Graph & Network Analytics

The power of relations

Vandy BERTEN
Section Recherche
6 juin 2017

Smals
ICT for society

Définir – Caractériser –  – Visualiser – Manipuler – Interroger

Table des matières

Définir un réseau

Caractériser un réseau

Visualiser un réseau

Manipuler un réseau

Interroger un réseau

Définir un réseau

Définir un réseau

MOTIVATIONS

Motivation

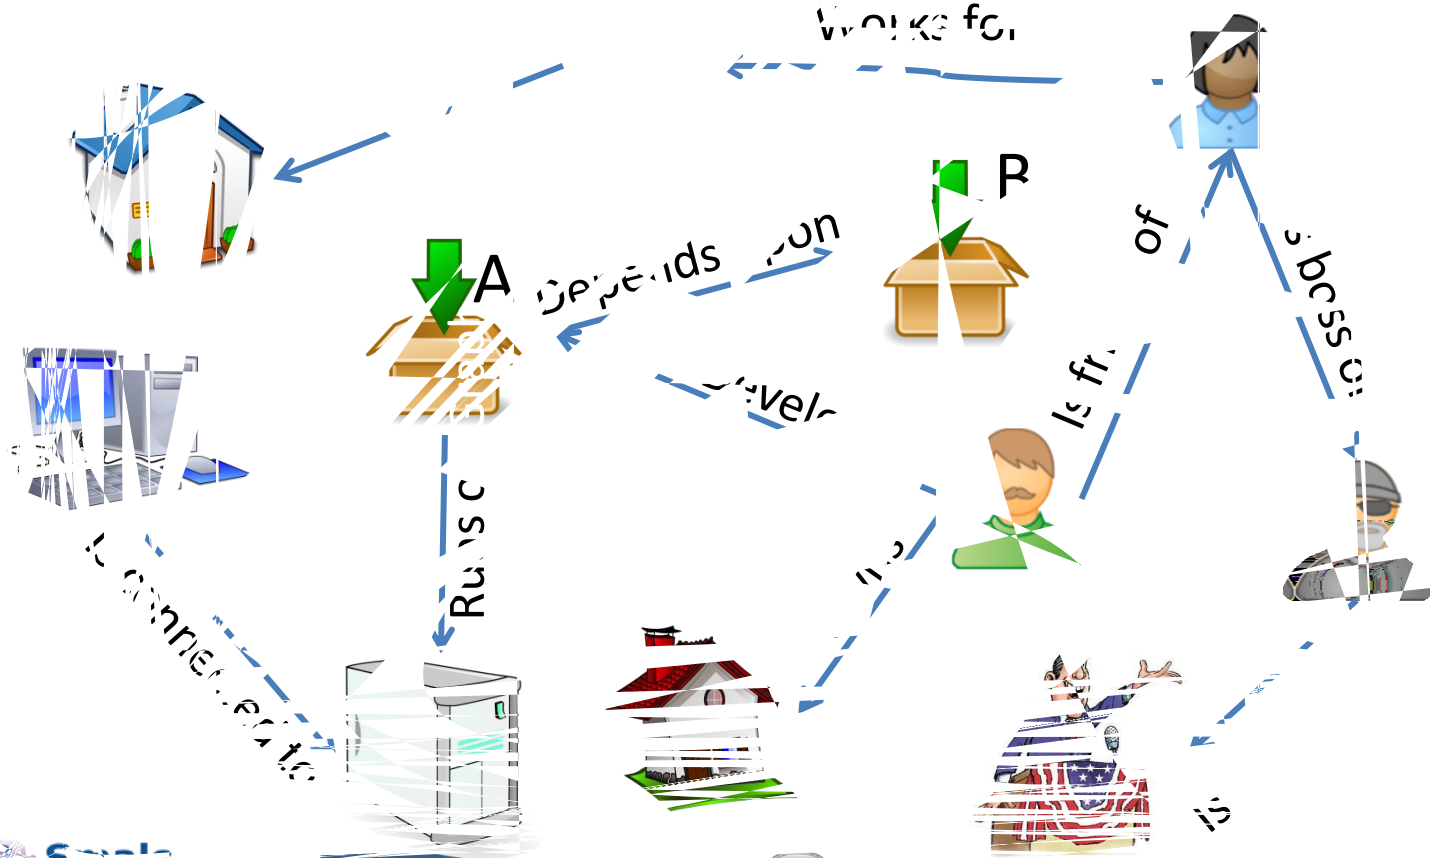

Facebook [ ] was founded on the idea that while value in discrete information about pe

Social Network Analytics

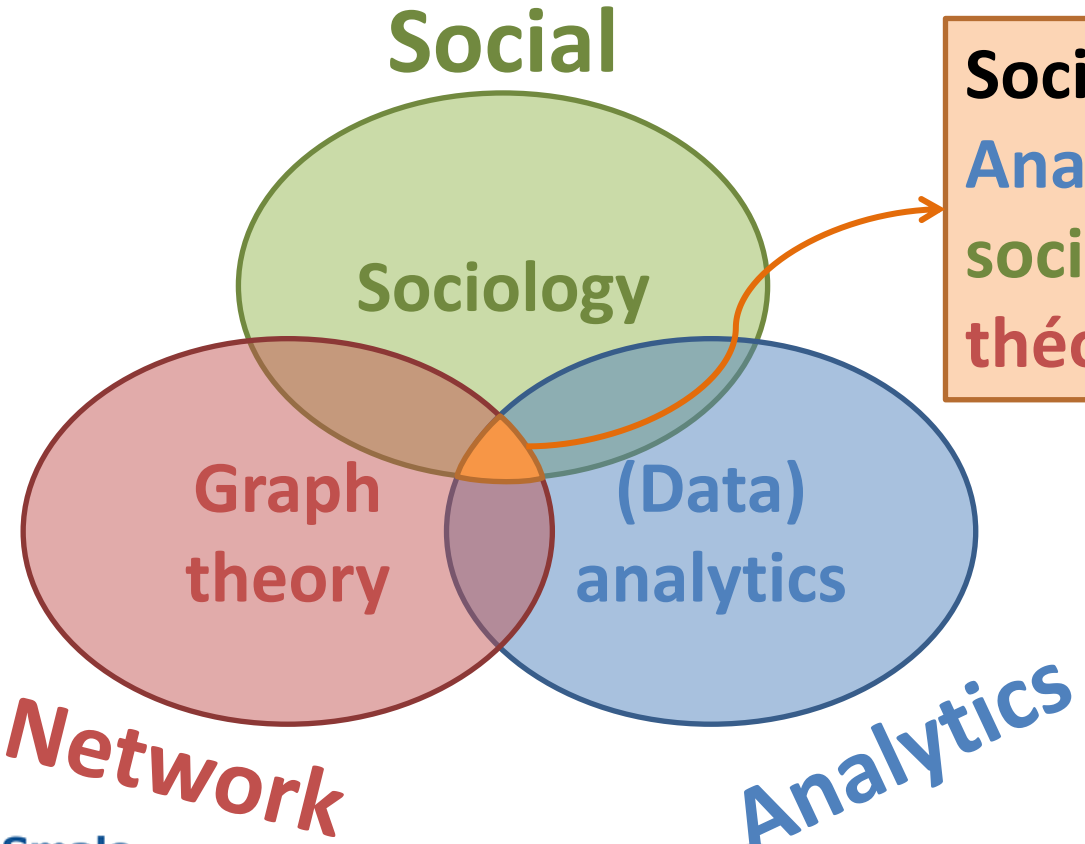

Social Network Analytics :
Analyse des **structures sociales** au travers de la **théorie des graphes**

(Social) Graph/Network Analytics is not…

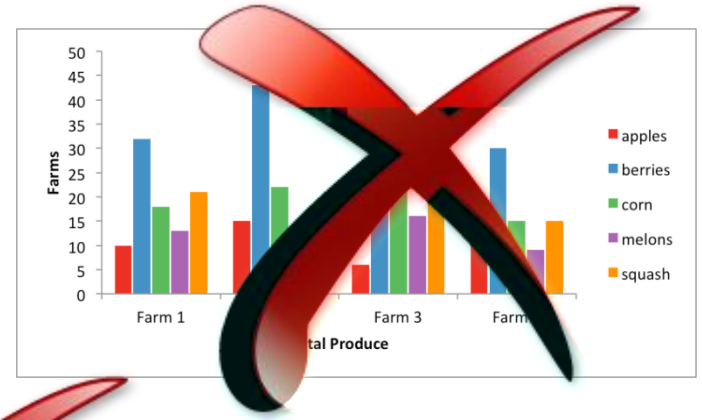

7 ponts de Königsberg (Euler, 1736)

