leaderboard = Tech = 40% of Top 20 Companies...100% of Top 5...**

Rank	Company	Region	Industry Segment	Current Market Value (\$B)	2016 Revenue (\$B)
1	Apple	USA	Tech – Hardware	\$801	\$218
2	Google / Alphabet	USA	Tech – Internet	680	90
3	Microsoft	USA	Tech – Software	540	86
4	Amazon	USA	Tech – Internet	476	136
5	Facebook	USA	Tech – Internet	441	28
6	Berkshire Hathaway	USA	Financial Services	409	215
7	Exxon Mobil	USA	Energy	346	198
8	Johnson & Johnson	USA	Healthcare	342	72
9	Tencent	China	Tech – Internet	335	22
10	Alibaba	China	Tech – Internet	314	21
11	JP Morgan Chase	USA	Financial Services	303	90
12	ICBC	China	Financial Services	264	85
13	Nestlé	Switzerland	Food / Beverages	263	88
14	Wells Fargo	USA	Financial Services	262	85
15	Samsung Electronics	Korea	Tech – Hardware	259	168
16	General Electric	USA	Industrial	238	120
17	Wal-Mart	USA	Retail	237	486
18	AT&T	USA	Telecom	234	164
19	Roche	Switzerland	Healthcare	233	51
20	Bank of America	USA	Financial Services	231	80
Total				\$7,207	\$2,497

# DIFFÉRENCES entre STATISTIQUE et DATA SCIENCE ?

DOMAINE	éléments
<b>STATISTIQUE</b> (classique)	idées, hypothèses, évaluation analyse : primaire , haut vers le bas confirmatoire données : à recueillir
<b>DATA SCIENCE</b> (data mining)	génération d'hypothèses, création idées analyse : secondaire, bas vers le haut exploratoire (après coup) données : historiques

idée

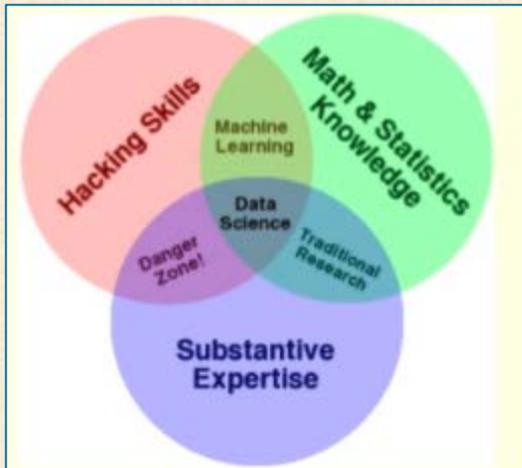
↓

données

idée

↑

données

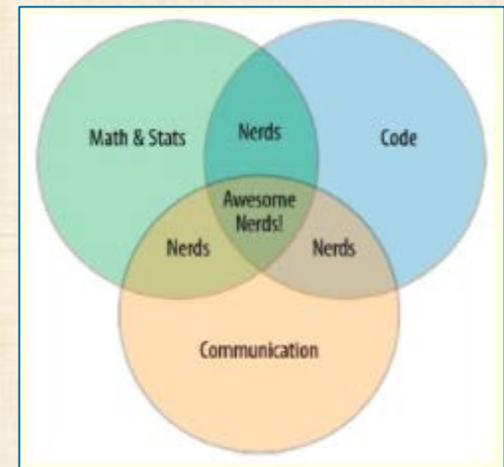


*" Data Science is much older than Kepler .. It is the second oldest profession "*

Gregory Piatetsky-Shapiro

*" Statistics has been the most successful information science. Those who ignore statistics are condemned to re-invent it "*

Brad Efron



# DATA SCIENCE : Tukey, Breiman, ...

## Un peu d'histoire ...

1961 **John Tukey** called for a reformation of academic statistics.

'**The Future of Data Analysis**', he pointed to the existence of an as-yet unrecognized science, whose subject of interest was learning from data, or 'data analysis'.

**20 years ago, John Chambers, Bill Cleveland, Leo Breiman** independently once again urged academic statistics to **expand its boundaries**

**Chambers** called for **more emphasis on data preparation and presentation** rather than statistical modeling;

**Breiman (2001)** called for emphasis on **prediction rather than inference**

**Cleveland** suggested the catchy name "**Data Science**"

## Breiman

"... there are 2 cultures in the use of statistical modeling to reach conclusions from data and solve problems"

**Culture ONE** = data are generated by a given **STOCHASTIC DATA MODEL**. (statistique classique)

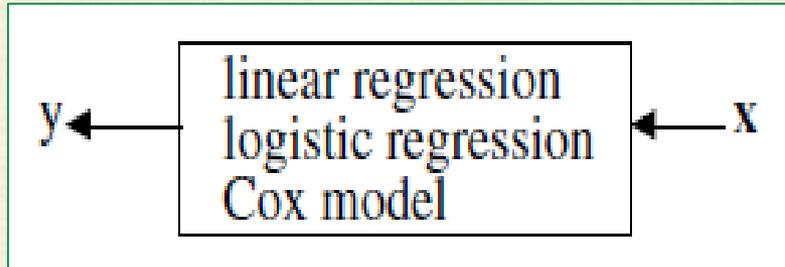
**Culture TWO** = uses **ALGORITHMIC MODELS** and treats the data mechanism as unknown.

The **statistical community** has been **committed** to **culture ONE**, kept statisticians from working on a large range of problems.

Algorithmic modeling has developed in fields outside statistics with **LARGE complex data sets** .... a more accurate and informative alternative to data modeling on **SMALL data sets**.

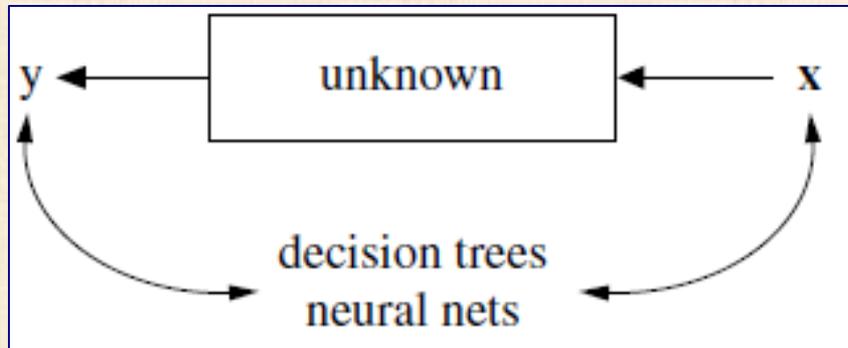
**move away from exclusive dependence on data models and adopt a more diverse set of tools.**"

## Stochastic Data Modeling Culture



Statisticians : 98%  
Computer Scientists : 2%

## Algorithmic Modeling Culture



Statisticians : 2%  
Computer Scientists : 98%

Leo Breiman (U Berkely) *Statistical Science* 2001, pp. 199-231

## DIFFÉRENCES et TERMINOLOGIE

### **STATISTIQUE**

### **INGÉNIERIE / INFORMATIQUE**

stat / math .....	informatique / computer science
<b>analyse statistique</b> .....	<b>machine learning (ML)</b>
régression / classification .....	apprentissage supervisé
<b>clustering / estimation densité</b> ...	<b>apprentissage non supervisé</b>
modèles .....	réseaux, graphiques
<b>tests / résidus</b> .....	<b>généralisation</b>
paramètres .....	poids
<b>variable input</b> .....	<b>features , classe</b>
variable output / réponse .....	target, label, features
<b>observation</b> .....	<b>instance, cas, exemple</b>
méthodes .....	algorithmes
<b>inférence = oui</b> .....	<b>inférence = non</b>
subvention = 20 000 \$ .....	subvention = 1 000 000 \$

## Mégadonnées (Big Data)

or noir du 21<sup>ème</sup> siècle

- grande quantité de données qui ne peuvent pas être traitées par des outils / méthodes de gestion informatiques traditionnels
- infrastructure / architecture matérielles et logiciels qui permet de manipuler et analyser les données massives avec des technologies informatiques appropriées

**5 V : Volume - Variété - Vitesse - Véracité - Valeur**

**Volume** : GRAND nombre d'observations (**n**) ou de variables (**p**)  
combien ? **pétabyte ....**

**Variété** : données sous tous les formats, images, vidéos, audio ..., web, banques de données gouvernementales, industrielles, disponibilité croissante .... **OPEN DATA SCIENCE**

**Vélocité** : données en mouvement, défilement continu,...

**Véracité** : fiabilité, qualité dans le temps, validité ..  
.... **très important .... problèmes de gouvernance**

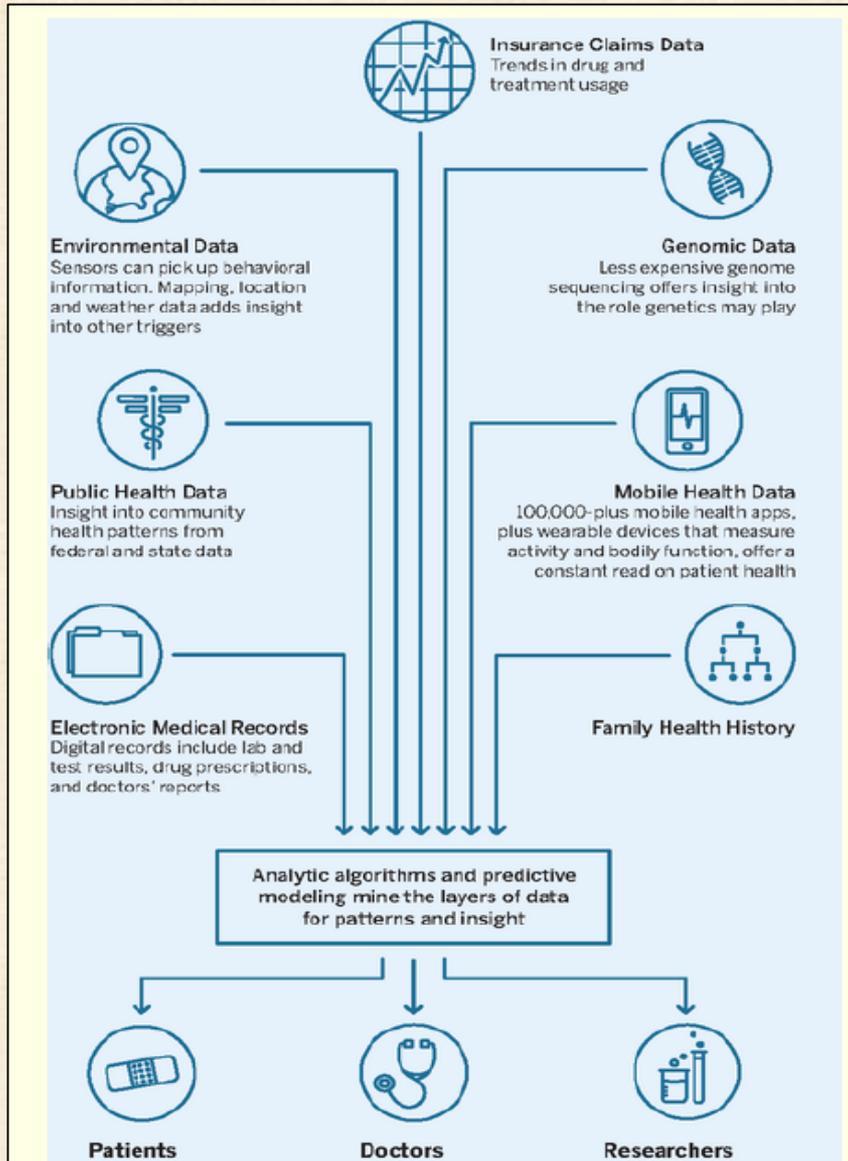
**Valeur** : création de valeur ajoutée ...

**APPLICATIONS** : santé, génomes, senseurs, réseaux sociaux, gouvernements, transport, ...

- très grande visibilité (**exagérée ?, promesses ?**) du **Big Data et l'IA**
- **défis et opportunités statistiques** : l'inférence classique est-elle inutile ?

**4 M du big data : Make Me More Money !**

## Exemple du BIG DATA : écosystème santé



+

### IOT (I nternet O T hings)

collecte des données personnelles  
via des

- appareils connectés sur la personne
- des senseurs stationnaires

fournit de l'information sur les activités  
des consommateurs et patients

### Données

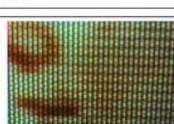
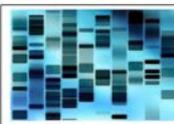
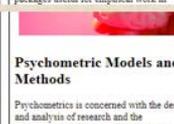
- environnementales
- dossiers médicaux
- santé publique
- génomiques
- familiales
- chercheurs
- patients
- médecins
- hôpitaux

# Statistique : définition - applications

## Statistique

collecte, analyse, interprétation, présentation, visualisation de données numériques et autres pour augmenter la connaissance en vue de ...

