

BIG data

opportunités & stratégies

Raphaël Jolivet - février 2018

Sommaire

- **Introduction** : généralités
- Nouveaux **paradigmes** & nouveaux **métiers**
- **Stats / IA / machine learning**
- Utilisations pratiques
- Question de droit : **sécurité & vie privée**
- Stratégies

Introduction

BIG comment ?

- **1995** : 30 Gb
- **1997** : 2 Tb (x60)

Introduction

2014

	Bande passante / jour	Stockage
Facebook	600 Tb	300 Pb
Google	100.000 Tb	15,000 Pb
Twitter	100 Tb	?
NSA	29.000 Tb	10.000 Pb

1 Tb (Terabytes) = 1000 Gb

1 Pb (Petabytes) = 1000 Tb

Introduction

Evolution des usages

- **Réseau sociaux** : Crowd sourcing
- **Smartphones / IoT** : senseurs automatiques
- Massification d'internet :
3.4 milliards (40 % vs 1% en 1995)

Introduction

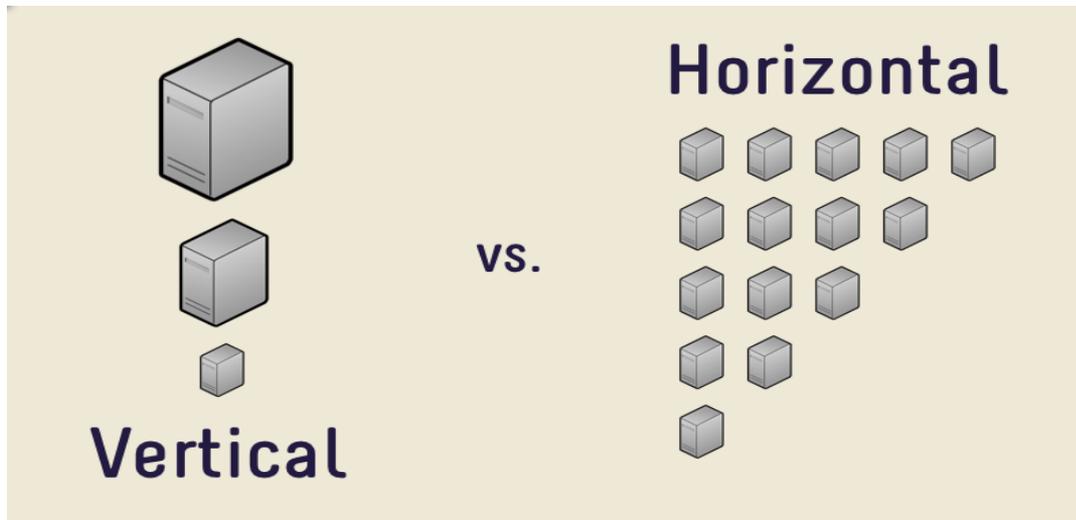
Evolution des technologies

- **Prix** du **stockage** de données
- **Centralisation** d'internet (GAFAM)
- **Virtualisation** des systèmes :
Cloud // IaaS (infrastructure as a service)
- Technologies de **stockage** / **calcul distribué**
- **APIs** (Wikipedia, Google, Facebook)
- **Horizontal** scaling