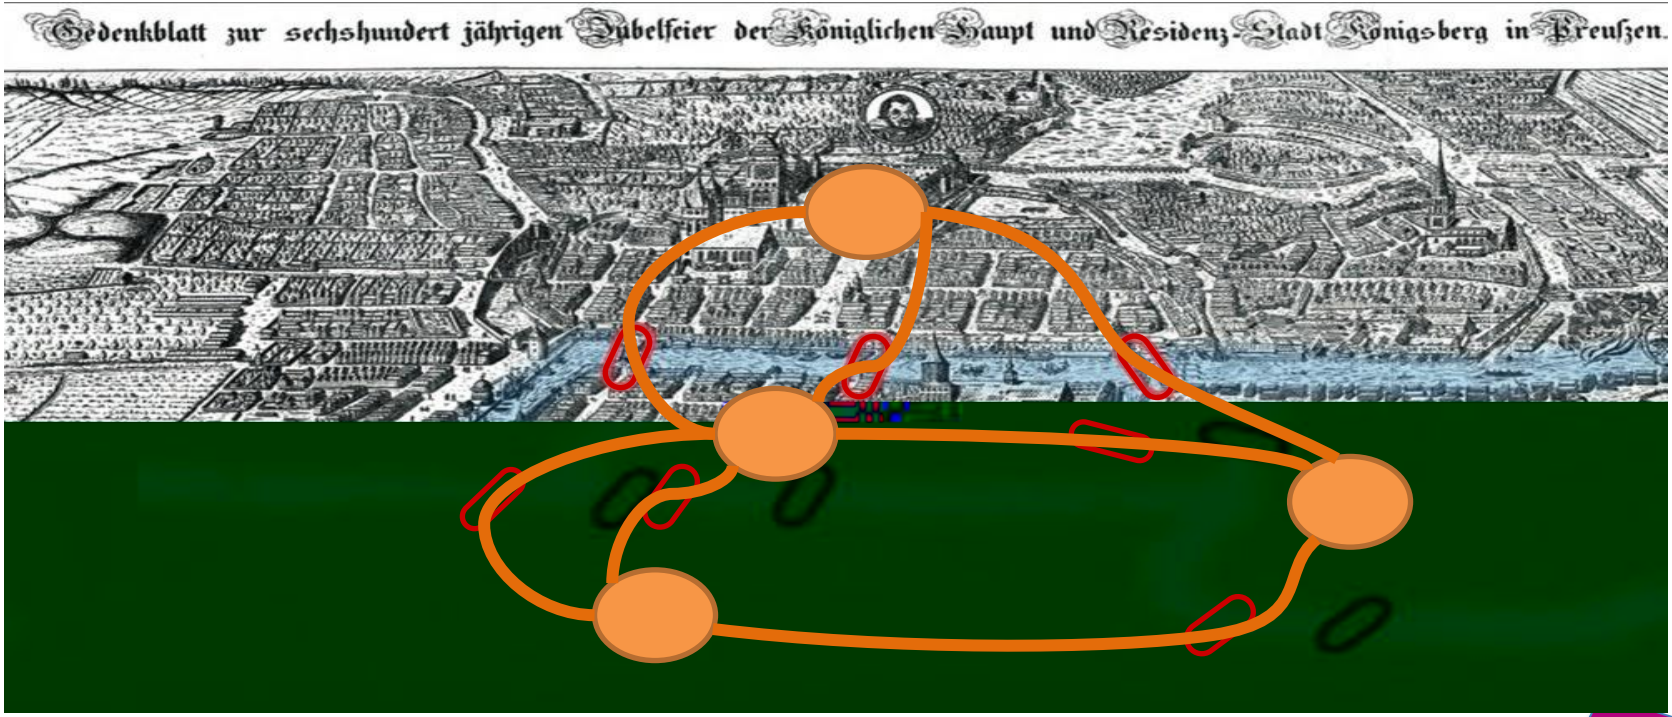

Gartner : BI and Analytics/Data Science

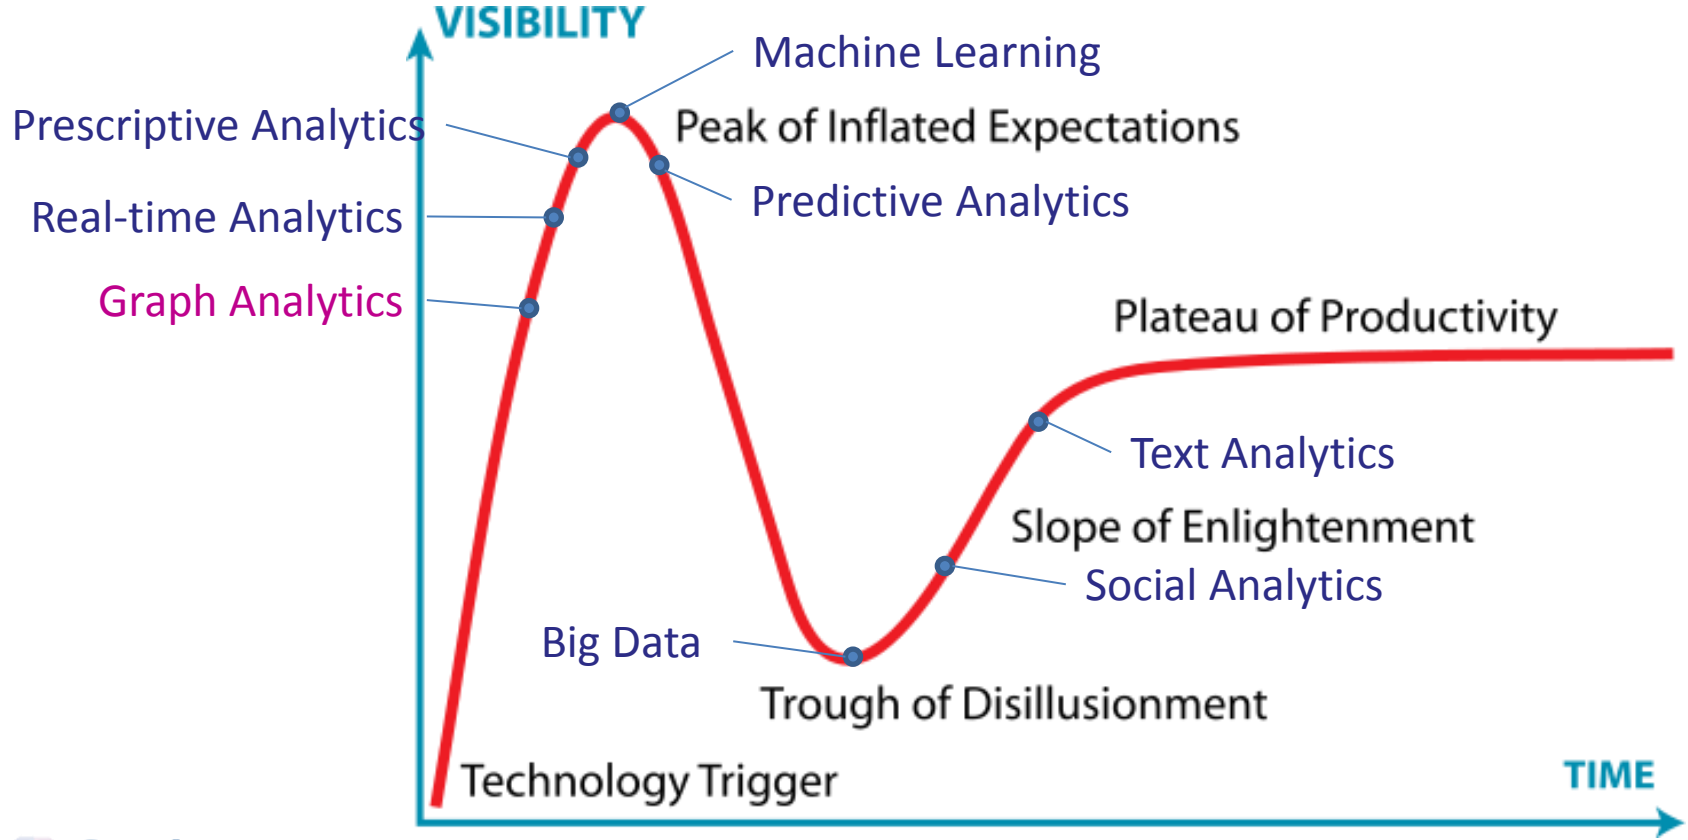

Hype Cycle for Data Science, 2016
Hype Cycle for Business Intelligence and Analytics, 2016