**But** prendre des décisions basées sur des **données existantes** (historiques) ou **données à recueillir** dans des conditions **d'incertitude** et de **variabilité**

 <p><b>Bayesian Inference</b> Applied researchers interested in Bayesian statistics are increasingly attracted to R because of the ease of which one can code algorithms to sample. <a href="#">[more]</a></p>	 <p><b>Chemometrics and Computational Physics</b> Chemometrics and computational physics are concerned with the analysis of data arising in chemistry and physics experiments, as well as the simulation of... <a href="#">[more]</a></p>	 <p><b>Clinical Trial Design, Monitoring, and Analysis</b> This task view gathers information on specific R packages for design, monitoring and analysis of data from clinical trials. It focuses on including... <a href="#">[more]</a></p>	 <p><b>Cluster Analysis &amp; Finite Mixture Models</b> This CRAN Task View contains a list of packages that can be used for finding groups in data and modelling unobserved cross-sectional heterogeneity. Many... <a href="#">[more]</a></p>	 <p><b>Probability Distributions</b> For most of the classical distributions, base R provides probability distribution functions (p), density functions (d), quantile functions (q), and... <a href="#">[more]</a></p>	 <p><b>Computational Econometrics</b> Base R ships with a lot of functionality useful for computational econometrics, in particular in the stats package. This functionality is complemented by many... <a href="#">[more]</a></p>
 <p><b>Design of Experiments (DoE) &amp; Analysis of Experimental Data</b> This task view collects information on R packages for experimental design and analysis of data from experiments. Please feel free to suggest enhancements... <a href="#">[more]</a></p>	 <p><b>Graphic Displays &amp; Reproducible Research</b> A comprehensive guide to the most up-to-date regression model in statistics... <a href="#">[more]</a></p>	 <p><b>Statistical Genetics</b> Great advances have been made in the field of genetic analysis over the last years. The... <a href="#">[more]</a></p>	 <p><b>High-Performance and Parallel Computing with R</b></p>	 <p><b>Analysis of Ecological and Environmental Data</b> This Task View contains information about using R to analyse ecological and environmental data... <a href="#">[more]</a></p>	 <p><b>Empirical Finance</b> This CRAN Task View contains a list of packages useful for empirical work in... <a href="#">[more]</a></p>
 <p><b>Phylogenetics, Especially Comparative Methods</b> The history of life unfolds within a phylogenetic context. Comparative phylogenetic methods are statistical approaches for analysing historical... <a href="#">[more]</a></p>	 <p><b>Reproducible Research</b> The goal of reproducible research is to tie specific instructions to data analysis and experimental data so that scholarship can be recreated, better... <a href="#">[more]</a></p>	 <p><b>Robust Statistical Methods</b> Robust (or "resistant") methods for statistics modelling have been available in S from the start, in R in package stats (e.g., median(), mean(), trim = ...). <a href="#">[more]</a></p>	 <p><b>Analysis of Pharmacokinetic Data</b> The primary goal of pharmacokinetic (PK) data analysis is to determine the relationship between the dosing regimen and the body's exposure to the drug as... <a href="#">[more]</a></p>	 <p><b>Psychometric Models and Methods</b> Psychometrics is concerned with the design and analysis of research and the measurement of human characteristics. Psychometricians have also worked... <a href="#">[more]</a></p>	 <p><b>gRaphical Models in R</b> Wikipedia defines a graphical model as a... <a href="#">[more]</a></p>
 <p><b>Analysis of Spatial Data</b> Base R includes many functions that can be used for reading, visualising, and analysing spatial data. This document provides... <a href="#">[more]</a></p>	 <p><b>Time Series Analysis</b> Base R ships with a lot of functionality useful for time series, in particular in the... <a href="#">[more]</a></p>	 <p><b>Survival Analysis</b> Survival analysis, also called event history analysis in social science, or reliability... <a href="#">[more]</a></p>	 <p><b>Survival Analysis</b> Survival analysis, also called event history analysis in social science, or reliability... <a href="#">[more]</a></p>	 <p><b>gRaphical Models in R</b> Wikipedia defines a graphical model as a... <a href="#">[more]</a></p>	 <p><b>gRaphical Models in R</b> Wikipedia defines a graphical model as a... <a href="#">[more]</a></p>

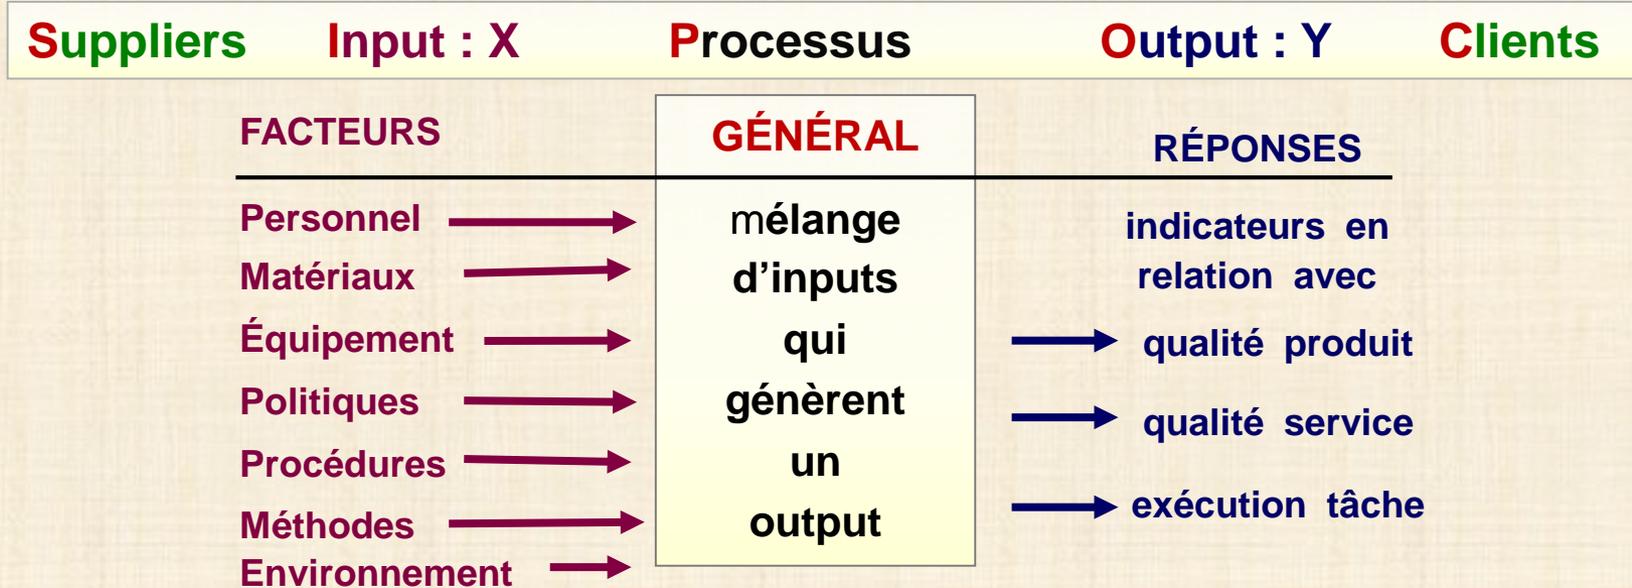
## Applications

**TOUS** les domaines de l'activité humaine **science interdisciplinaire**

" **Statistical thinking** will one day as necessary for efficient citizenship as the ability to read and write. "

H.G. Wells (1866-1946)

# PROCESSUS / SYSTÈME) : S I P O C



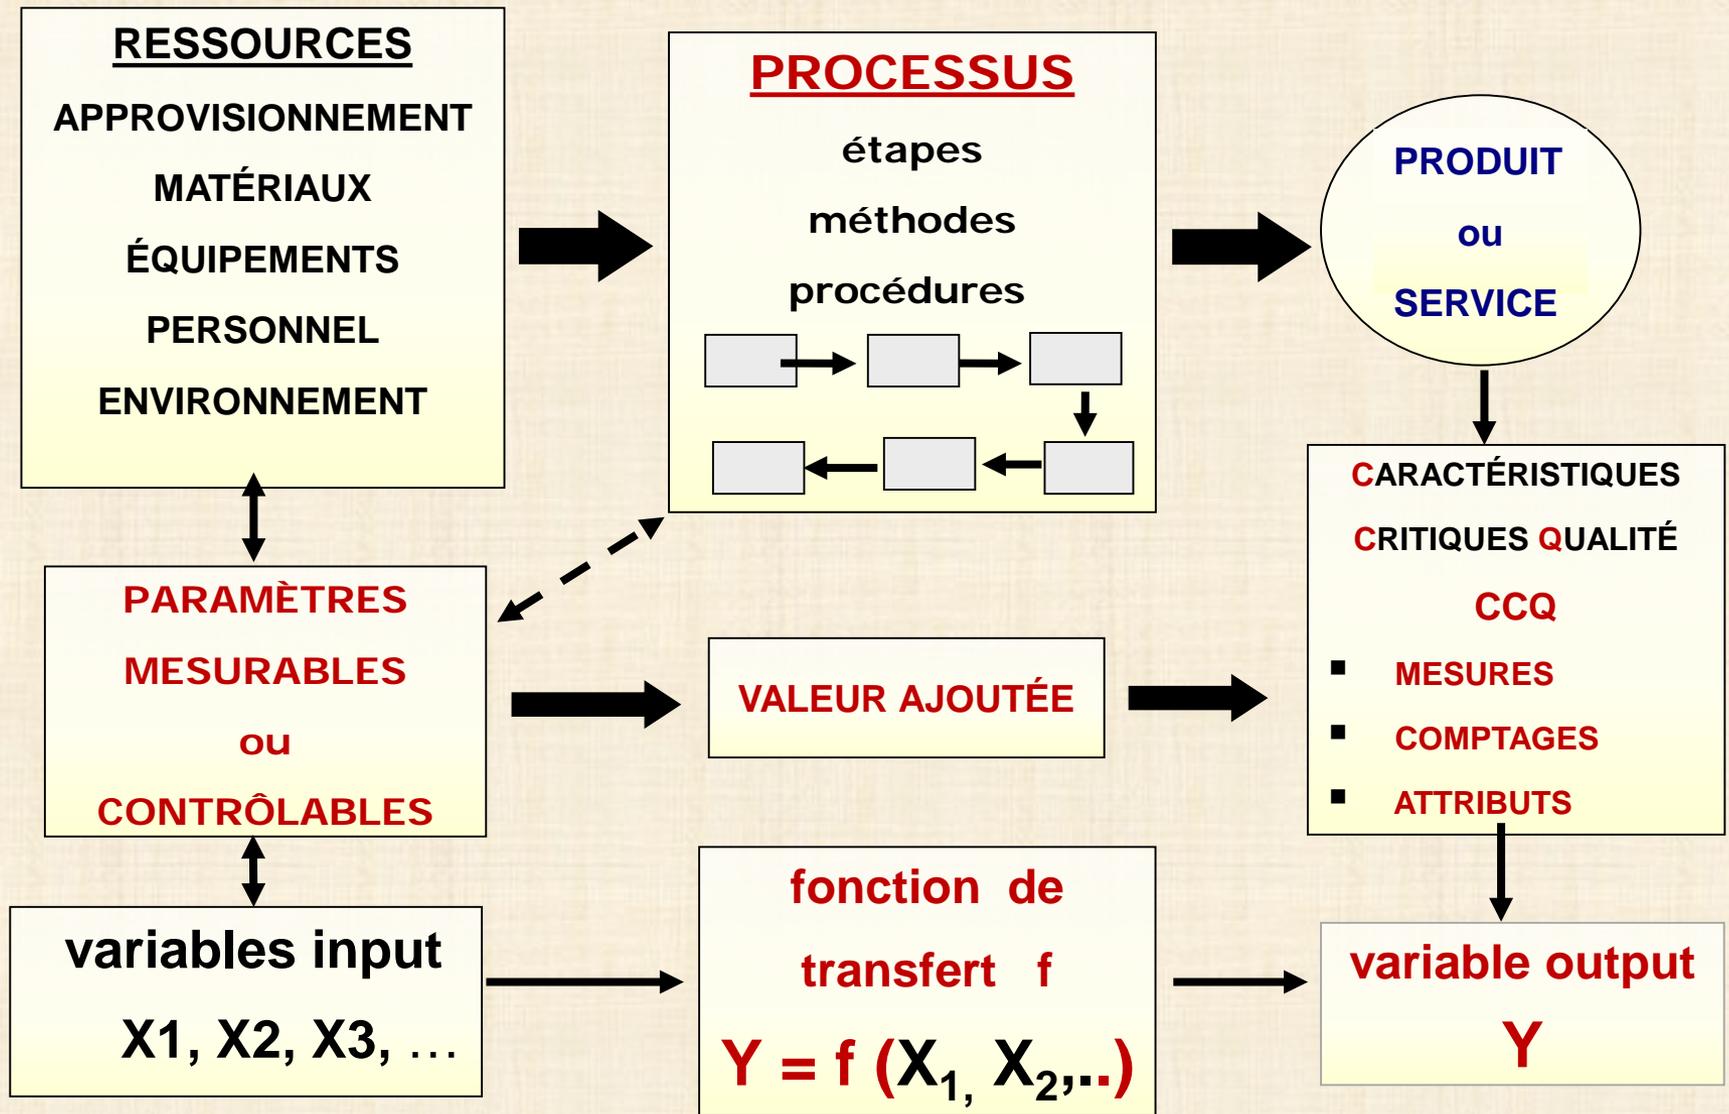
## exemples en intelligence artificielle

### PROCESSUS / SYSTÈME

- DESIGN (CONCEPTION)
- FABRICATION
- MESURAGE
- TRANSACTIONNEL
- ADMINISTRATIF

INPUT A	RESPONSE B	APPLICATION
Picture	Are there human faces? (0 or 1)	Photo tagging
Loan application	Will they repay the loan? (0 or 1)	Loan approvals
Ad plus user information	Will user click on ad? (0 or 1)	Targeted online ads
Audio clip	Transcript of audio clip	Speech recognition
English sentence	French sentence	Language translation
Sensors from hard disk, plane engine, etc.	Is it about to fail?	Preventive maintenance
Car camera and other sensors	Position of other cars	Self-driving cars

# PROCESSUS / SYSTÈME



# Type d'études statistiques

**actif**

rôle  
statisticien

**passif**

Expériences planifiées  
traitements appliqués aux  
**unités expérimentales**  
selon un protocole (design)

structure traitements

design expérimental :  
**randomisation, blocage,**  
**répétitions**

biostatistique,  
pharmaceutique,  
sciences physiques,  
sciences exactes,  
expériences avec  
sujets humains /  
animaux .....