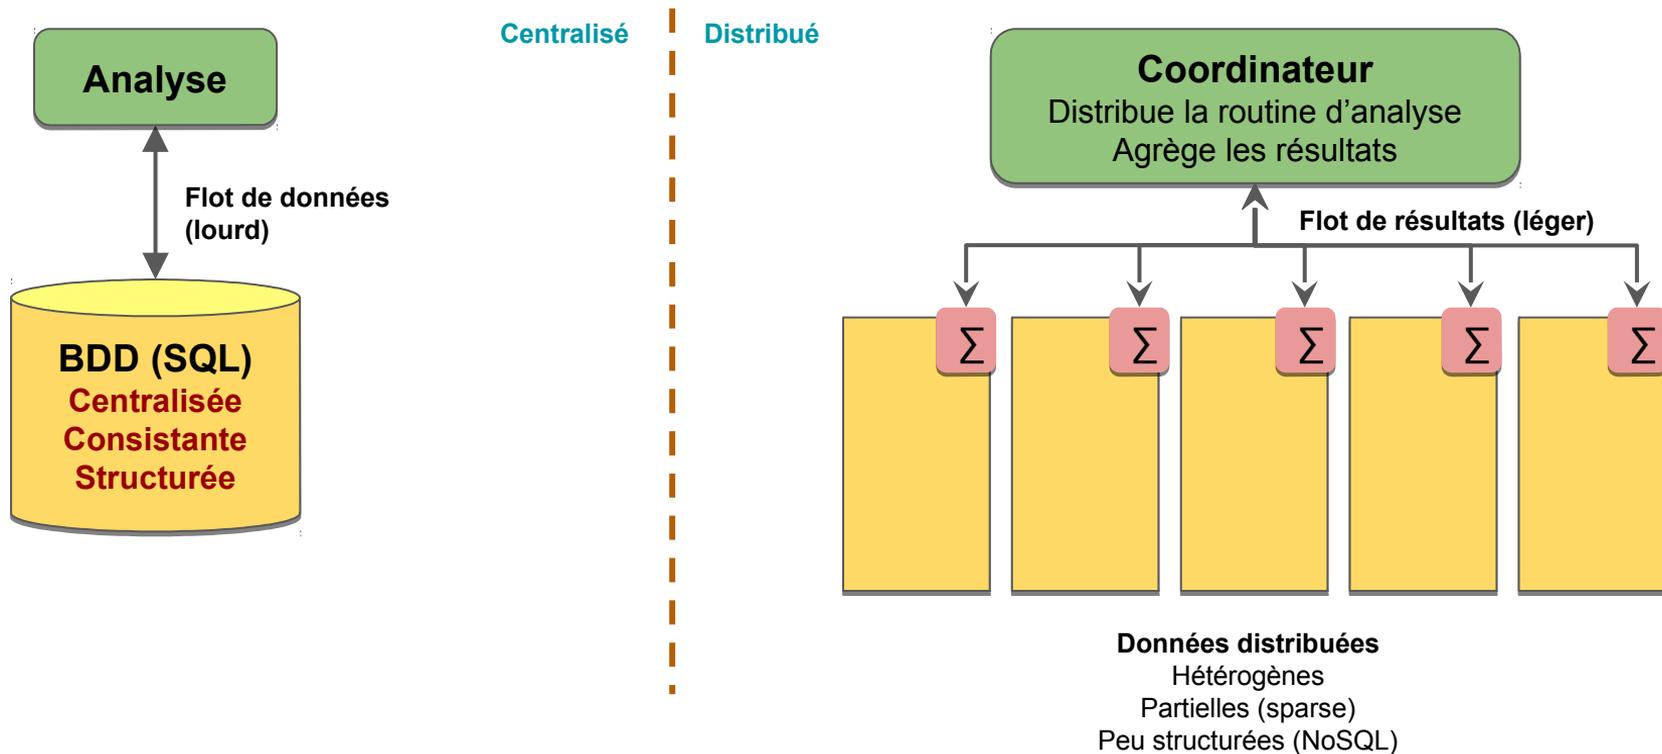
Nouveaux paradigmes : horizontal scaling