Gartner : applications

Route optimization

Epidemiology

Intelligence

Supply chain

Fraud detection

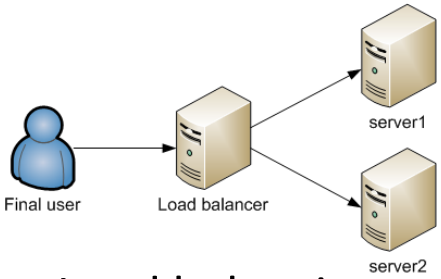

Load balancing

Market basket analysis

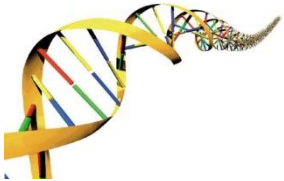

Genome

Money laundering

Définir un réseau

EXEMPLES

Spider construction

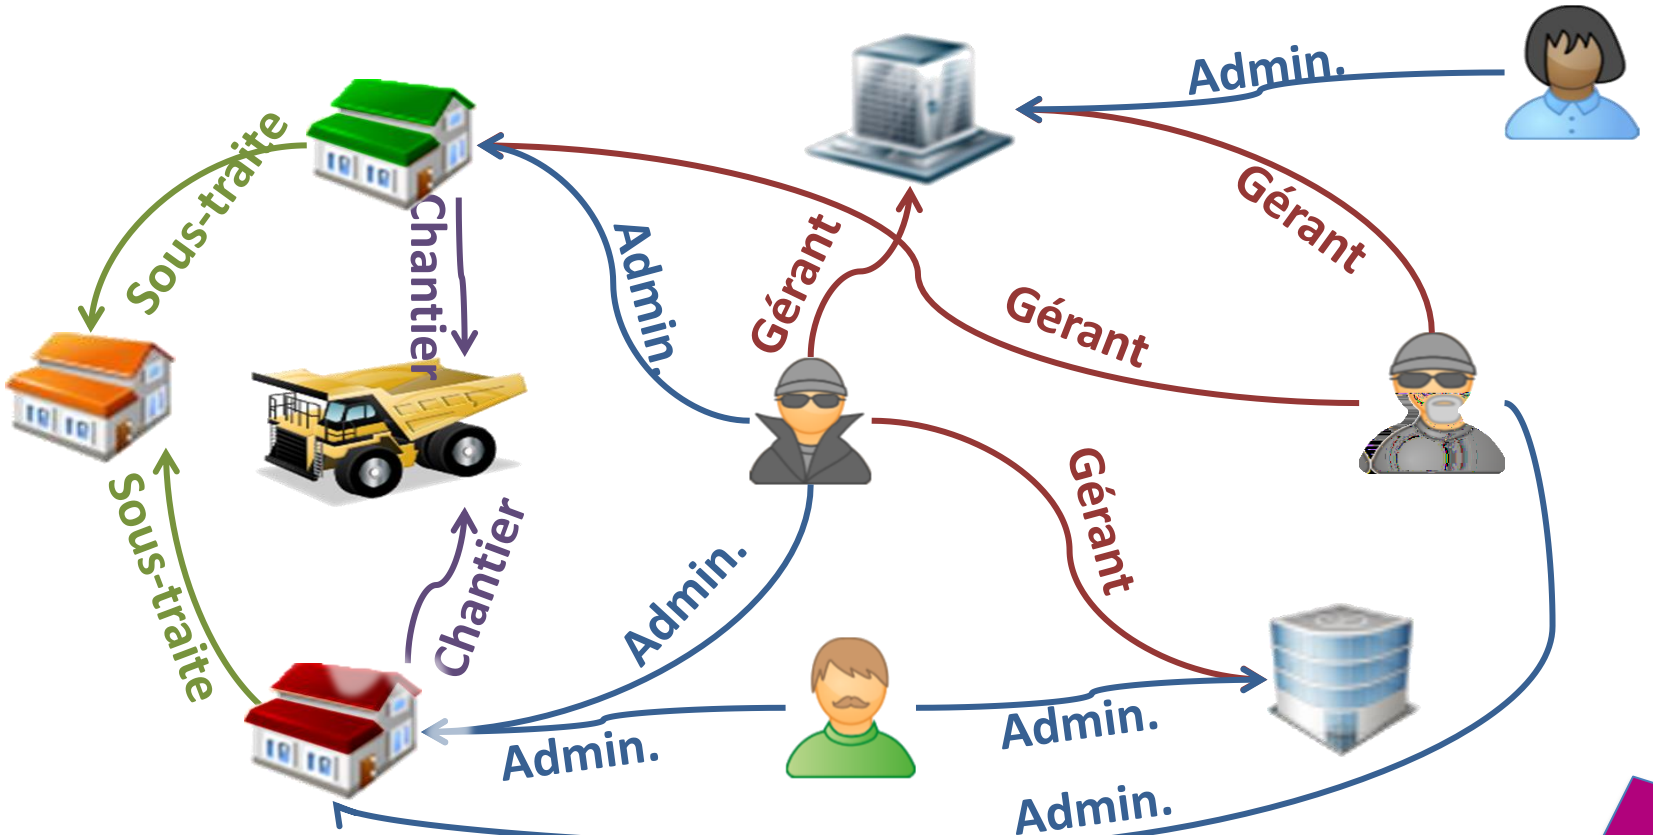

e-commerce

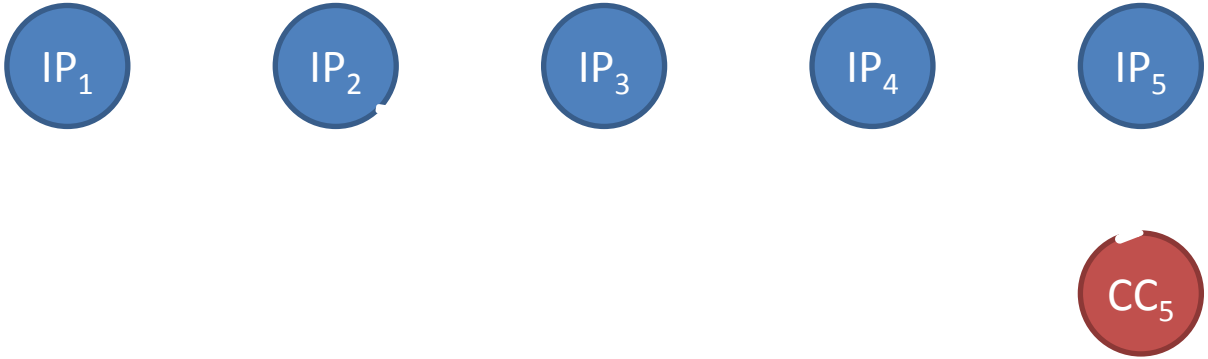

Mariages à Florence

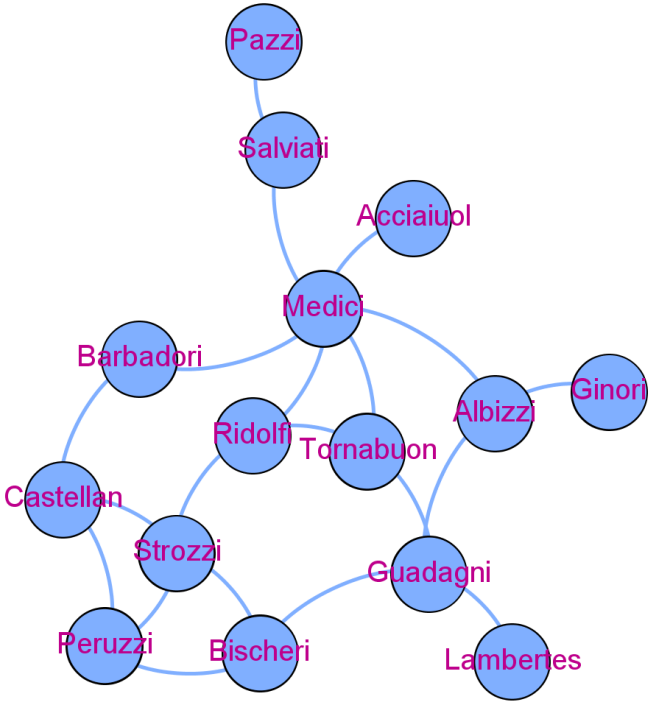