Sondages, enquêtes,  
recensements  
=  
études énumératives  
plan d'échantillonnage  
des **unités statistiques**  
pas de traitements  
appliqués aux unités

**sciences humaines,**  
**sciences sociales,**  
.....

Études observationnelles  
données collectées au  
fil du temps / temps réel  
unité statistiques  
=  
**instants d'observations**  
peu / pas de  
planification statistique

**banques de données,**  
**mégadonnées**  
**(big data)**

# Type d'études statistiques

observationnelle

expérimentale

énumérative

analytique

## Observational Studies

Average and Range Charts  
(used as Process Behavior Charts)

Individual & Moving Range Charts  
(used as Process Behavior Charts)

Characterization of Process Behavior  
using  
Generic, Fixed-width Limits  
that are reasonably conservative  
with all types of homogeneous data sets.

**outils SPC**

cartes comportement  
processus

## Experimental Studies

Average &  
Range  
Charts

$\bar{X}$  &  
R  
Charts

Analysis of Means

Analysis of Variance

Estimation and Tests of Hypotheses  
using  
Alpha-levels,  
Critical Values,  
Interval Estimates

**outils statistiques**

tests, ANOVA,  
régression, etc.

## Two Types of Studies

### Enumerative Studies:

Census  
Inventory  
Exit survey at polls  
Acceptance sampling

### Analytic Studies:

Selection of suppliers  
Poll to determine strategy  
Experiment to improve  
performance  
Drug testing

### W. E. Deming's Two Types of Studies



Chapter 7 from *Some Theory of Sampling*, 1950

*The aim of any experiment is to provide a rational basis for action*

**Enumerative study:** an experiment in which action will be taken on the universe.

**Analytic study:** an experiment in which action will be taken on a cause system to improve performance in the future.

**nouvelle distinction**

**CLASSIQUE (traditionnelle) : base inférentielle**

**MÉGADONNÉES (nouvelle) : base algorithmique**

# Planification étude statistique

## Identification des VARIABLES

**Nature:** continue - catégorique

**Rôle:** explicatives (X = input) - à expliquer (Y = output = réponse)

Liste des X complète? p = nombre OK?

Mesure de Y - processus de mesure / erreur? justesse?

## STRUCTURE et le PLAN de collecte des données

expérience planifiée - quel plan statistique ?

- combien de données ? n ?

données observées sans plan expérimental – qualité ?

## Terme d'erreur expérimentale - distribution normale? Importance ?

*préoccupation obsessionnelle de la normalité !*

Forme de f - connue – linéaire / non linéaire (cas plutôt rare)

- inconnue - quelle approximation ? – polynomiale ?

- techniques de sélection des variables pour modéliser

- qualité du modèle ajusté ? Critères ?

Ajustement du modèle - analyse de sensibilité des X

Évaluation de qualité du modèle - analyse des résidus

# **ÉTAPES ÉTUDE STATISTIQUE CLASSIQUE**

- |                          |   |
|--------------------------|---|
| <b>1. Identification</b> | processus / problème / variables                        |
| <b>2. Observation</b>    | plan collecte des données                               |
| <b>3. Spécification</b>  | modèle pour analyse                                     |
| <b>4. Estimation</b>     | paramètres du modèle                                    |
| <b>5. Décomposition</b>  | variabilité (ANOVA), test F                             |
| <b>6. Validation</b>     | tests, ratio-F, analyse résidus                         |
| <b>7. Exploitation</b>   | optimisation / résolution problème<br>décision / action |

## **ÉTAPES**

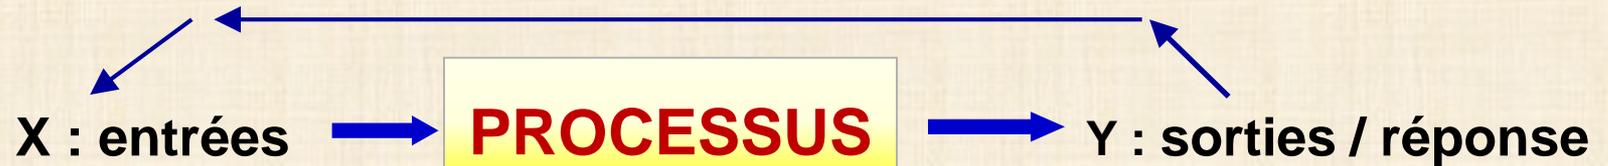
## **ANALYSE**

## **STATISTIQUE**

## **CLASSIQUE**

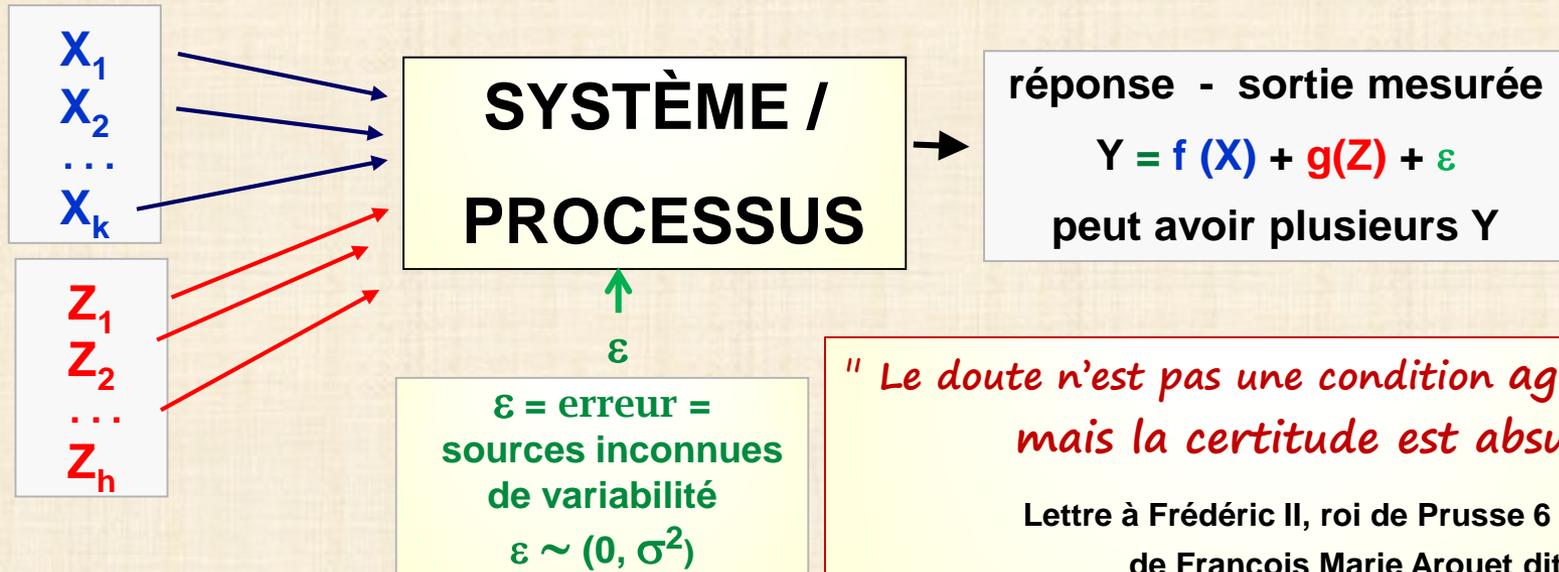
- 1. Spécification d'un modèle statistique**
- 2. Estimation des paramètres du modèle**
- 3. Décomposition de la variabilité : ANOVA**
- 4. Tests d'hypothèses sur les paramètres**
- 5. Analyse diagnostique des résidus**
  - vérification des hypothèses de base
  - identification d'observations influentes
  - transformation Box-Cox de réponse Y
- 6. Si nécessaire : itération des étapes 1 à 5**
- 7. Optimisation de la réponse (s'il y a lieu)**
- 8. Graphiques de la réponse**

# Étude des relations entrées-sorties



COMPARAISON	Modèle de prédiction	Modèle d'analyse de variance
<b>But</b>	développement d'un modèle prédictif de la réponse	identification des effets significatifs sur la réponse
<b>Source des données</b>	historiques / observationnelles	résultat d'un plan d'expérimentation
<b>Nombre d'observations</b>	grand: centaines, milliers...	petit : dizaines
<b>Variables d'entrée</b>	continues / quantitatives	catégoriques / qualitatives
<b>Nombre de valeurs distinctes des variables d'entrée</b>	autant qu'il y a d'observations	nombre restreint généralement moins de 10
<b>Utilisation des variables indicatrices (0-1)</b>	occasionnelle	employées systématiquement pour représenter les modalités
<b>Emphase et difficulté</b>	forme et la qualité du modèle	spécification du modèle reflétant la complexité du plan expérimental
<b>Structure des données</b>	simple	complexe

# ANALYSE STATISTIQUE CLASSIQUE : comprendre / prédire / optimiser



*" Le doute n'est pas une condition agréable, mais la certitude est absurde. "*

Lettre à Frédéric II, roi de Prusse 6 avril 1767  
de François Marie Arouet dit **Voltaire**

**Aucune restriction concernant la nature des  $X$  et  $Y$**

**$X$ : catégorique, entière, continue, contrôlées, aléatoires**

**$Y$ : binaire(0, 1), multinomiale, entière, continue**

**Algorithmes du Machine Learning**

**linéaire, linéaire généralisé, arbres, réseaux neurones,  
PLS, etc. ..**

**$p$  = nombre de variables     $n$  = nombre d'observations**

**on peut avoir plus de variables que d'observations !**

# VARIABLES et MODÈLE

V  
A  
R  
i  
A  
B  
L  
E  
S

## RÔLE

---

**Y** : réponse , output, à expliquer

peut être: **binaire (0, 1), multinomiale, continue, multidimensionnelle**

**X, Z** : explicatives, régresseurs, input

inter / intra      relativement aux unités expérimentales

## NATURE

---

**X (fixées)** : continues, catégoriques (facteurs)

**Z (aléatoires)** : continues, catégoriques

## INFLUENCE

---

**X** : affecte la centralité (moyenne) de Y : **effets fixes**

**Z** : affecte la dispersion (variance) de Y : **effets aléatoires**

**MODÈLES** **effets fixes** | **effets aléatoires** | mixtes (**fixés** , **aléatoires**)

$$Y = f (X_1, X_2 , \dots , X_k ; \beta_0 , \beta_1 , \beta_2 , \dots ) \\ + g (Z_1, Z_2, \dots, Z_h ; \sigma_1^2 , \sigma_2^2 , \dots ) + \varepsilon (0, \sigma^2)$$

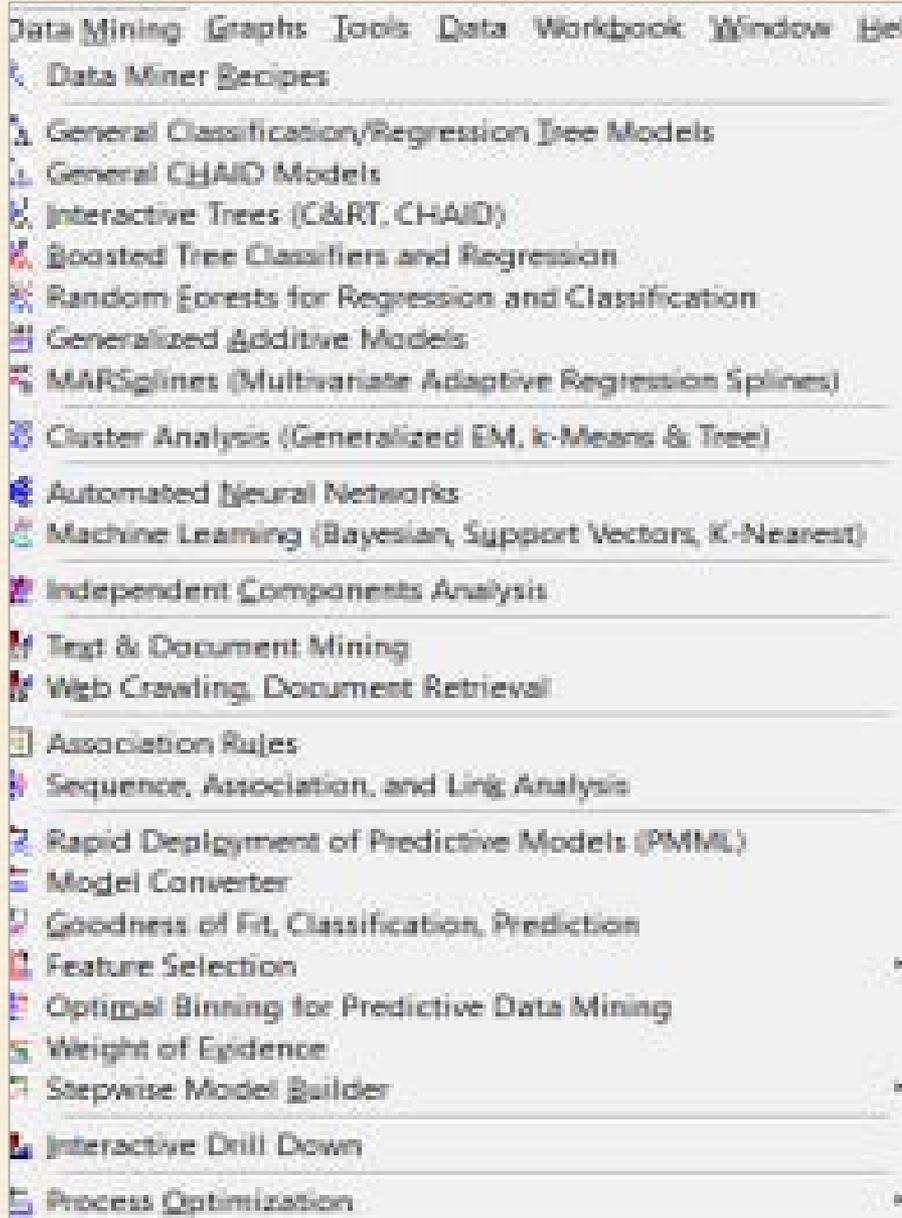
## GLM : General Linear Model

**modèles linéaires**

For related ANOVA and regression methods, also refer to the Experimental Design and the Variance Components and Mixed-Model ANOVA/ANCOVA modules.