Scaling horizontal

- économique
- sans coupure
- sans limite de taille

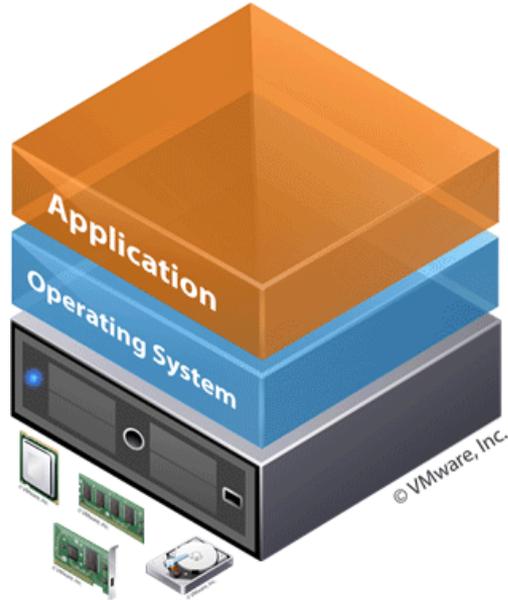


Nouveaux paradigmes : BDD

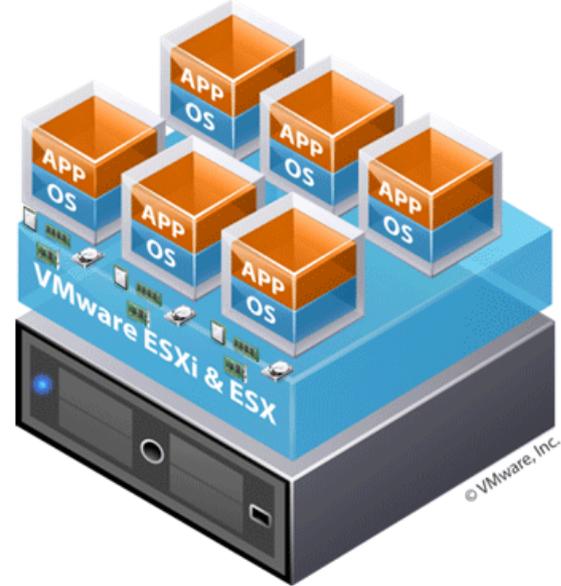


Nouveaux paradigmes : Virtualisation

Sans virtualisation



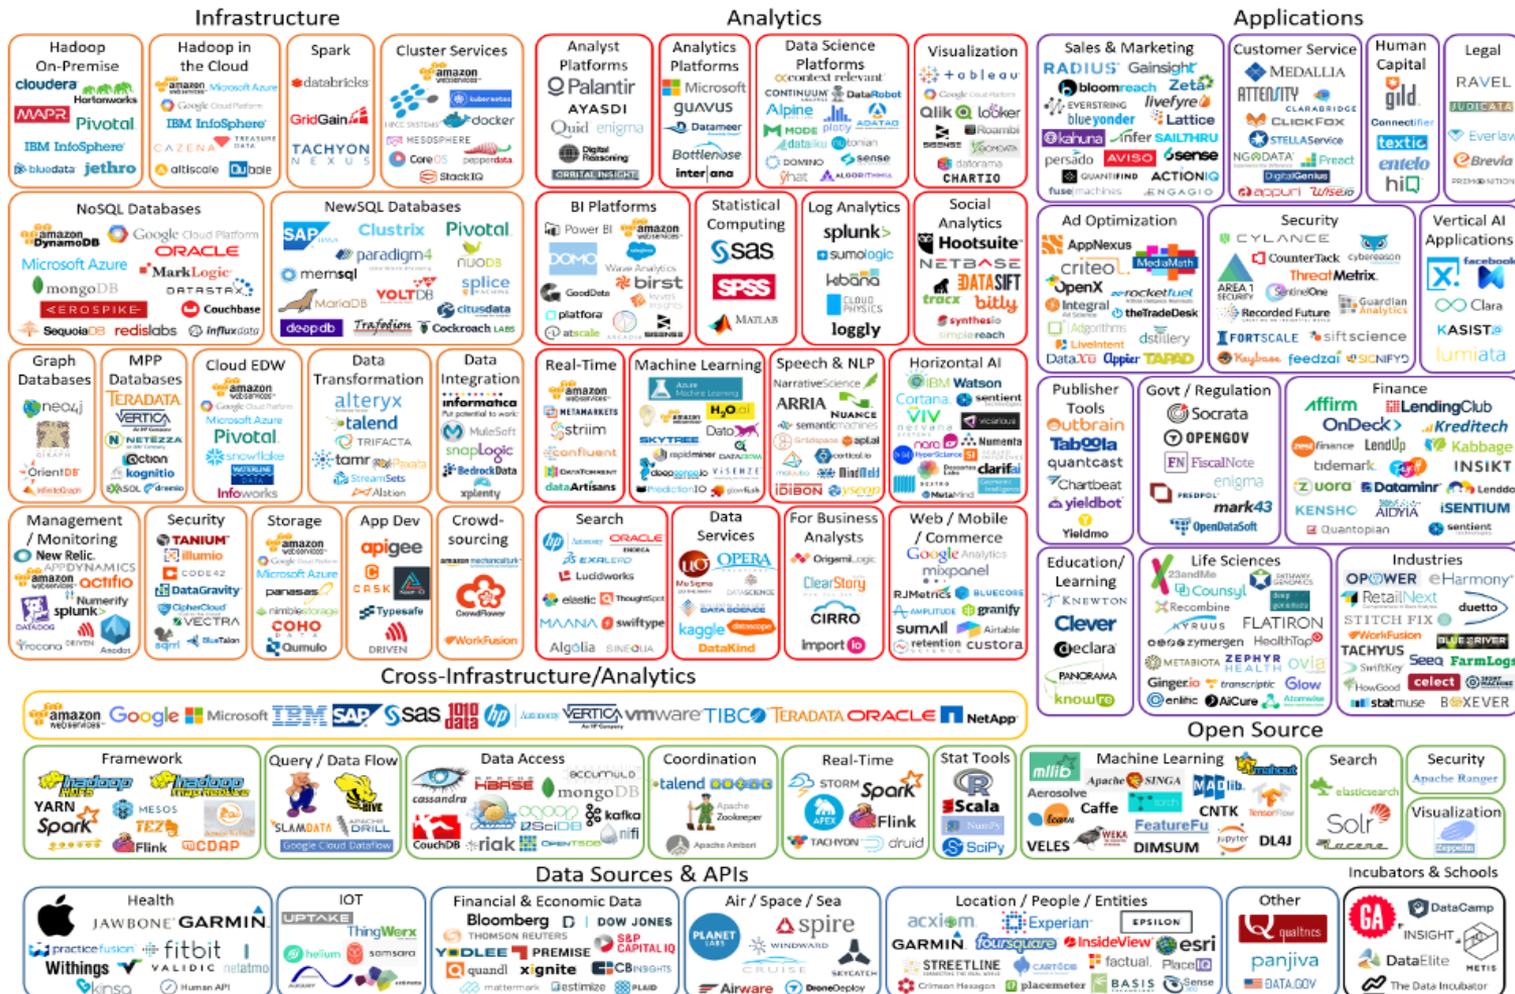
Avec virtualisation



Nouveaux paradigmes : Virtualisation

- **Isolation** des VMs ⇒ **Sécurité**
- **Décorrélation** physique / logique
- Adaptation à la **charge** (paiement **ressource * temps**)
- Provision rapide (qq **jours** ⇒ qq **minutes**)
- **Sauvegarde, clonage, migration** facile
- **Automatisation** de l'administration : **IaaS**

Big Data Landscape 2016 (Version 2.0)