Padgett and Ansell, Robust Action and the Rise of the Medici, 1993

Mariages à Florence

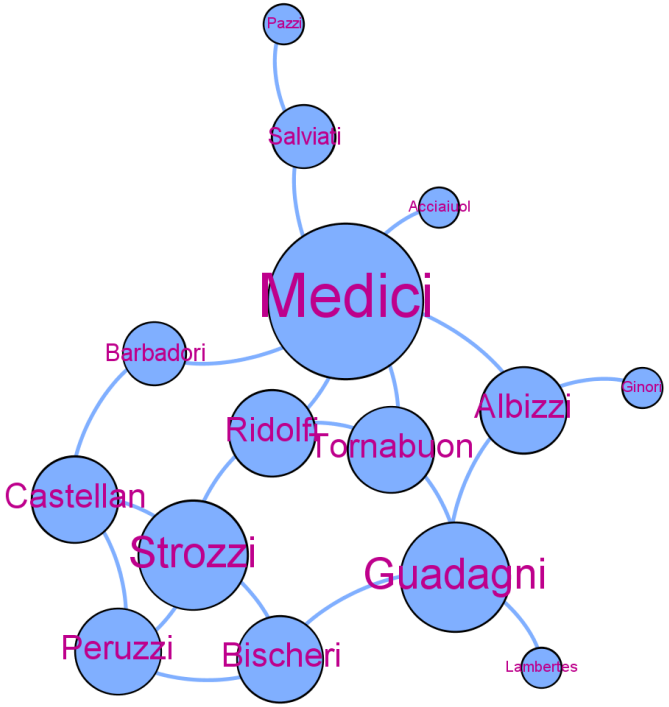

Padgett and Ansell, Robust Action and the Rise of the Medici, 1993

Mariages à Florence

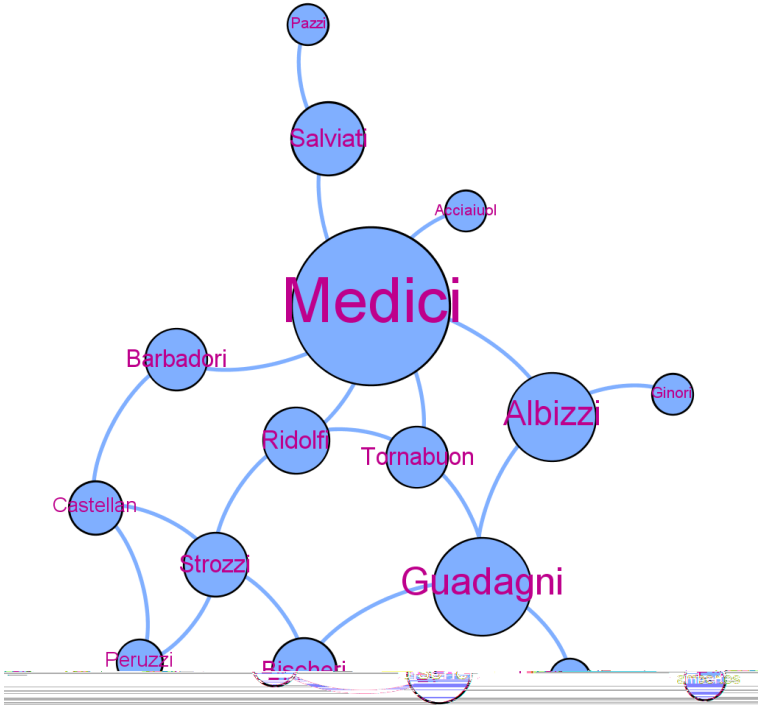

Padgett and Ansell, Robust Action and the Rise of the Medici, 1993

Dépendance de librairies Python

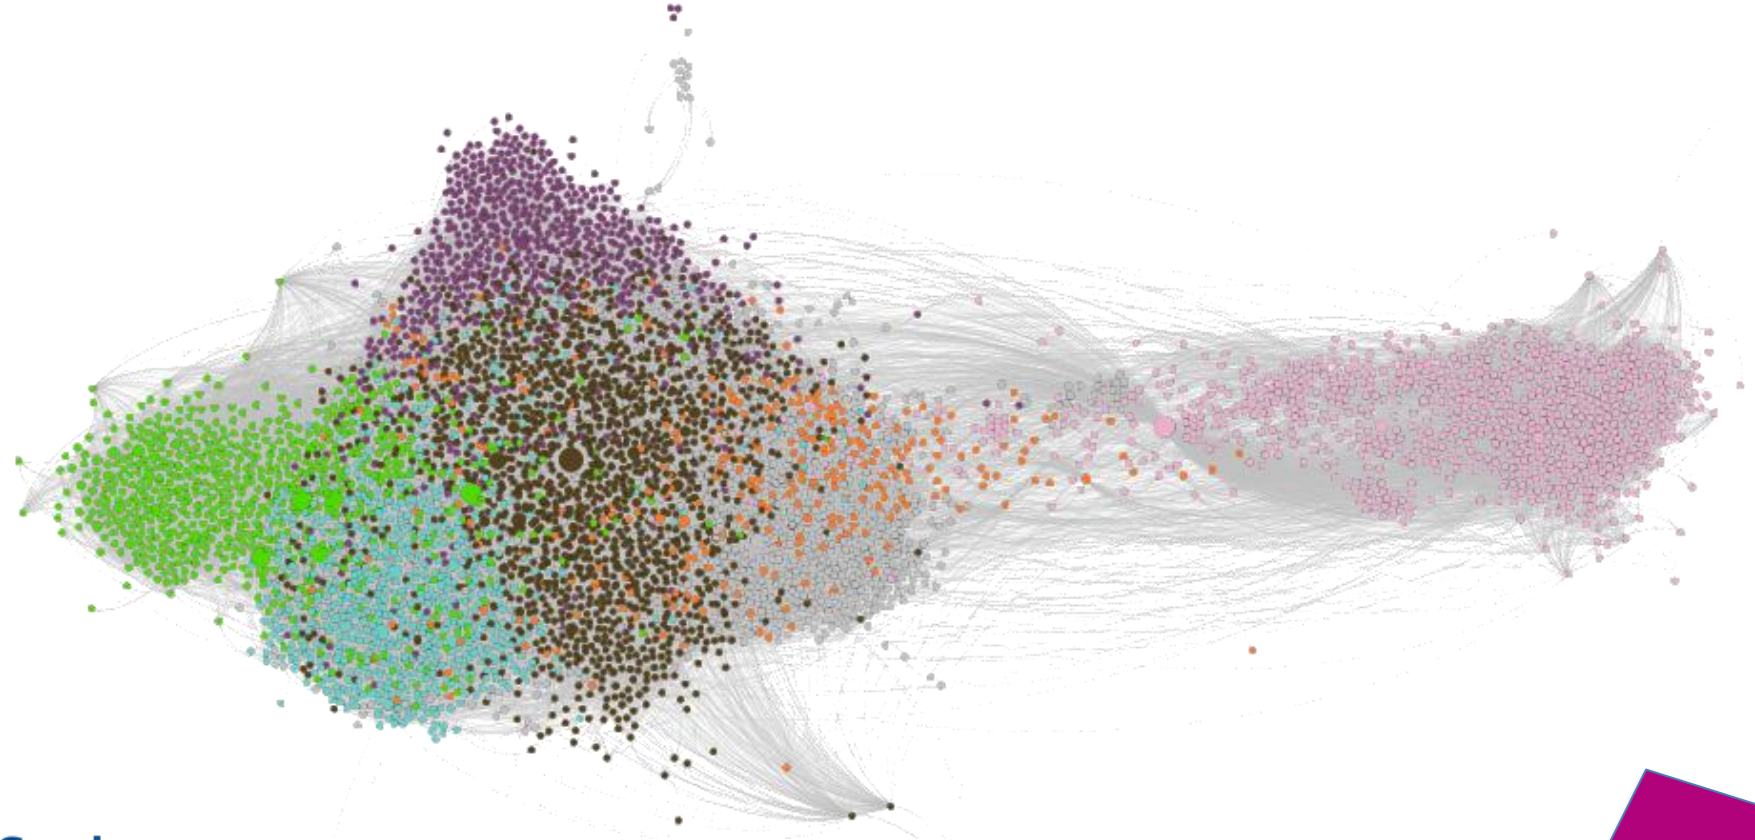

Définir un réseau

DÉFINITIONS

Nœuds, arcs

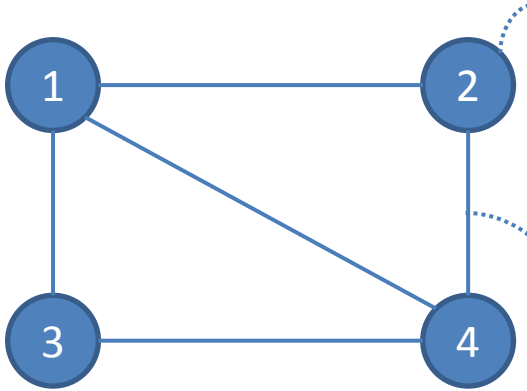