## GLZ : Generalized Linear/Nonlinear Model

**modèles linéaires généralisés**



**Class Regression Trees (CRT)**

**Bosting (bootstrap)**

**Ensembles**

**Random Forests**

**GAM**

**MARSplines**

**Clustering**

**Bayesian Networks**

**Automated Neural Networks**

**Support Vector Machine (SVM)**

**Text Mining**

**Web Crawling**

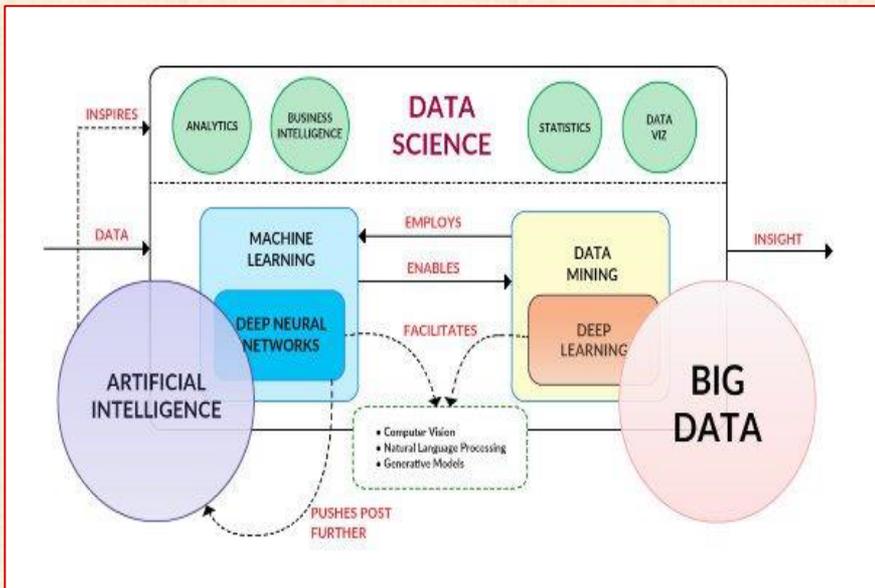
**Rapid Deployment (PMML)**

**Optimal Binning**

**Stepwise Model Builder**

**Process Optimization**

# BIG DATA



Unités d'octets <span style="float: right;">v · d · m</span>						
Ordre de grandeur	Système international (SI)			Préfixes binaires		
	Unité	Notation	Valeur	Unité	Notation	Valeur
1	octet	o	1 octet	octet	o	1 octet
10 <sup>3</sup>	kiloctet	ko	10 <sup>3</sup> octets	kibioctet	Kio	2 <sup>10</sup> octets
10 <sup>6</sup>	mégaoctet	Mo	10 <sup>6</sup> octets	mébioctet	Mio	2 <sup>20</sup> octets
10 <sup>9</sup>	gigaoctet	Go	10 <sup>9</sup> octets	gibioctet	Gio	2 <sup>30</sup> octets
10 <sup>12</sup>	téraoctet	To	10 <sup>12</sup> octets	tébioctet	Tio	2 <sup>40</sup> octets
10 <sup>15</sup>	pétaoctet	Po	10 <sup>15</sup> octets	pebioctet	Pio	2 <sup>50</sup> octets
10 <sup>18</sup>	exaoctet	Eo	10 <sup>18</sup> octets	exbibioctet	Eio	2 <sup>60</sup> octets
10 <sup>21</sup>	zettaoctet	Zo	10 <sup>21</sup> octets	zèbibioctet	Zio	2 <sup>70</sup> octets
10 <sup>24</sup>	yottaoctet	Yo	10 <sup>24</sup> octets	yobioctet	Yio	2 <sup>80</sup> octets

**big data**

Tout Enregistré Zetta 21  
Tous les livres MultiMédia Exa 18  
Tous les livres (mots) Peta 15  
Tous les livres (mots) Tera 12  
Tous les livres (mots) Giga 9  
Photo Mega 6  
Livres Kilo 3

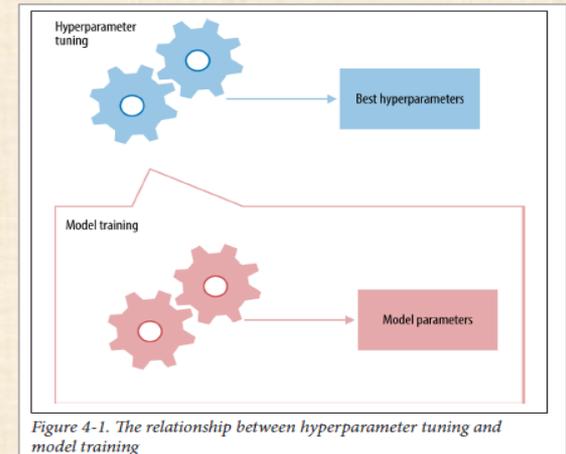
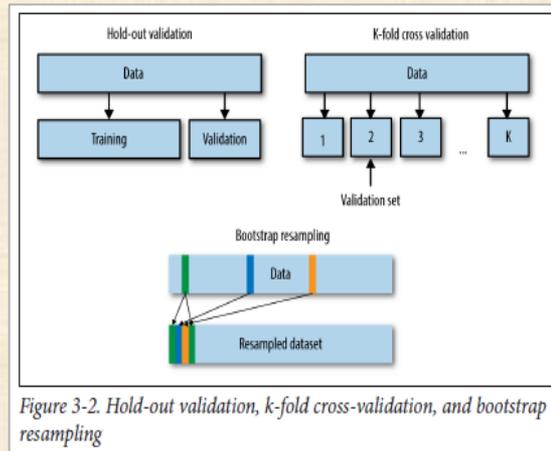
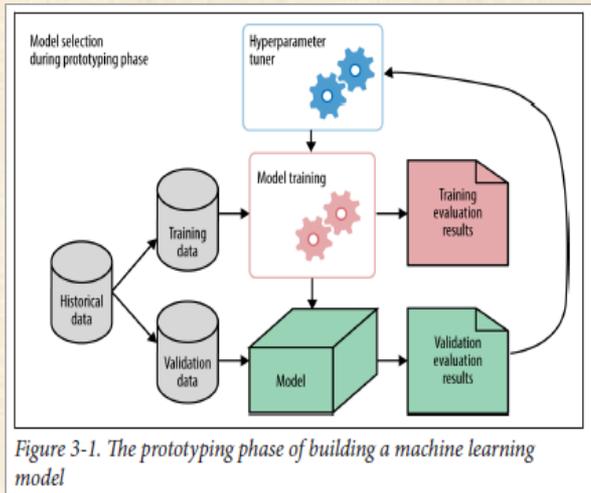
### Point de vue scientifique

- Les données sont collectées et enregistrées à des vitesses énormes (GB/h)
  - Capteurs sur un satellite
    - NASA EOSDIS archive plusieurs pétaoctets de données géoscientifiques par an
  - Télescopes observent les ciux
  - Analyse du génôme
  - simulations scientifiques
    - téraoctets de données générées en quelques heures

### Point de vue commercial

- Des morceaux de données sont saisis et stockés
  - Données du Web
  - achats en hyper/supermarchés
  - Opérations bancaires

# DÉMARCHE Machine Learning / Data Mining



## Statistique traditionnelle (classique)

expert du domaine apprend les bonnes variables ("features") et apporte au statisticien un **petit** tableau de données nettoyées

**étapes** : spécification modèle + analyse des résidus + critères d'évaluation

## Approche Data Mining / Machine Learning

départ avec un gros ensemble de données  
(beaucoup de variables / d'observations) (pourrait être un big data)  
lance plusieurs algorithmes pour identifier plusieurs « **bons** » modèles  
data séparé en 2 / 3 parties : entraînement + test + prédiction

**étapes** : plusieurs algorithmes

+

**critères d'évaluation** : courbe ROC, AUC, Lift chart, bootstrap ...

## EXAMPLES

### Click-through rate

Based on the search term, knowledge of this user (IPAddress), and the Webpage about to be served, what is the probability that each of the 30 candidate ads in an ad campaign would be clicked if placed in the right-hand panel.

**Logistic regression with billions of training observations.  
Each ad exchange does this, then bids on their top candidates,  
and if they win, serve the ad within 10ms!**

### Adverse drug interactions

US FDA (Food and Drug Administration) requires physicians to send in adverse drug reports, along with other patient information, including disease status and outcomes. Massive and messy data.

**found drug interactions associated with good and bad outcomes.**

### Social networks

Based on who my friends are on Facebook or LinkedIn, make recommendations for who else I should invite. Predict which ads to show me.

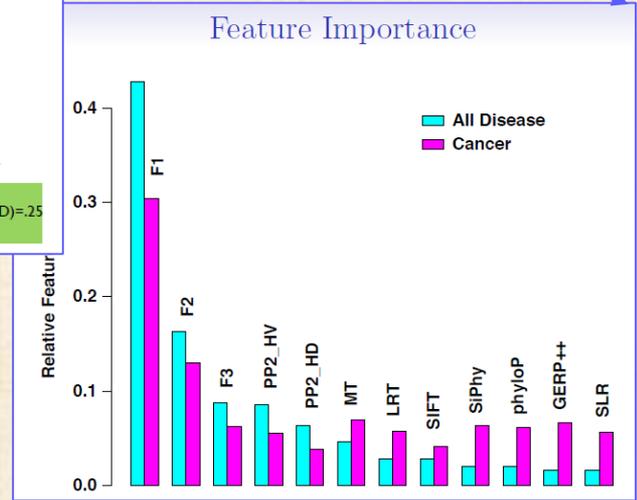
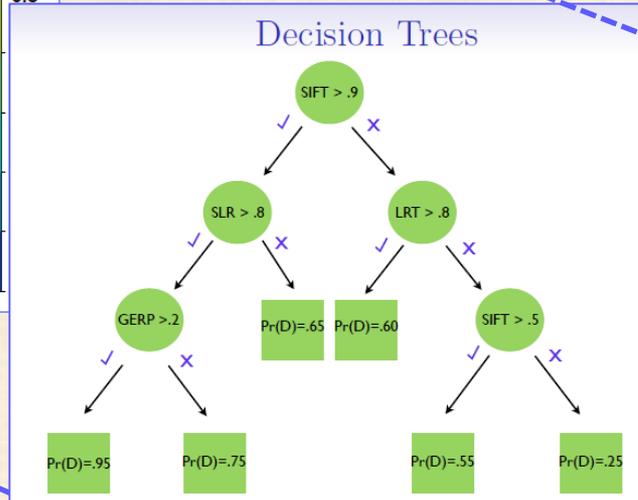
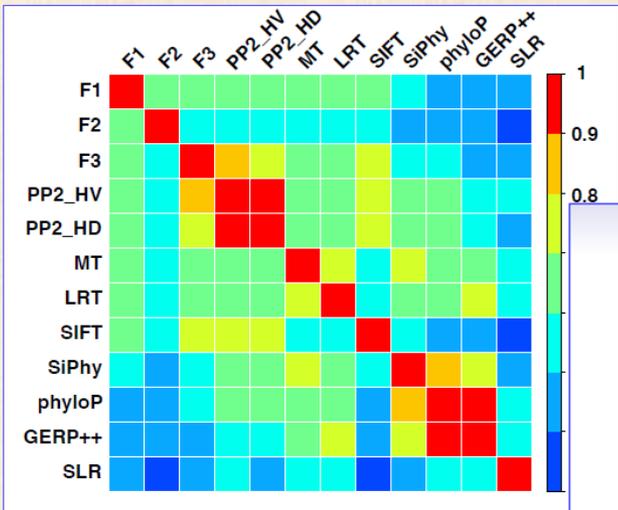
**more than a billion Facebook members, and two orders of magnitude more connections.**

**Knowledge about friends informs our knowledge about you.**

# CANCER PROSTATE

- 12 scores existants (variables de réponse) pour la maladie ne sont pas toujours en accord
- Données : 52 000 observations : 31 00 sujets sains + 21 000 sujets malades
- Algorithme **Forêts Aléatoires** intégrer les scores dans un critère de décision de maladie

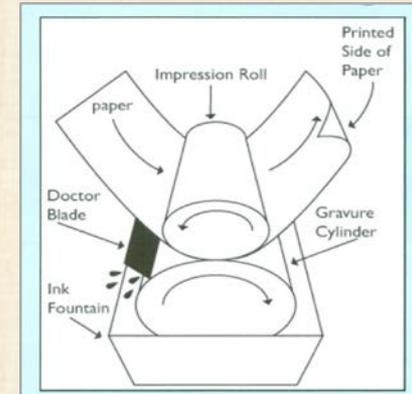
## matrice de corrélations



# IMPRIMERIE

combinaison des 2 approches : data mining + planification d'expérience (DOE)

**Example** printing industry - process description  
**Problem** defect on cylinder = « banding » image of poor quality occurring 40% of time  
**Action** stop production – repair cylinder many hours - cost 10 000\$ per incident  
**Project** what conditions lead to banding?  
**Data** 540 observations x 39 variables Y = band occurred (red)  
 X : 11 categorical var (blue) + 17 continuous var (green)