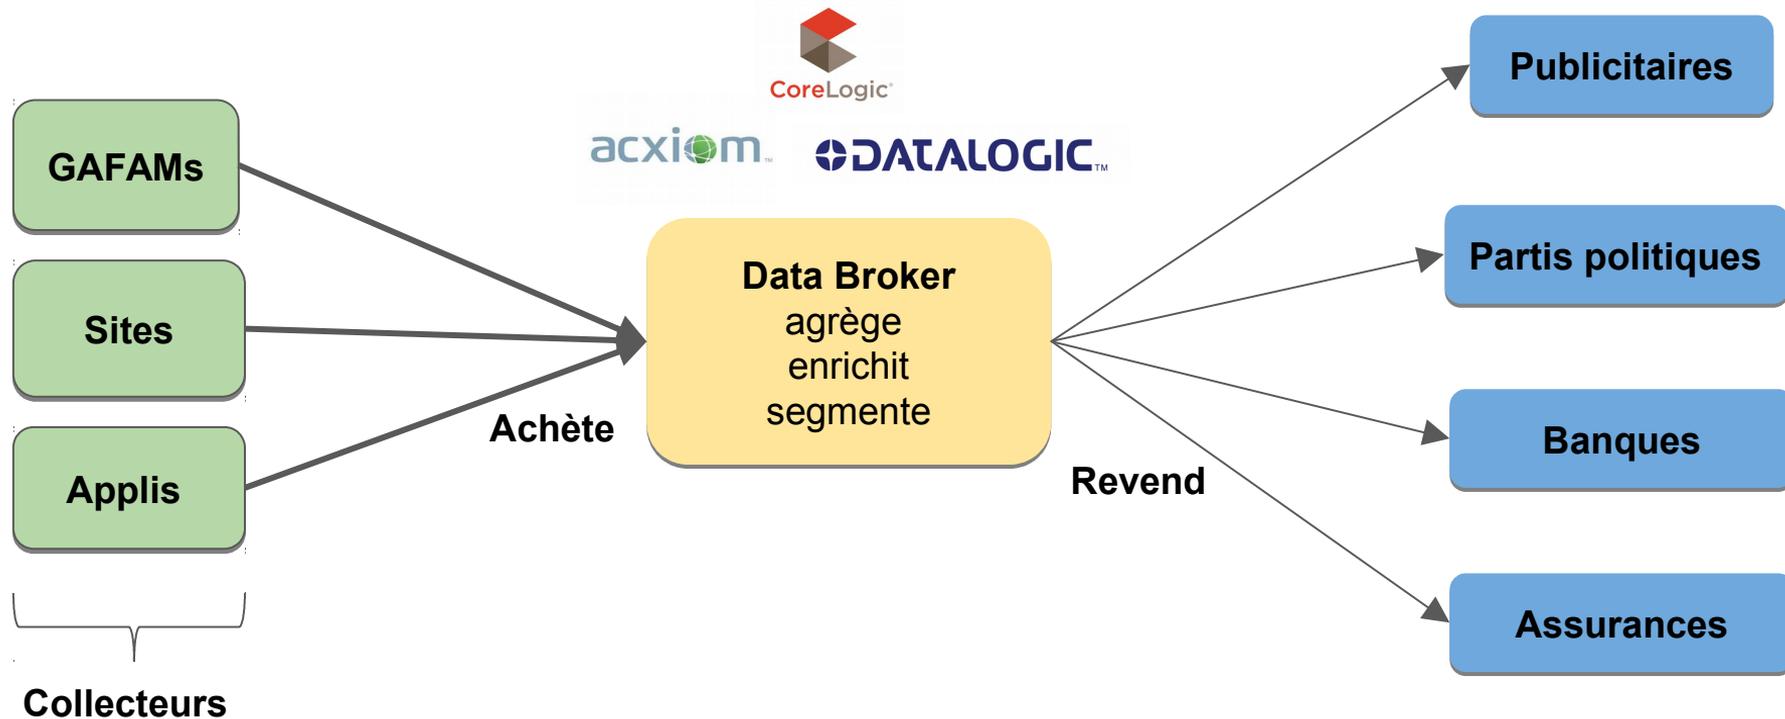


Nouveaux acteurs

- **Infrastructure / Cloud** : *Google, Amazon, Microsoft, OVH*
- **BDD distribuées, NoSQL** : *CouchDB, MongoDB, Hive*
- **Framework** : *Hadoop, Apache Spark*
- **Ecosystème fourni d'outils et d'applications**
- **Intégration** complexe
- **Domaine évoluant très vite**

⇒ **Distributions** : *Cloudera, Mapr*

Nouveaux acteurs : Les Data Brokers

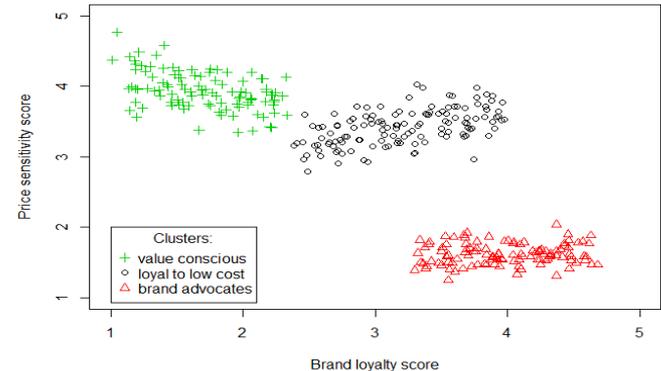
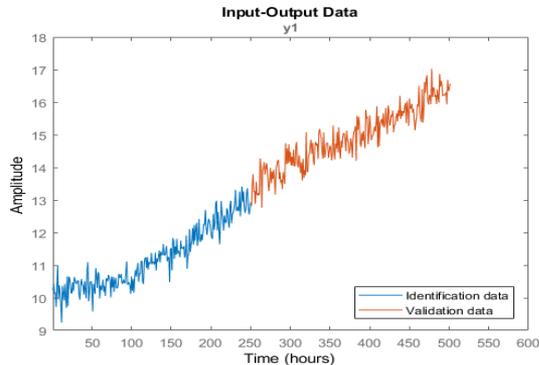
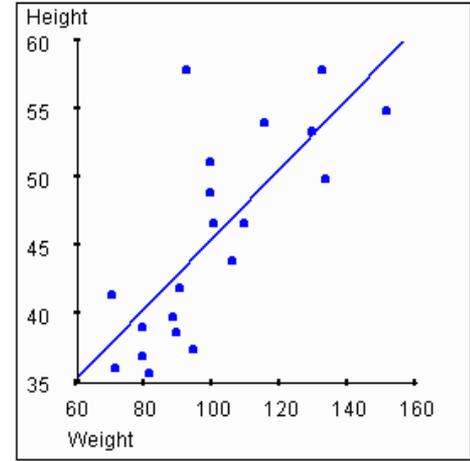


Nouveaux métiers

- Nouveaux langages : **Scala** (calcul parallèle, fonctionnel)
- **Spécialisations** en informatique
 - **Data analyst** : maths, stats
 - **Architecte de données**
 - **IA / Machine learning** :
“psychologues” de réseaux de neurones.