Nœud, sommet, entité, *vertex*

Arc, relation, lien, connexion, *edge*

Label, attribut

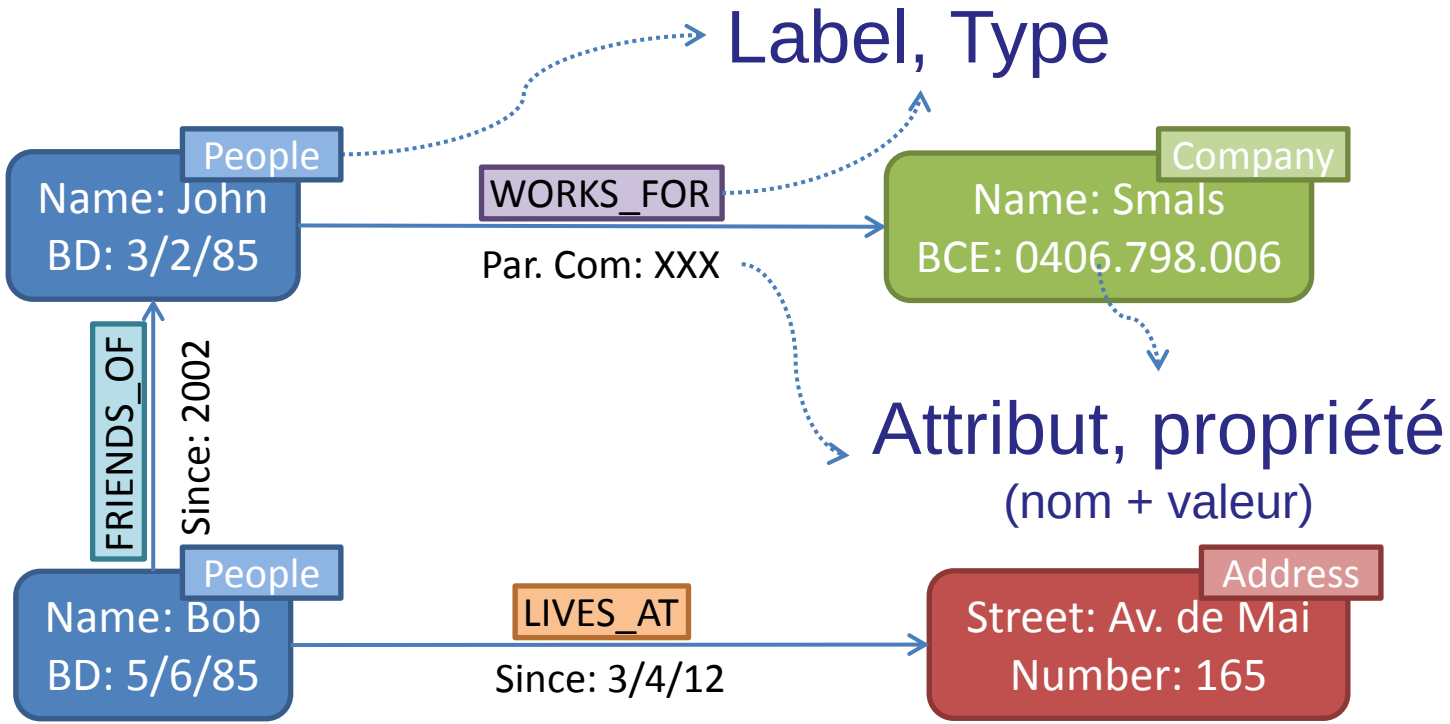

Réseau dirigé/non-dirigé

Non dirigé (*undirected*) :
collègue, ami Facebook

Dirigé (*directed*) :
travaille pour, dépend de, follower Twitter

Degré

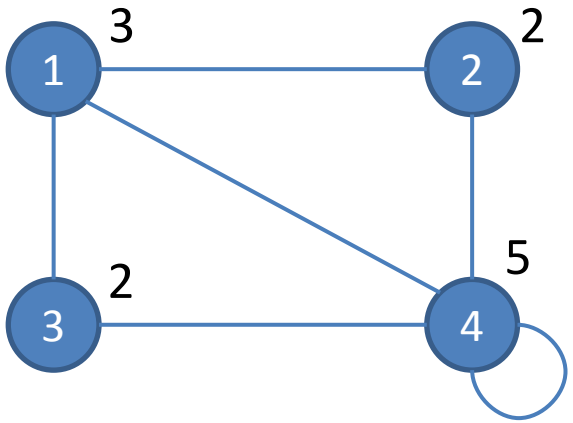
1
2
3
4
3
2
5
2


5
0

( ) = ( ) + ( )

( ) | |

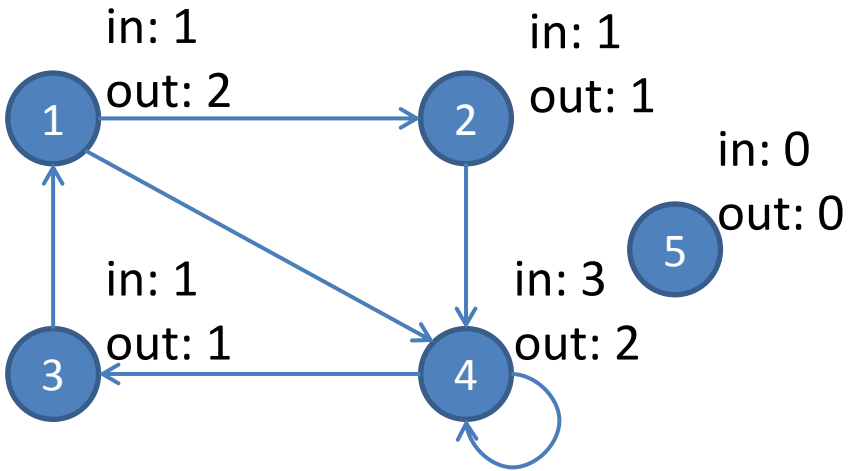
1
in: 1
out: 2
2
in: 1
out: 1
5
in: 0
out: 0
3
in: 1
out: 1
4
in: 3
out: 2

( )

( )