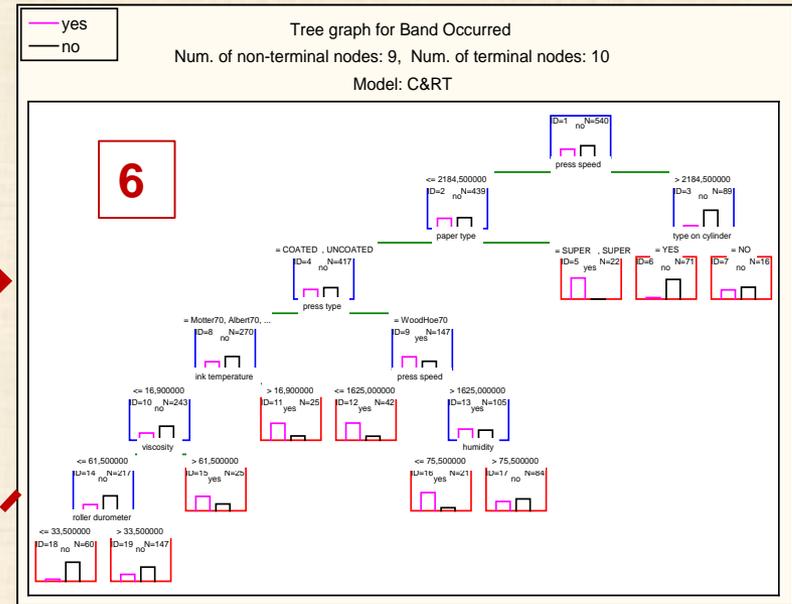
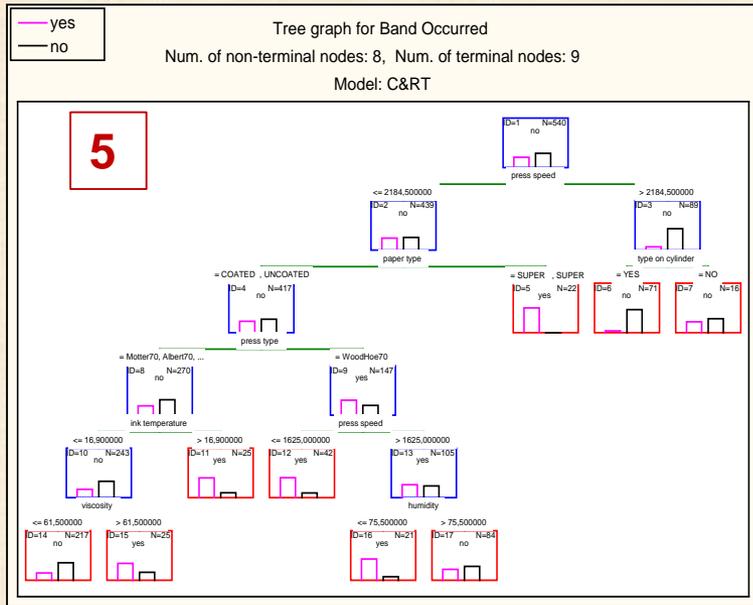


## data

	Year	Month	Day	Job Number	Cylinder No	Customer	Y band occurred	grain screened	proof on ctd ink	paper type	ink type	solvent type	type on cylinder	press type	press	cylinder size	location	plating tank
1	1990	03	30	23040	X750	GUIDE POSTS	yes	YES	YES	UNCOATED	UNCOATED	LINE	NO	Motter94	821	TABLOID		
2	1990	04	09	34683	G467	ECKERD	no	NO	YES	COATED	COATED	LINE	YES	WoodHoe70	815	TABLOID	North US	1910

	proof cut	viscosity	caliper	ink temperature	humidity	roughness	blade pressure	varnish pct	press speed	ink pct	solvent pct	wax	hardener	roller durometer	current density	anode space ratio	chrome content
1	50,0	59	0,33	14,5	71	0,63	20	11,1	1650	55,5	33,3	2,5		40			100
2	40,0	38	0,30	16,0	92	0,63	25	11,1	1600	53,8	45,2	2,5		30	33	100,0	100

**Phase 1 : CRT utilisé pour identifier 8 variables input critiques**  
**Phase 2 : Planification une expérience pour modéliser et optimiser**



**8 critical controllable input variables (X) identified**

1. press speed
2. paper type
3. type on cylinder
4. press type
5. ink temperature
6. grain screened
7. viscosity
8. humidity

**Follow up study DOE**

**Design Of Experiment**  
 8 input X variables  
 24 runs - new data on Y  
 Model Y with X then  
 optimal values of X found  
 such that Y = yes (banding)  
 occurs **4,5% now**  
 vs. **40% before**

## MÉGADONNÉES : défis associés à des problèmes statistiques

- **Ethique** : utilisation et liaison de données personnelles, assurer la confidentialité voir General Data Protection Regulation (GDPR) de UE (mai 2018)
- **Mégadonnées** : seulement un échantillon à un temps particulier d'intérêt dans un processus – pas un échantillon aléatoire – pas toutes les données !
- **Qualité des données** : erreurs, omission, biais, censures, données manquantes, duplication, erreurs de mesure. observations atypiques, **VARIABLES MANQUANTES**, **hétérogénéité des données ! pourquoi pas le SPC ?**
- **Visualisation des données** : développement de nouvelles procédures graphiques
- **Fausse associations** : accroissement associations fausses avec l'accroissement de la taille de l'échantillon - habileté à trouver des variées relations causales **correlation n'est pas cause !**
- **Development de méthodes statistiques valides** pour résoudre le problème de tester un grand nombre d'hypothèses simultanées
- **Development de stratégies statistiques valides** pour la réduction du fléau de la dimensionalité / selection de variables **curse of dimensionality !** data sparse out as the dimensionality increases
- **Réplication des résultats** : est-ce que des expériences indépendantes visant les mêmes questions produiront des résultats cohérents ?
- **Reproductibilité du résultat** : habileté à recalculer les résultats avec les mêmes données
- **Généralisation** : interprétation d'une étude exploratoire comme une étude prédictive

## Conclusions et défis

- **Les décisions basées sur l'intuition sont chose du passé; elles doivent reposer sur les données.**
- **Les mégadonnées sont là pour rester; elles impacteront tous les domaines de l'activité humaine ; l'âge d'or de la statistique est maintenant.**
- **Les principes statistiques et la rigueur sont nécessaires pour justifier le saut entre les données et la connaissance scientifique.**
- **Le manque d'expertise en statistique peut conduire à des erreurs fondamentales.**
- **Une grande quantité de données combinées à des analyses sophistiquées ne garantit pas le succès.**
- **Les données historiques n'assurent pas la performance future.**
- **Les éléments clés pour l'exploitation réussie des mégadonnées et le développement de la science sont la rigueur et les principes statistiques.**
- **La statistique, les mégadonnées, les algorithmes de la science données sont des aides pour penser et non pas des remplacements.**
- **L'utilisation des connaissances du domaine d'application est absolument nécessaire pour aider à définir le problème, appuyer le plan de collecte des données et guider l'analyse des résultats et leur interprétation.**

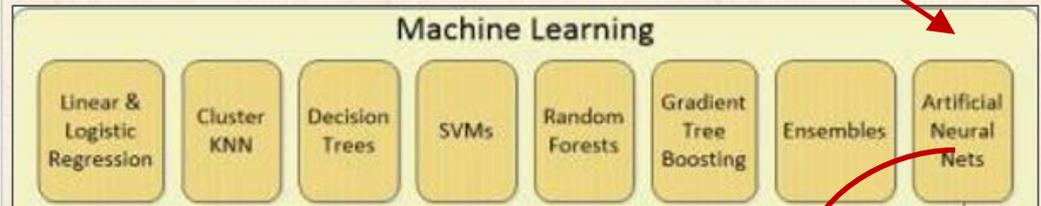
# Rôle pour la statistique en IA ?

Quelques éléments sur les réseaux de neurones ...

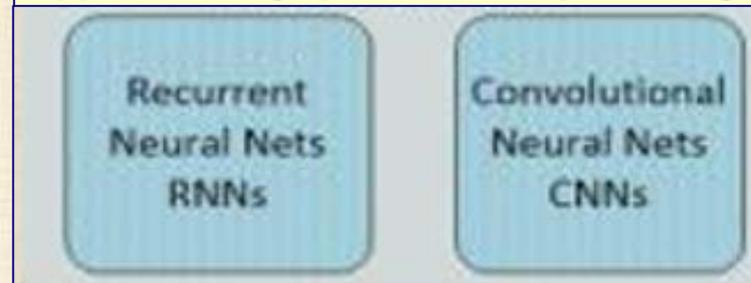
## Algorithmes du ML

Data Mining	Class Regression Trees (CRT)
Data Miner Recipes	Bosting (bootstrap)
General Classification/Regression Tree Models	Ensembles
General CHAID Models	Random Forests
Interactive Trees (C&RT, CHAID)	GAM
Boosted Tree Classifiers and Regression	MARSplines
Random Forests for Regression and Classification	Clustering
Generalized Additive Models	Bayesian Networks
MARSplines (Multivariate Adaptive Regression Splines)	<b>Automated Neural Networks</b>
Cluster Analysis (Generalized EM, k-Means & Tree)	Support Vector Machine (SVM)
Automated Neural Networks	Text Mining
Machine Learning (Bayesian, Support Vectors, K-Nearest)	Web Crawling
Independent Components Analysis	Rapid Deployment (PMML)
Text & Document Mining	Optimal Binning
Web Crawling, Document Retrieval	Stepwise Model Builder
Association Rules	Process Optimization
Sequence, Association, and Link Analysis	
Rapid Deployment of Predictive Models (PMML)	
Model Converter	
Goodness of Fit, Classification, Prediction	
Feature Selection	
Optimal Binning for Predictive Data Mining	
Weight of Evidence	
Stepwise Model Builder	
Interactive Drill Down	
Process Optimization	