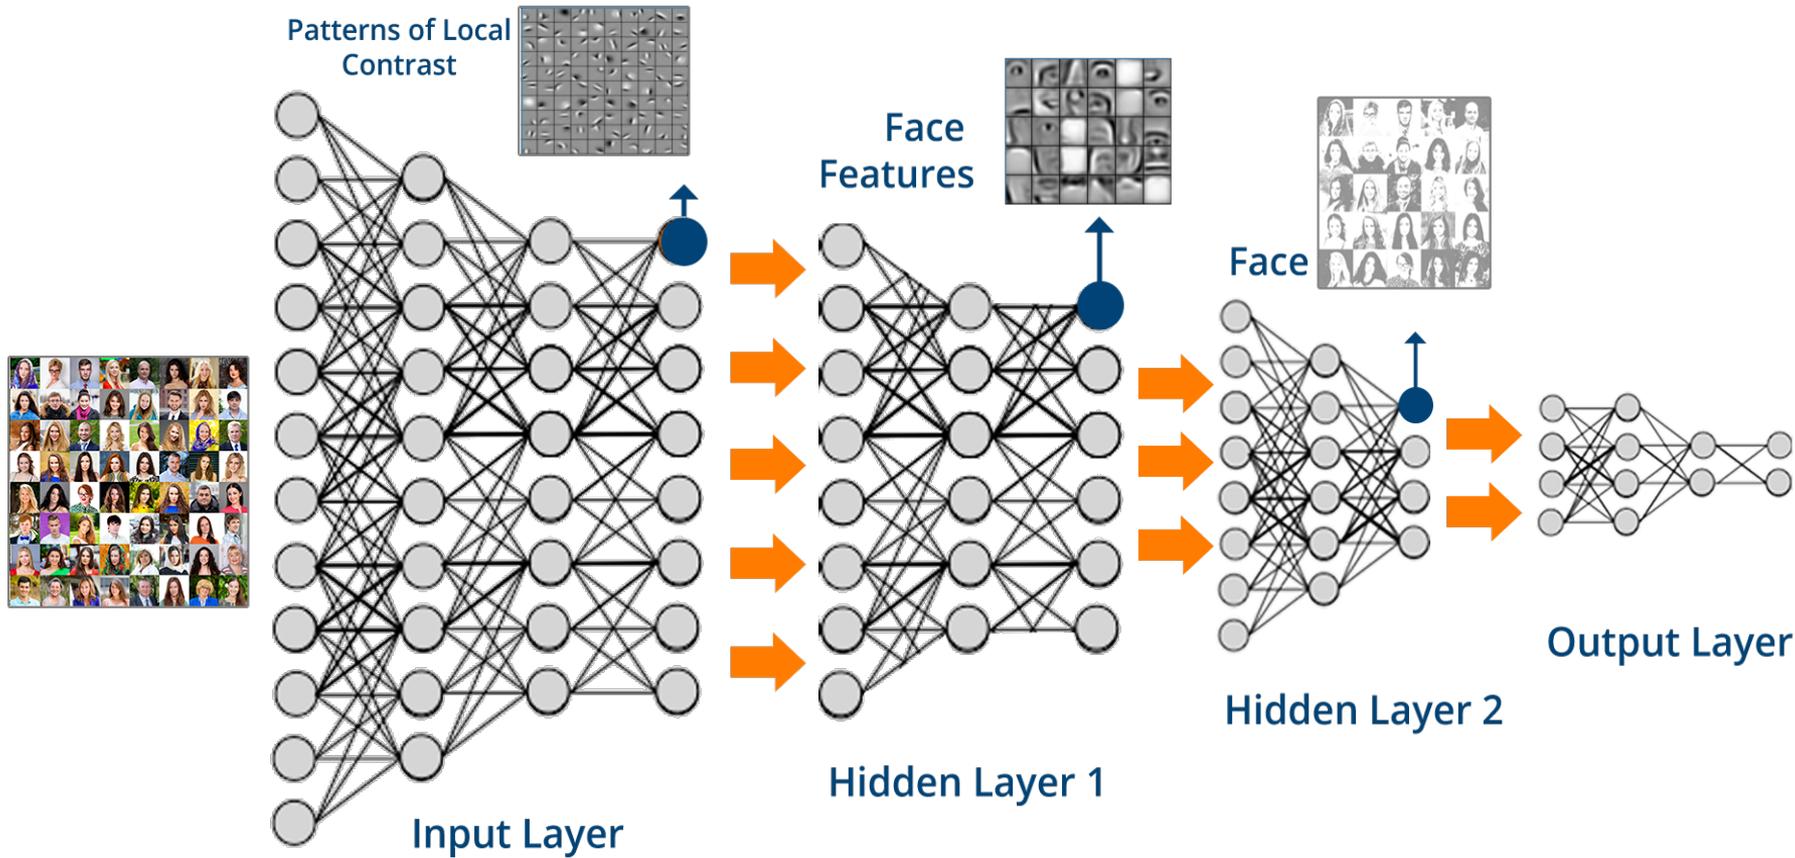
Big data & Statistiques

- Analyse, métriques
- Prédications
- Corrélations, régression \Rightarrow Fonction
- Segmentation
- Périodicité, prévision temporelle



Big data : Deep learning

- **Machine learning** :
apprentissage sans programmation explicite
- Le programme **s'améliore avec l'expérience**
- Deep learning = **imitation du cerveau**
- Réseau de **neurones artificiels**
- **Essai / erreur** ⇒ **renforcement**







Big data : Deep learning

- Apprentissage : nécessite énormément de données
- **BIG DATA** ⇒ progrès fulgurant des IA :
 - **Classification** d'images
 - Reconnaissance **vocale**
 - Reconnaissance **faciale**