Graphe biparti *(bipartite graph)*

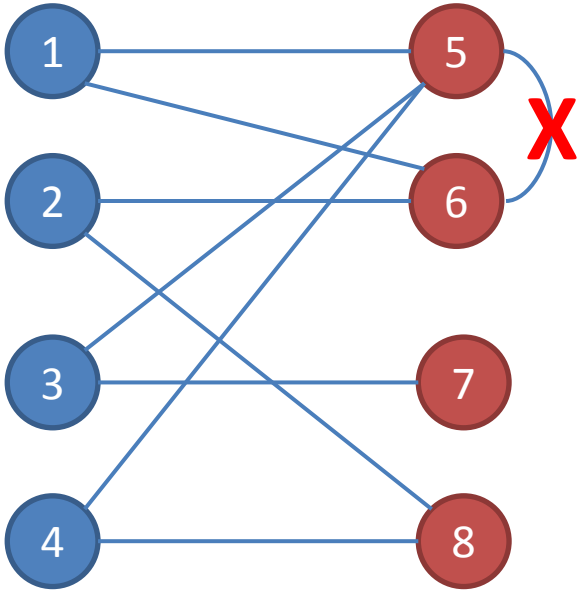

Exemple : Dimona

- Déclarations Dimona de 2007 à aujourd'hui
- 7 048 178 nœuds, 20 640 727 relations
- Graphe biparti
- Degré d'un nœud :
  - EMPLOYER : nombre de ses employés
  - WORKER : nombre de ses employeurs

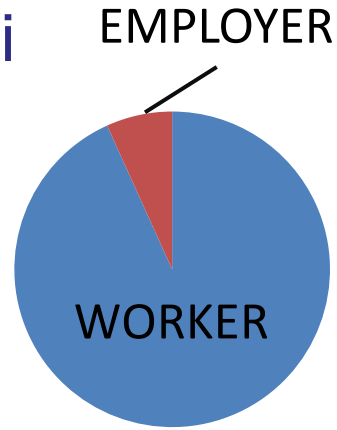

Exemple : BCE/KBO

- Fonctions BCE de 2007 à aujourd'hui
- 3 572 876 nœuds, 3 244 227 relations
- Graphe biparti
- Degré d'un nœud :
  - EXECUTOR : nombre de compagnies où il officie
  - COMPANY : nombre de ses « executors » (=mandataires)

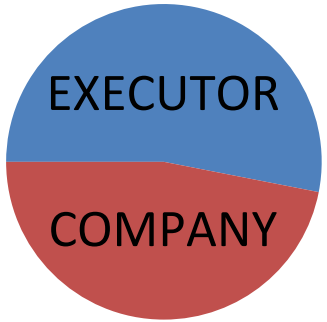

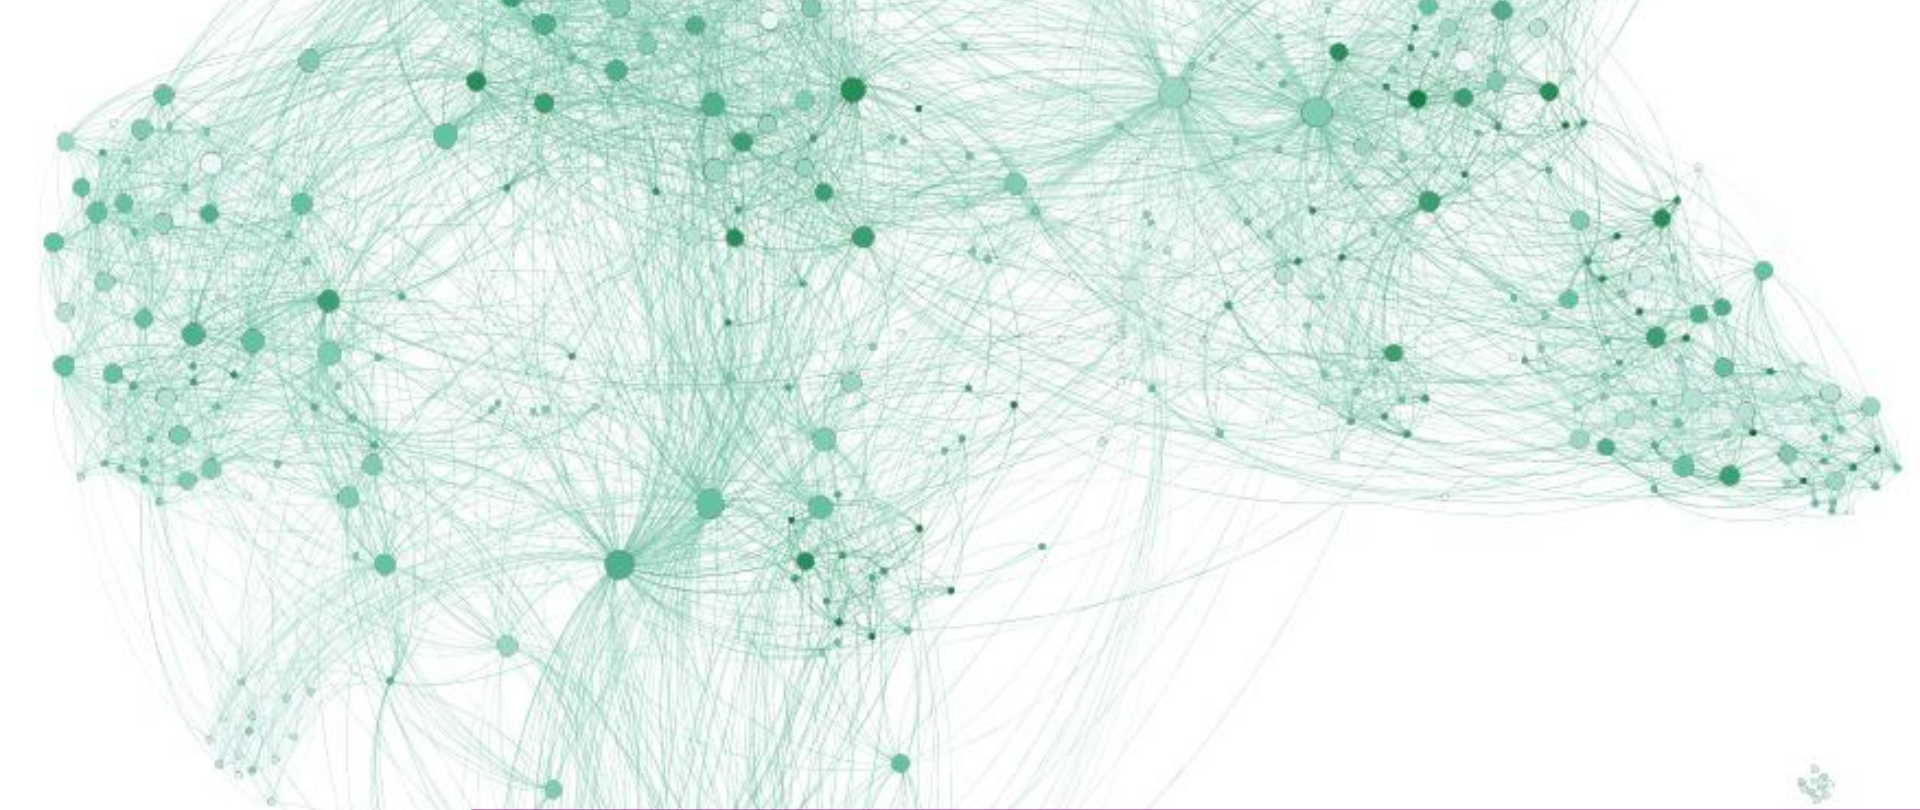

Caractériser un réseau

Caractériser un réseau

On peut caractériser :

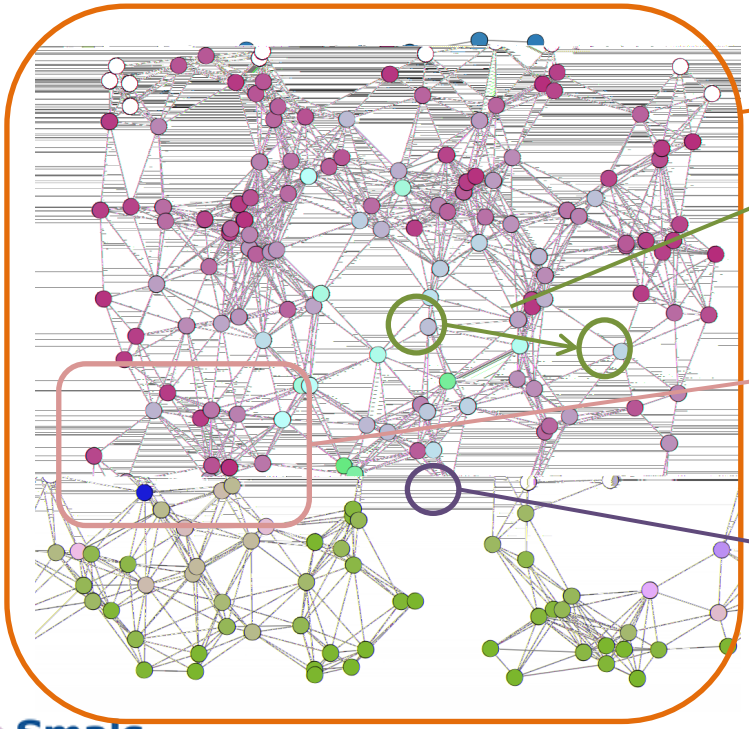

Le réseau dans son ensemble (Métriques générales)