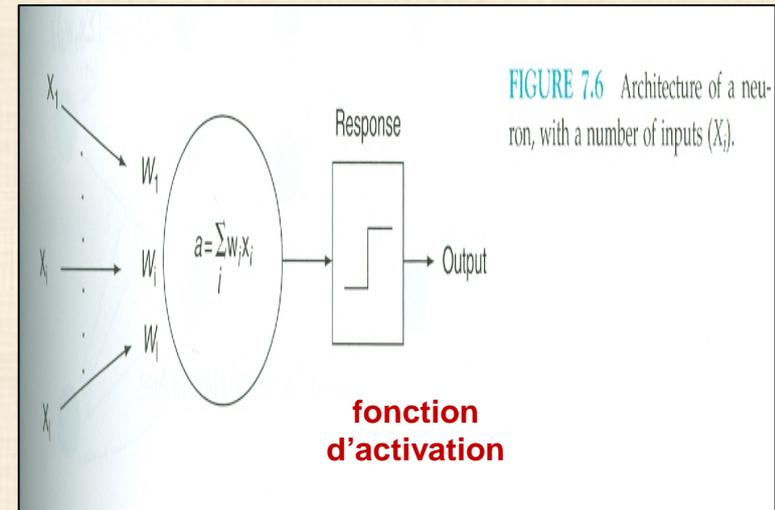
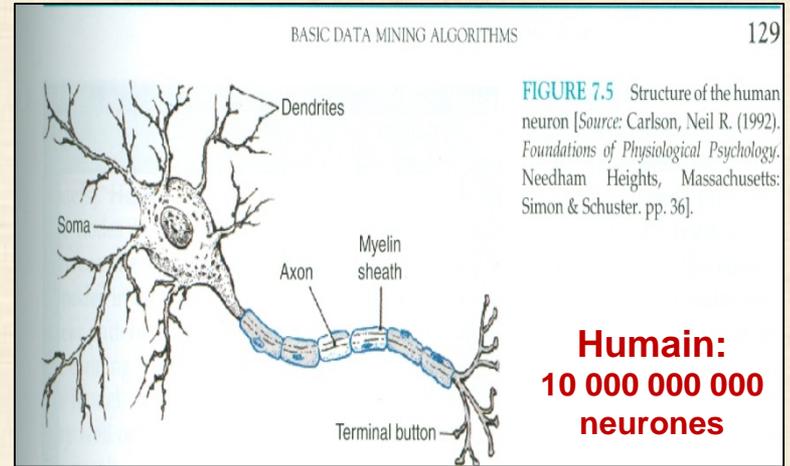
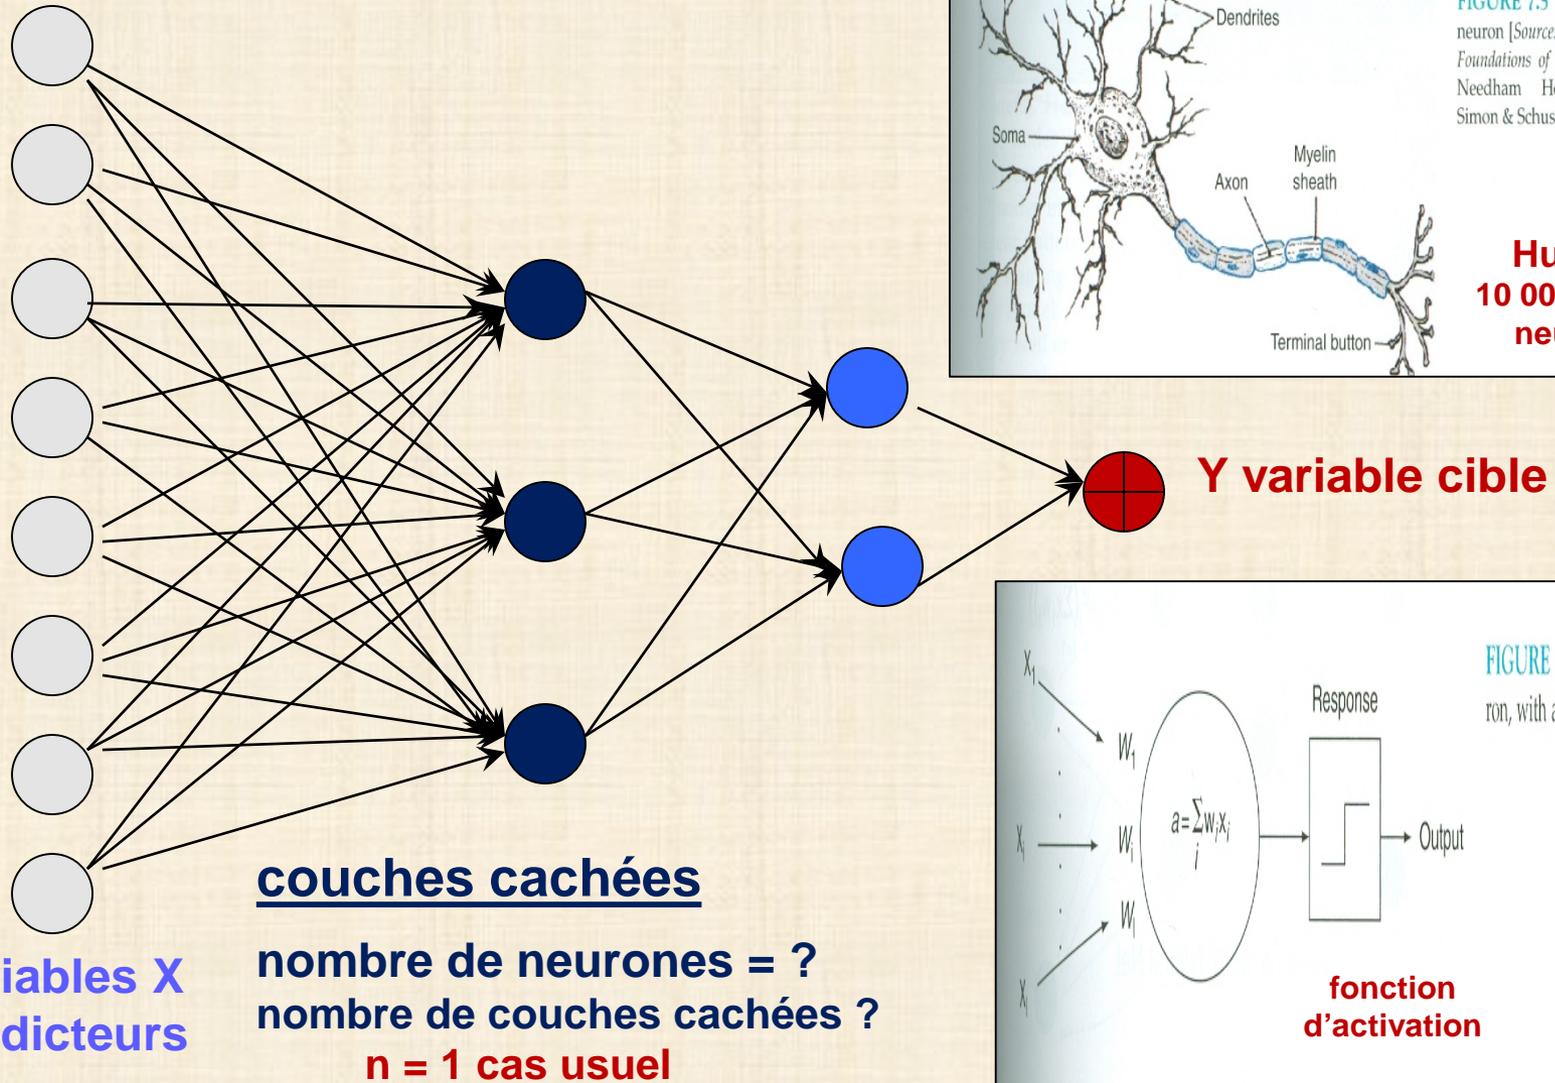
## Automated Neural Networks



## apprentissage profond : deep learning



# Base des Réseaux Neurones



source: Nisbet et all p.129

# Types de réseaux de neurones

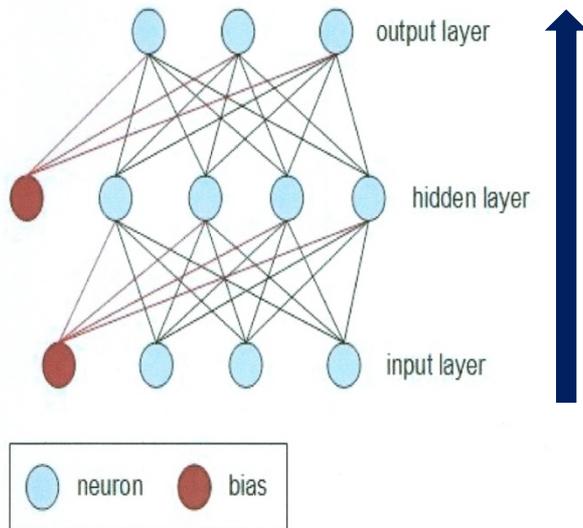
## RBF Radial Basis Function

### MLP Multi Layer Perceptron

SANN Overviews - Network Types

SANN Overviews - Network Types

The Multilayer Perceptron Neural Networks

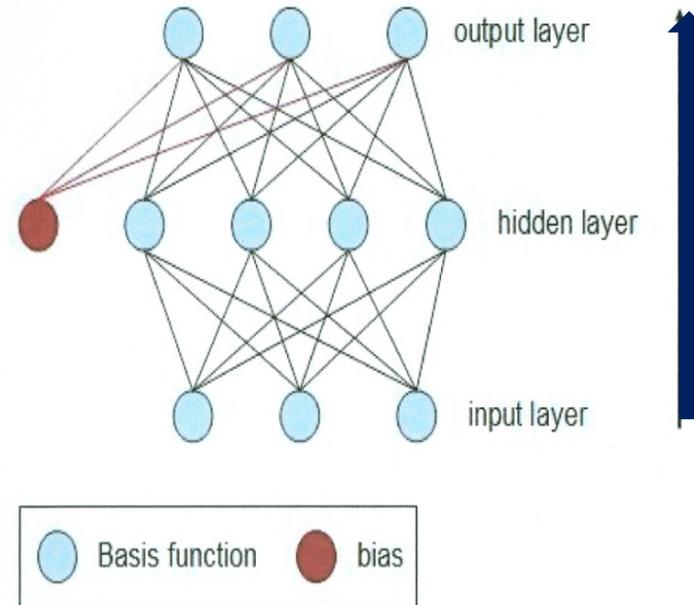


A schematic diagram of a fully connected MLP2 neural network with three inputs, four hidden units (neurons), and three outputs. Note that the hidden and output layers have a bias term. Bias is a neuron that emits a signal with strength 1.

Source : Statistica

type le plus employé

The Radial Basis Function Neural Networks

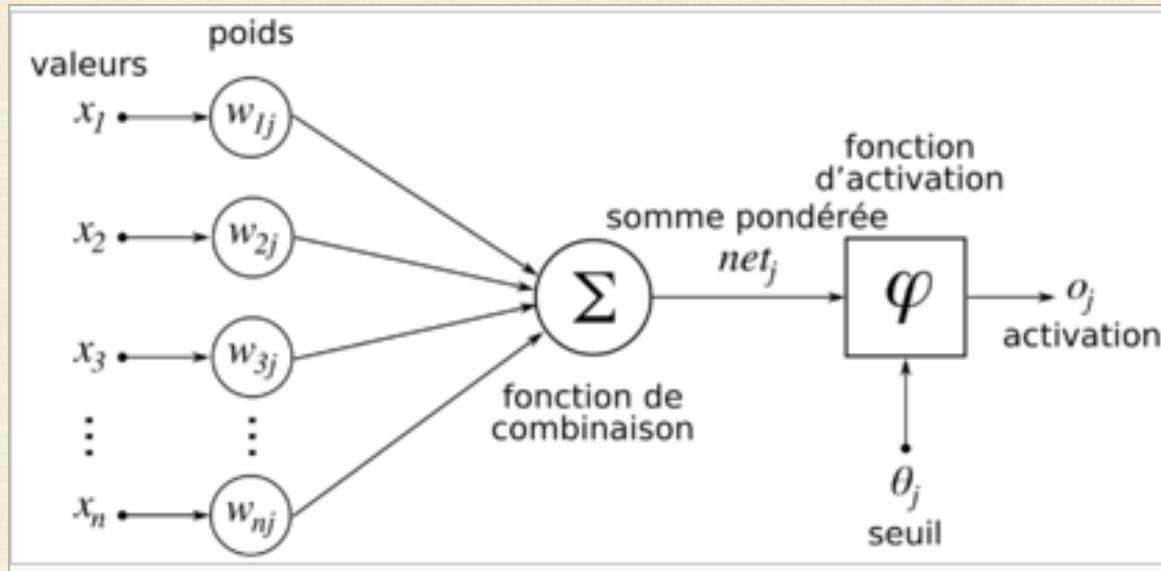


A schematic diagram of an RBF neural network with three inputs, four radial basis functions and 3 outputs. Note that, in contrast to MLP networks, it is only the output units that have a bias term.

type pas très recommandé  
pour des inputs catégoriques

# Éléments des réseaux de neurones

## Perceptron Multi Couches



- Les solutions ne sont pas calculées directement : un algorithme d'optimisation calcule itérativement les solutions
- Le modèle est construit sur une base d'apprentissage et testé à chaque étape sur une base de validation
- L'apprentissage du réseau s'effectue en mode supervisé : les poids  $W_i$  et les valeurs  $V_i$  synaptiques des neurones de chaque couche (cachée) sont évalués pour minimiser une fonction d'erreurs
- Les entrées (variables explicatives) et sorties (variables à expliquer) du réseau sont connues

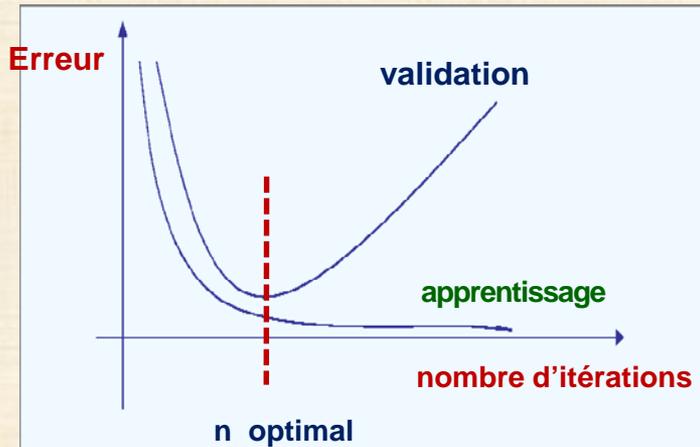
# Éléments des réseaux de neurones

## Interprétation modèles et traitements

- valeur  $Y_j$  d'un individu  $j$  est une fonction
- composée des valeurs prises par  $X_i$
- **fonctions d'activation** .....
- poids  $W$  associés aux neurones
- **Évaluation complexe + présence de colinéarités**  
variables, poids, nombre de couches, nombre de neurons  
éviter le « **sur apprentissage** »

**fonctions  
d'activation**

Function	Definition
Identity	$x$
Logistic sigmoid	$\frac{1}{1 + e^{-x}}$
Hyperbolic tangent	$\frac{e^x - e^{-x}}{e^x + e^{-x}}$
Exponential	$e^{-x}$
Sine	$\sin(x)$
Softmax	$\frac{\exp(a_i)}{\sum \exp(a_i)}$
Gaussian	$\frac{1}{\sqrt{2\pi\sigma}} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right]$



$y_i$  : prédictions     $t_i$  : target

**Erreur : Sum Of Square**  
 $= E_{SOS} = \sum (y_i - t_i)^2$

$t_i$  continue

**Erreur : Cross Entropy**  
 $= E_{CE} = -\sum t_i \ln(y_i / t_i)$

$t_i$  catégorique

### Algorithmes

- BFGS Broyden-Fletcher-Goldfarb-Shanno
- Scaled Conjugate Gradient

## Commentaires sur les réseaux de neurones

- performance bonne à très bonne en général
- boîte noire : difficile à interpréter
- analyse de sensibilité possible mais limitée
- utiles domaine des données non structurées

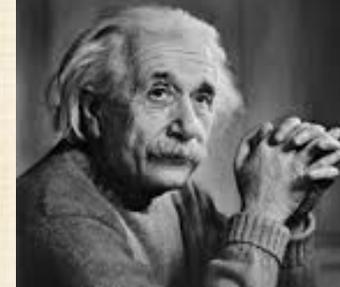
INPUT A	RESPONSE B	APPLICATION
Picture	Are there human faces? (0 or 1)	Photo tagging
Loan application	Will they repay the loan? (0 or 1)	Loan approvals
Ad plus user information	Will user click on ad? (0 or 1)	Targeted online ads
Audio clip	Transcript of audio clip	Speech recognition
English sentence	French sentence	Language translation
Sensors from hard disk, plane engine, etc.	Is it about to fail?	Preventive maintenance
Car camera and other sensors	Position of other cars	Self-driving cars

sortie en C / C++ interprétation ?

```
double 4bar_linkage2_sta_in_RéseauxNeurones_1_MLP_5_10_4_input_hidden_weights[10][5]=
{
{2.02837435462445e-003, -9.19300736782718e-002, -8.33394542388945e-003, 5.96815120368463e-003, -9.72173081422972e-001 },
{-4.10541254965628e+001, -1.57048702434030e+001, 7.24298697308776e+000, 7.54136136116508e-001, 7.23575930276387e+000 },
{-4.27953674542435e-003, 5.22558713365225e-002, -2.02630063174860e-002, 3.55526806539767e-001, 4.38086865729618e-001 },
{8.36988375566669e-003, 6.51471505482633e-002, -1.87374240864233e-005, -2.93668874571122e-002, 4.28066974047903e+000 },
{-4.51758787016232e-003, -1.65295098364779e-002, -9.55504020044409e-003, 3.37743795686801e-002, -3.92503675526061e+000 },
{8.09715832028303e-003, 1.40380167160264e-001, -5.11574576386343e-002, 4.63819910138810e-002, -4.1437759972541e+000 },
{2.64573937244475e-002, 1.38171451159571e-001, -5.05816891278269e-002, 3.03640534484363e-002, -4.99478506036909e+000 },
{3.56819229312110e+001, -1.44427879618125e+001, 5.05330645369423e+000, 6.79476064151221e+000, -1.20589227870316e+001 },
{1.63237325776004e-002, 9.93417867044676e-002, -4.79318114375762e-003, -2.87432514207203e-002, 3.81634117448330e+000 },
{5.06016857284542e-003, -6.65190232893867e-003, 1.98066912357954e-002, -3.29635020222122e-002, 3.65513674103006e+000 }
};
```

If you can't explain it **simply**, you don't understand it well enough.