 - **Conduite** automatique
 - **Traduction** automatique

Utilisations

- **Trafic** temps réel / bouchon (**Waze**)
Smart cities ⇒ optimisation des flux :
Circulation: lignes de bus.
 - Smart **GRIDS** : réseau électrique:
 - Prédiction / pilotage de la consommation (**Linky**)
 - Prédiction de la production (**ENRs**)
- ⇒ **Pilotage** de stockage & **vente** sur le marché D+1

Utilisations

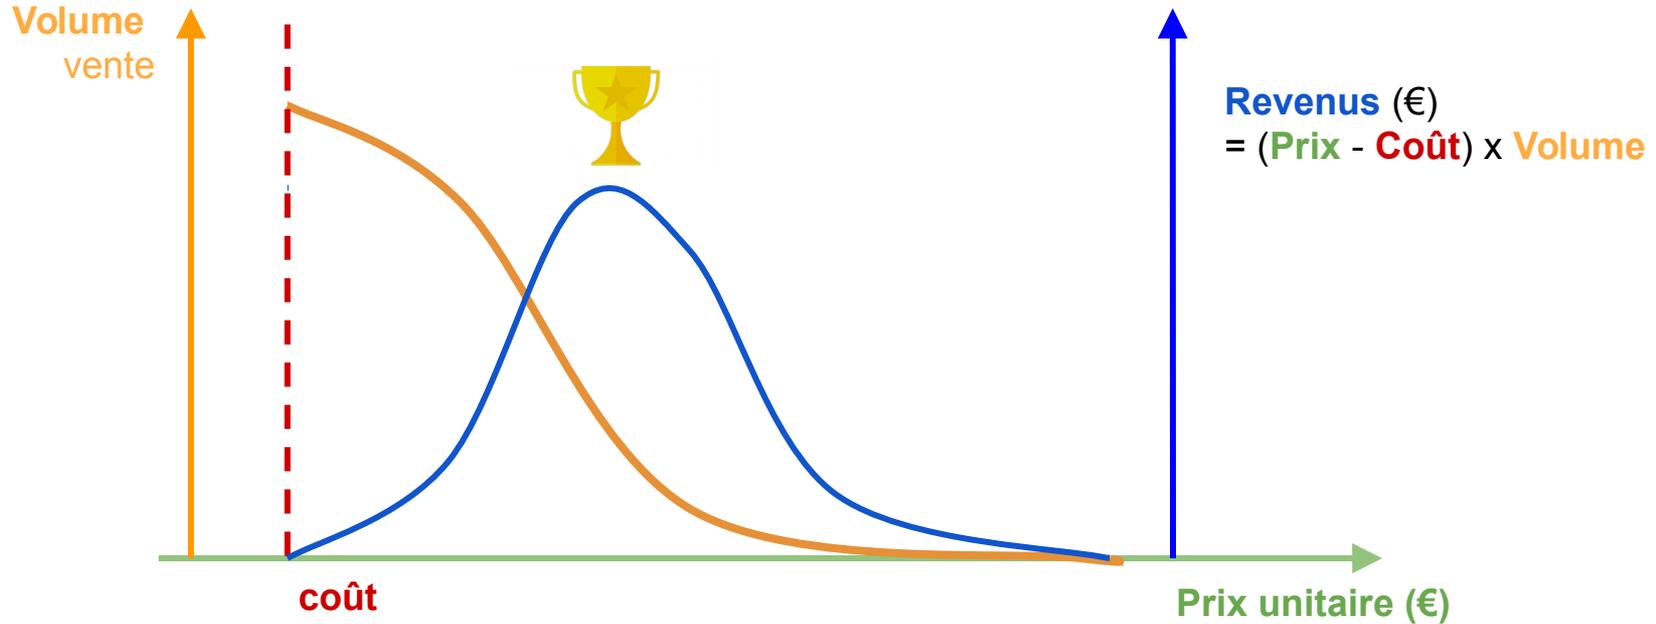
- Détection **épidémies** (google trends) / **catastrophes** (Twitter)
- Gestion des **communs** : Réseau **hydraulique** (fuites, suivi perso, quotas, pénurie ...)
- **Médecine** : aide au diagnostique
- **Droit** : aide aux **juristes**, recherche de jurisprudence