La relation/distance/similarité entre deux nœuds

Un groupe de nœuds (Clustering)

Un nœud en particulier (Centralité)

Caractériser un réseau

MÉTRIQUES GÉNÉRALES

Densité

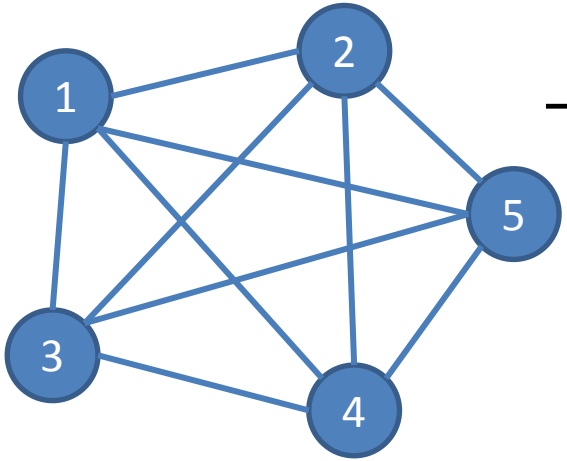

vs.

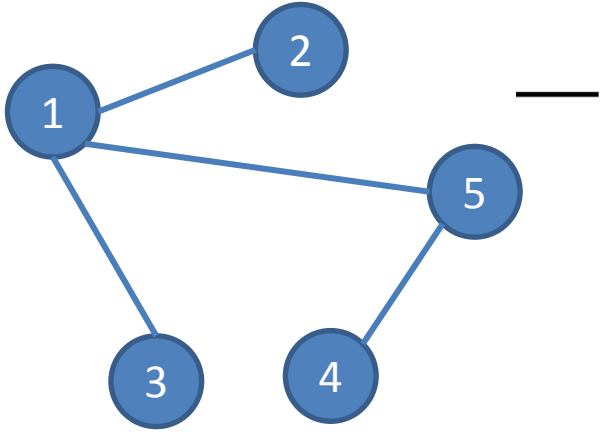

$$\frac{|\ |}{(|\ |\quad)\ (|\ |\quad)} \qquad \frac{|\ |}{|\ |\ (|\ |\quad)}$$

Densité ≠ Densité !

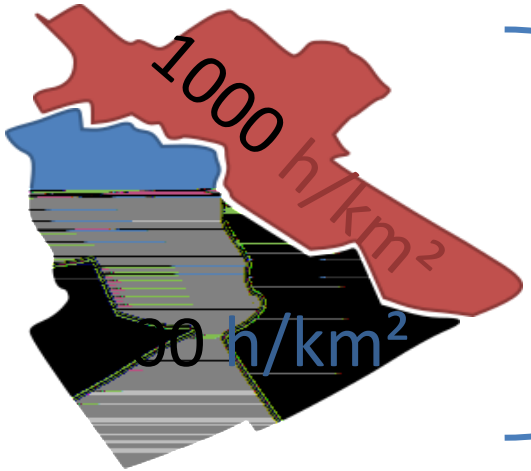

1000 h/km²

Difficile de comparer 2 graphes de tailles différentes !

Définition alternative :

_____

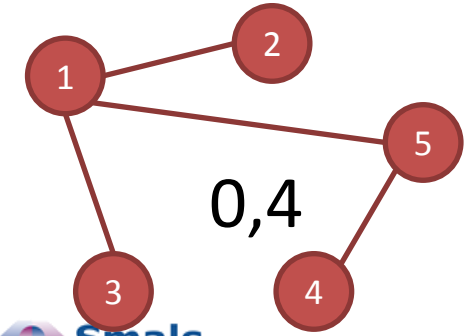

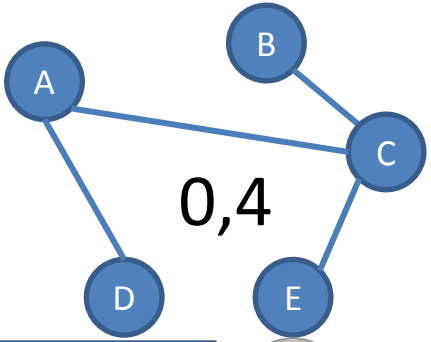

_____

Densité

Dimona:

CODE	# nœuds	# arcs
ALL	6 474 928	13 722 678
BCW	332 705	476 003
IVT	209 166	163 105
OTH	5 587 049	9 950 130
STU	1 062 334	1 976 673

BCE:

CODE	# nœuds	# arcs
ALL	3 572 876	2 933 450
ADM	923 485	1 055 779
MGR	1 087 647	781 269
FND	1 928 211	964 697

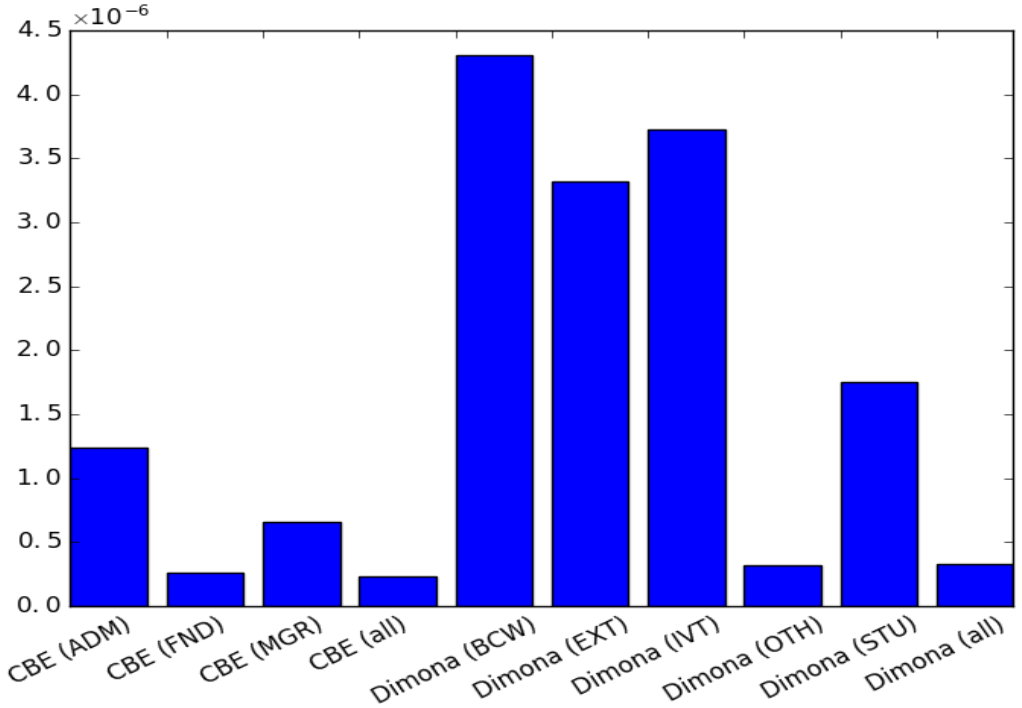

Densité alternative

Dimona:

CODE	# nœuds	# arcs
ALL	6 474 928	13 722 678
BCW	332 705	476 003
IVT	209 166	163 105
OTH	5 587 049	9 950 130
STU	1 062 334	1 976 673

BCE:

CODE	# nœuds	# arcs
ALL	3 572 876	2 933 450
ADM	923 485	1 055 779
MGR	1 087 647	781 269
FND	1 928 211	964 697