– Albert Einstein

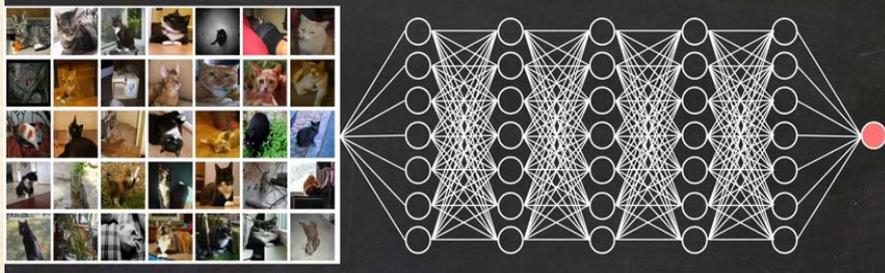
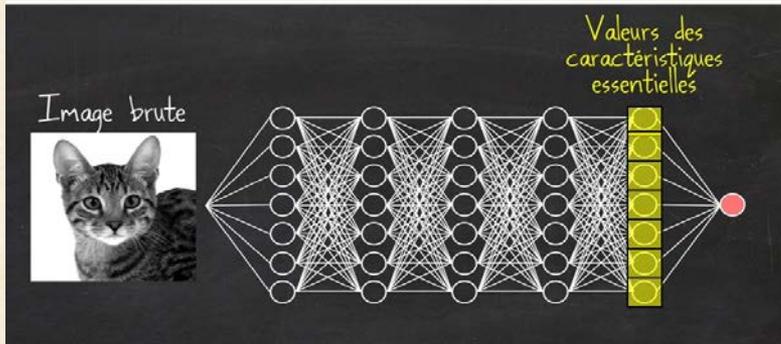
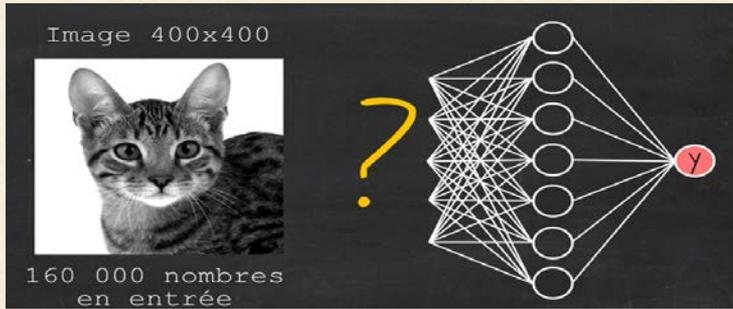


# IA = réseaux neurones multi couches (réseau profond)

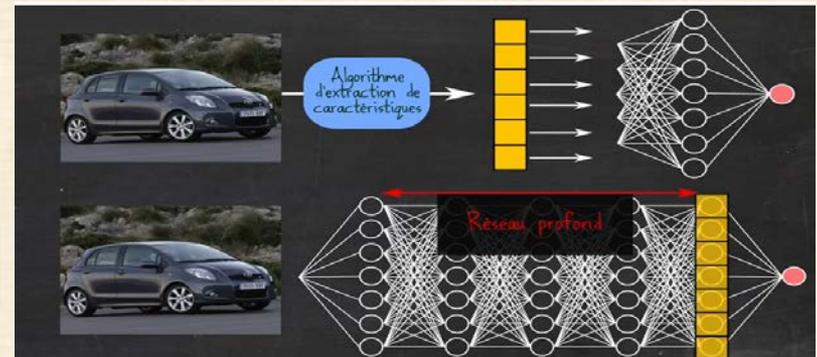
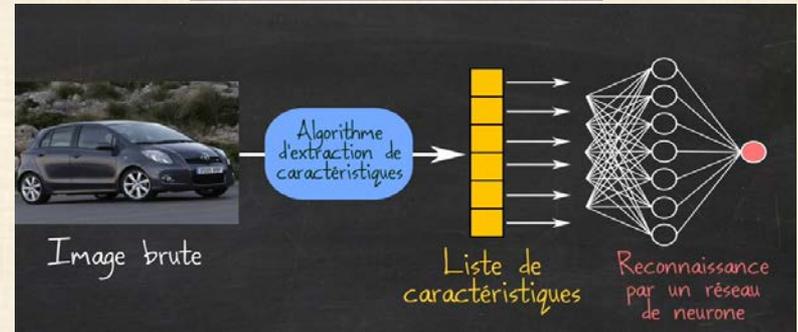
apprentissage profond : deep learning = IA

Recurrent  
Neural Nets  
RNNs

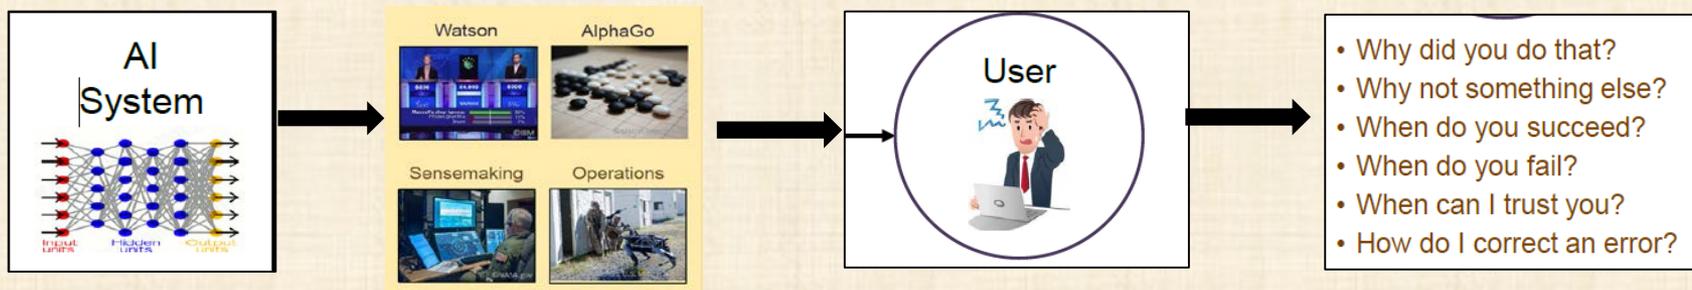
Convolutional  
Neural Nets  
CNNs



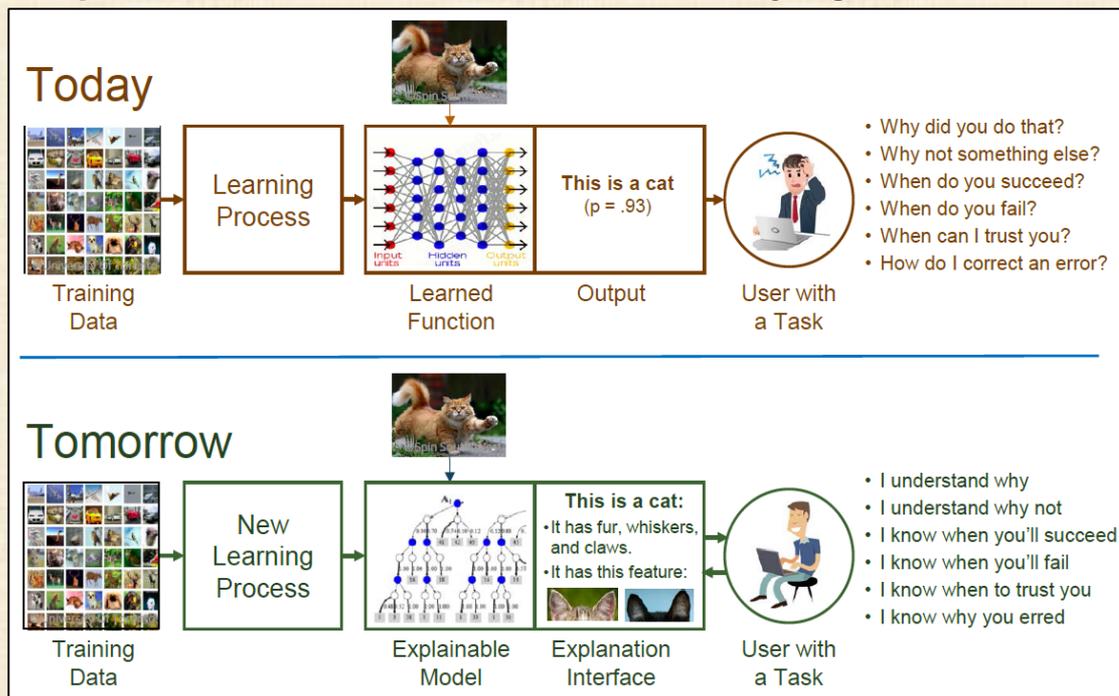
découverte des caractéristiques communes :  
hauteur, largeur, nombre de roues, ...  
algorithmes : RNN CNN ..