Utilisations : marketing

- Vers une **personnalisation** des offres
- **Fidéliser** le client : promos **ciblées**, rappels
- **Provoquer** l'achat : "Vous aimerez aussi"
- **Prédiction** de la **demande** :
Gestion des **stocks**, demande **périodique** (WE, vacances), dépendant de la **météo** (Cinema, Restaurant)
- Etudes de **tendances** du **marché** :
Ouvertures de **lignes aériennes**, création de **produits**

Utilisations : A/B testing

- La **courbe de prix** : Le **Graal** du commercial



Utilisations : A/B testing

- Variation aléatoire du prix (ou % promo, pub, design, ..) sur un échantillon de visiteurs (qq %)
- Impact **négligeable** sur les ventes **pendant la campagne**
- Puis **statistiques** ⇒ **courbe de prix**
- **Bonus** : segmentarisée !

⇒ **Action** : changement du prix, voire **variable** par **segment**

⇒ **Maximisation des revenus**

Question de droit : sécurité & vie privée

- Les données critiques :
 - Données **client** ⇒ Réputation en cas de vol
 - **Secret industriel** :
Innovation ? ⚠ **NSA / GAFAM**
 - Secret **défense** / **légal** / **admin FR** ⇒ **Sol Français**
- Droit, espionnage ⇒ préférer **UE / France** (OVH)

Question de droit : données personnelles

- Données personnelles : **définition** (FR / UE)
 - Identifiants uniques (nom, tel, sécurité sociales, ..)
 - **ou** identification par **recoupement**
- **Obligations** :
 - **FR** : Déclaration **CNIL** + accès, modif, suppression
 - + UE [**RGPD**] Mai **2018** :
 - Collecte limitée, explicite, légitime ↔ finalités
Cf **droits applis** sous **android**
 - Expiration

Stratégies : Open Source

- **Open Source** : Logiciel avec **accès au code source** + droit de **modification et redistribution**
- **Big DATA** : Beaucoup d'outils **open source** :
 - Suite Apache Spark
 - Apache **Impala**
 - Elasticsearch
- **Gratuits, puissants, maintenus + communauté**
- **Open Source != bénévole** :
 - **support, formation, consulting**

Stratégies : résumé

	Outils ⇒ Données	Données ⇒ Cloud
Vie privée	<ul style="list-style-type: none">● Déclaration CNIL	<ul style="list-style-type: none">● Déclaration CNIL● + Anonymiser si possible● + Préférer Cloud privé (+ cher)
Sécurité	⚠ Politique stricte de sécu interne compétences interne	Souvent bonne politique sécurité ⚠ Espionnage / NSA
Outils d'analyse	Open source Installation spécifique Adaptation au business	<ul style="list-style-type: none">● Open source● ou logiciel "maison" ⇒ Pas de communauté
Coûts / travail	<ul style="list-style-type: none">● Consulting● ou compétences internes	<ul style="list-style-type: none">● Licence / abonnement Cloud● Préparation des données● Transfert● Config

À emporter



- Secteur porteur : **marchés & métiers**
- Technologies **jeunes / mouvantes**
- Données = mines d'or
- **Analyse = extraction de valeur**
- Gardez-en le contrôle !

Questions ?



ATELIER DES COMMUNS



Des artisans développeurs, au service du bien commun.

<http://atelier-des-communs.fr/>
raphael@atelier-des-communs.fr