# mais la boîte noire est encore plus fortement incompréhensible ...



## Explainable AI (XAI) - What Are We Trying To Do?

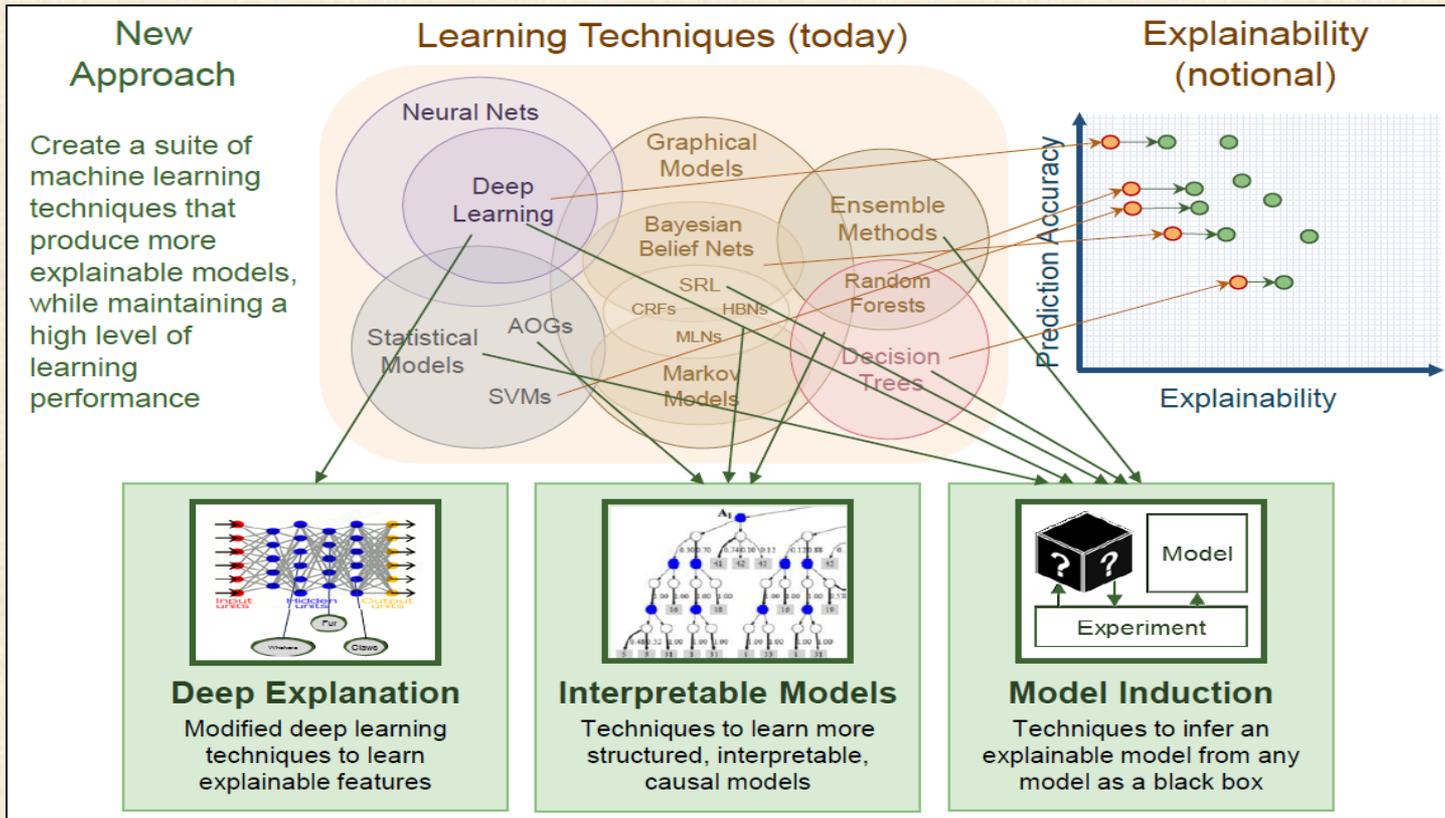


## REMARQUE

**l'explication de l'action / décision va au-delà de la seule prédiction (pensons traitement médical)**

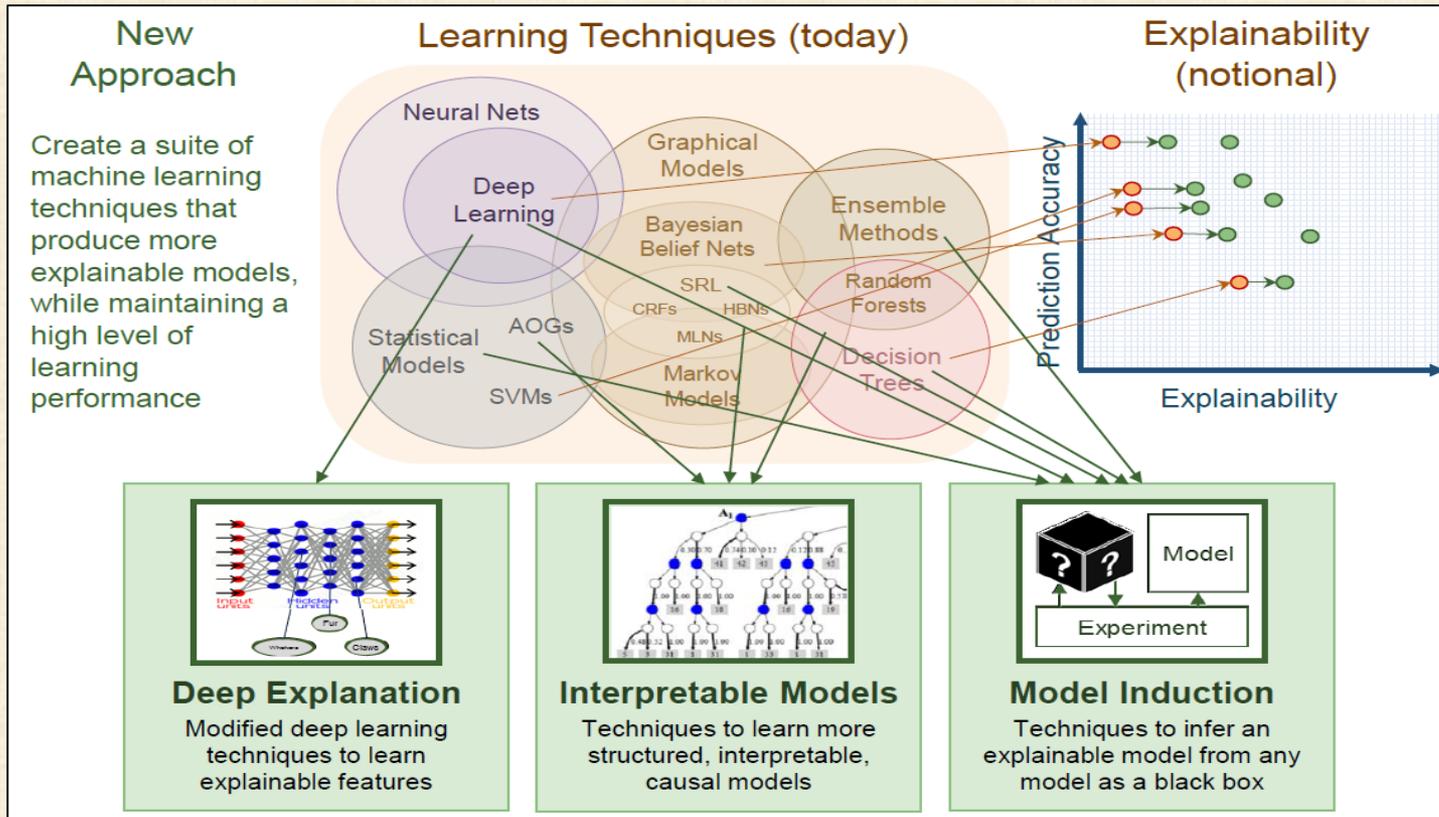
**la connaissance scientifique va encore bien plus loin ...**

**la vraie intelligence artificielle ce n'est pas celle qui est abondamment galvaudée aujourd'hui ...**



**Rôle de la statistique dans le AI d'aujourd'hui de demain ?**

**OUI c'est .....**



**Rôle de la statistique dans le AI d'aujourd'hui de demain ?**

**OUI c'est ..... l'analyse de sensibilité et de robustesse des systèmes AI particulièrement : médical ... sécurité ...**

# QUESTIONS

**Q1 : quel est l'avenir de la science statistique ?**

**Q2 : le métier de statisticien est-il en train de changer ?**

**Q3 : comment doit-on former les futurs statisticiens ?**

**Q4 : l'inférence statistique a-t-elle encore une place dans l'ère des mégadonnées ?**

**Q5 : quelle contribution la statistique peut-elle apporter dans le domaine de l'intelligence artificielle ?**

**Q6 : comment faire pour rehausser l'appréciation et la reconnaissance du rôle du statisticien dans la société ?**

**Q7 : .... vos questions ....**

# RÉPONSES

**R1 :**

**R2 :**

**R3 :**

**R4**

**R5 :**

**R6 :**

**R7 : .... vos questions ....**

## QUELQUES CONCLUSIONS

- Tout modèle statistique fournit une représentation simplifiée du système dont on a obtenu des données.
- **La statistique est avant tout un état d'esprit avec un grand coffre d'outils.**
- La modélisation automatisée est risquée au-delà d'un certain niveau.
- **La connaissance du domaine d'application est essentielle.**
- Un statisticien professionnel habilité à **concevoir une étude statistique**: c'est la caractéristique principale d'un statisticien.
- **Toute personne qui entreprend une étude statistique devrait absolument chercher à collaborer avec un statisticien professionnel pour assurer la plus grande qualité de l'étude.** L'expert d'un domaine d'application ne doit pas être le seul responsable de la planification d'une étude statistique. **Le statisticien doit être partie prenante dès le début.**
- Un statisticien professionnel n'est pas un simple technicien qui analyse des données qu'on lui fournit.
- **Dans une étude primaire, les données sont collectées avec un objectif (hypothèse) spécifique de départ.**
- Dans une étude secondaire, on analyse des données qui furent collectées avec d'autres objectifs initialement.
- **Il ne faut pas croire que l'analyse de mégadonnées rend inutile la démarche inférentielle pour l'évaluation des risques.**
- L'analyse statistique inférentielle apporte une contribution essentielle en intelligence artificielle pour étudier la robustesse des systèmes développés en AI.

## QUELQUES RÉFÉRENCES

-  12 Useful Things to Know About Machine Learning.pdf
-  Adadi-Explainable AI.pdf
-  Andrew NG-What Artificial Intelligence Can and Can do.pdf
-  Benjio&all-Deep Learning.pdf
-  Breiman-Statistical Modeling-2 cultures.pdf
-  Choudhary-Interpreting predictive models with Skater.pdf
-  Darpa-Explainable AI-2017.pdf
-  Darpa-Explainable AI.pdf
-  DARPA-xAI-eXplainable AI.pptx
-  Donoho-50YearsDataScience.pdf
-  Efron&Hastie-Computer Age Statistical Inference.pdf
-  Friedman-DataMining&Statistics.pdf
-  Gartner-Aplying-AI-in-the-enterprise.pdf
-  Google-Explainable AI.pdf
-  Granville-Differences Stat DataScience AI.pdf
-  Holzinger-Explainable AI in medecine.pdf
-  Holzinger-Explainable AI-the new 42.pdf

-  JPMorgan-Guide To AI-2018.pdf
-  Julia-IA machine à fantasques.pdf
-  Lescue-Explainable AI.pdf
-  LIME- model explanation proces.pdf
-  LIME on GitHub.pdf
-  McKinsey-Artificial-Intelligence-2018.pdf
-  Michael Jordan-The AI Revolution Hasn't Not Happend Yet.pdf
-  Molnar-Interpretable Machine Learning.pdf
-  Molnar-interpretable-machine-learning-2.pdf
-  Monaco-Explainable AI.pdf
-  Nat Acad Press-Robust Machine Learning.pdf
-  Natale-software\_is\_narrative.pdf
-  O'Reilly-ML-interperatability.pdf
-  O'Reily-AI&ML.pdf
-  Sameck-Explainable AI.pdf
-  Sarkar-Explainable AI.pdf



2900, boul. Édouard-Montpetit  
2500, chemin de Polytechnique  
Montréal (Québec) Canada H3T 1J4  
**Adresse postale**  
C.P. 6079, succ. Centre-ville  
Montréal (Québec) Canada H3C 3A7

### BERNARD CLÉMENT, PhD

Professeur titulaire  
Département de mathématiques et de génie industriel  
Pavillon principal, bureau A-520.30  
bernard.clement@polymtl.ca ■ www.polymtl.ca  
Tél. : 514 340-4711 poste 4944 ■ Cell. : 514-677-7896



2900, boul. Édouard-Montpetit  
2500, chemin de Polytechnique  
Montréal (Québec) Canada H3T 1J4  
**Mailing Address**  
P.O. Box 6079, Station Centre-ville  
Montréal (Québec) Canada H3C 3A7

### BERNARD CLÉMENT, PhD

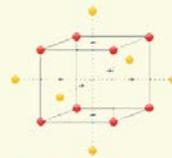
Full Professor  
Department of Mathematics and Industrial Engineering  
Main Building, office A-520.30  
bernard.clement@polymtl.ca ■ www.polymtl.ca  
Tel. : 514 340-4711 ext. 4944 ■ Cell: 514 677-7896

## Bernard Clément PhD

### Génistat Conseils

Courriel : [genistat@sympatico.ca](mailto:genistat@sympatico.ca)  
Tel : (514) 677-7896

Département de mathématiques  
et de génie industriel  
École Polytechnique de Montréal  
Tél. : (514) 340-4711 poste 4944  
Courriel : [bernard.clement@polymtl.ca](mailto:bernard.clement@polymtl.ca)



## Bernard Clément, PhD

Statisticien

### Génistat Conseils

1205-80 Berlioz  
Verdun, QC  
Canada H3E 1N9

Cell : 514-677-7896  
[genistat@sympatico.ca](mailto:genistat@sympatico.ca)

Bernard Clément, PhD est professeur titulaire au département de mathématiques et de génie industriel de l'École Polytechnique de Montréal affiliée à l'Université de Montréal. Il possède plus de 30 années d'expérience en enseignement des méthodes de statistiques appliquées et en management de la qualité aux ingénieurs et scientifiques.

Il a fondé Génistat Conseils Inc., une firme de consultation spécialisée en design et analyse d'études statistiques. Son produit principal est le transfert d'expertise, de connaissance et de management pour l'amélioration de la qualité des produits et des procédés.

Sa liste de clients comprend IBM, Sidbec-Dosco, Noranda Research Center, Bolting Technology Council, Nortel, Institut de Recherche en Biotechnologie, Compagnie Générale des Eaux (Vivendi), Bell, Postes Canada, DALSA semiconducteurs, Cardianove, Wamex, Camoplast, CIRANO et plusieurs établissements de recherche.

Il est membre élu de l'International Statistical Institute et membre de American Society of Quality. Il a été vice-président du Canada Quality Council, administrateur de l'Association québécoise de la Qualité (Mouvement Québécois Qualité), et il fut président de la Société Statistique de Montréal. Il a été membre du comité ISO du Standard Council du Canada.

#### Consultation - recherche - formation

- Planification et analyse d'expériences industrielles (DOE)
- Maîtrise statistique des processus (SPC)
- Études statistiques appliquées: design, analyse, data mining
- Management de la qualité et Six Sigma
- Ingénierie robuste de Taguchi : design de produit et de procédé
- Logiciels statistiques : STATISTICA, MINITAB, JMP, SAS, DESIGN-EXPERT

#### Consultation - recherche - formation

- Planification et analyse d'expériences industrielles (DOE)
- Maîtrise statistique des processus (SPC)
- Études statistiques appliquées: design, analyse, data mining
- Management de la qualité et Six Sigma
- Ingénierie robuste de Taguchi : design de produit et de procédé
- Logiciels statistiques : STATISTICA, MINITAB, JMP, SAS, DESIGN-EXPERT

### Bernard Clément, PhD

Professeur titulaire | Mathématiques et génie industriel | Polytechnique Montréal

E [bernard.clement@polymtl.ca](mailto:bernard.clement@polymtl.ca) | O +1 514-340-4711 x 4944 | M +1 514-677-7896 | bureau A-520.30

2900, boul. Édouard-Montpetit, Campus de l'Université de Montréal

2500, chemin de Polytechnique, Montréal, QC, Canada H3T 1J4

Adresse postale : C.P. 6079, succ. Centre-ville, Montréal, QC, H3C 3A7

Enseignement : <http://www.groupe.polymtl.ca/mth6301>

Expertise : <http://www.polymtl.ca/expertises/clement-bernard>

CV : <http://www.groupe.polymtl.ca/mth6301/mth8301/PDF/Clement-CV.pdf>

#### Sites Internet

<http://www.groupe.polymtl.ca/mth6301>

<http://www.groupe.polymtl.ca/mth6301/MTH8302.htm>

<http://www.groupe.polymtl.ca/ind2501>

<http://www.groupe.polymtl.ca/mth6301/STATISTICA.htm>

<http://www.groupe.polymtl.ca/mth6301/JMP.htm>

Planification et analyse d'expériences

Modèles de régression et d'analyse de variance

Ingénierie de la qualité

STATISTICA

JMP