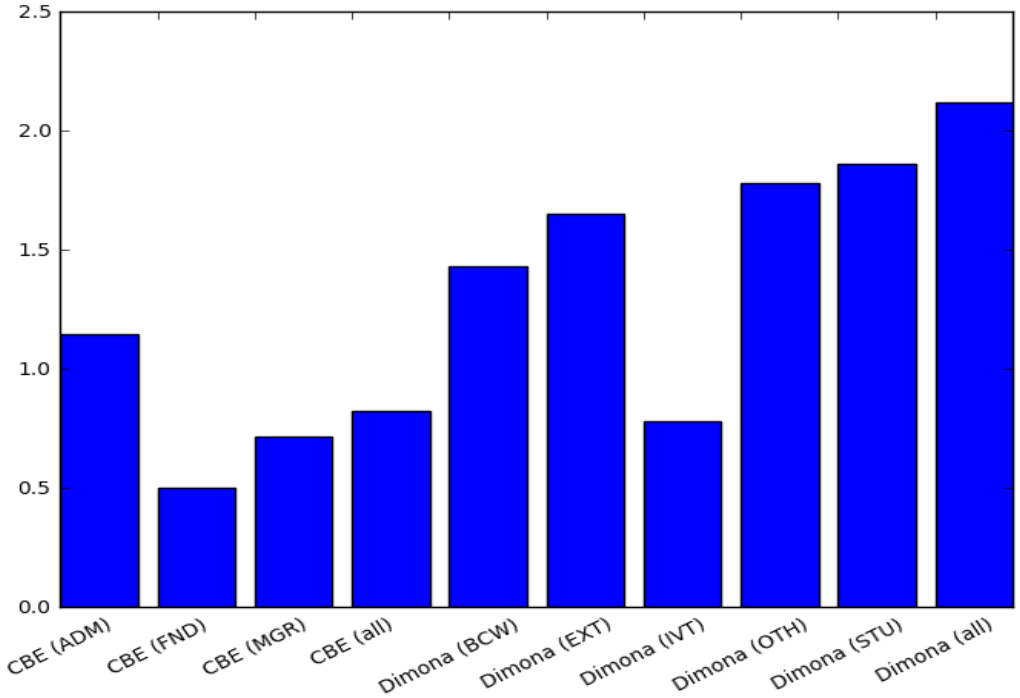

Densité

- Peut se calculer sur une partie d'un graphe (cluster, communauté, …)
- Donne une idée de l'intensité des relations/contacts entre les nœuds
- Définition 2 : nombre moyen d'arcs par nœuds

Diamètre

Diamètre = plus long « plus court chemin »

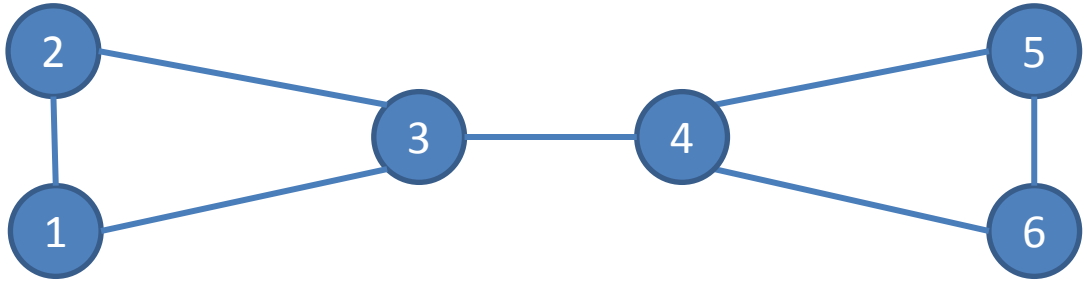

→ 3

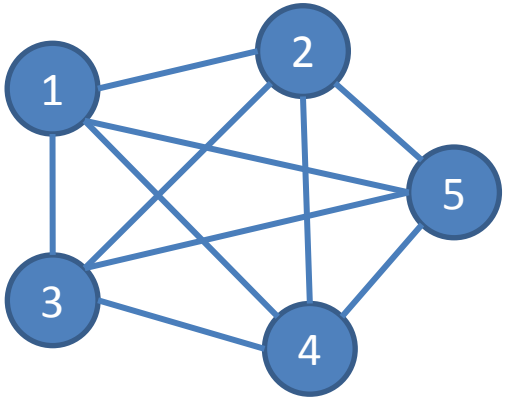

→ 1

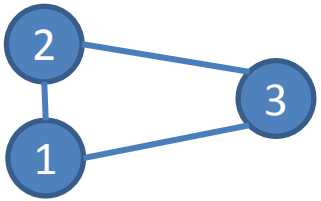

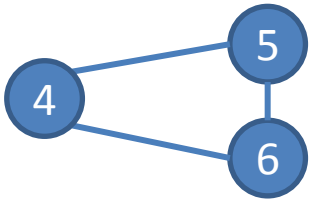

→ ∞

Diamètre

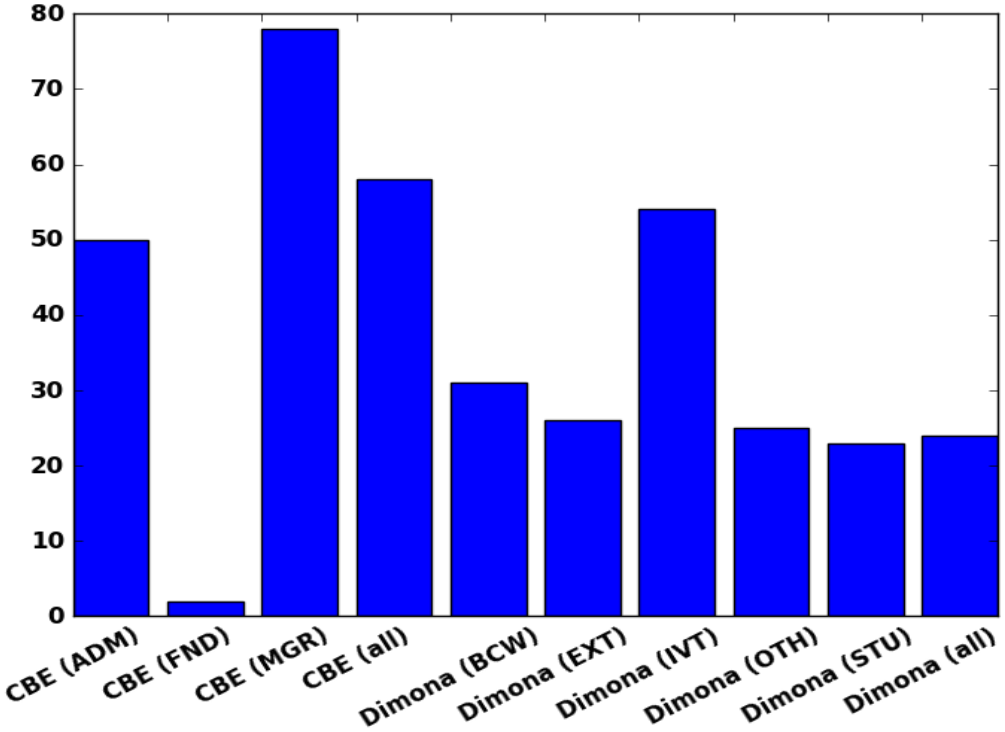
80
70
60
50
40
30
20
10
0
CBE (ADM)
CBE (FND)
CBE (MGR)
CBE (all)
Dimona (BCW)
Dimona (EXT)
Dimona (IVT)
Dimona (OTH)
Dimona (STU)
Dimona (all)

Distribution de degrés

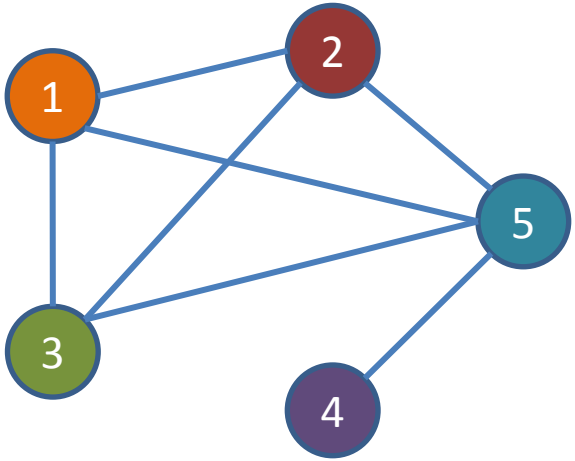

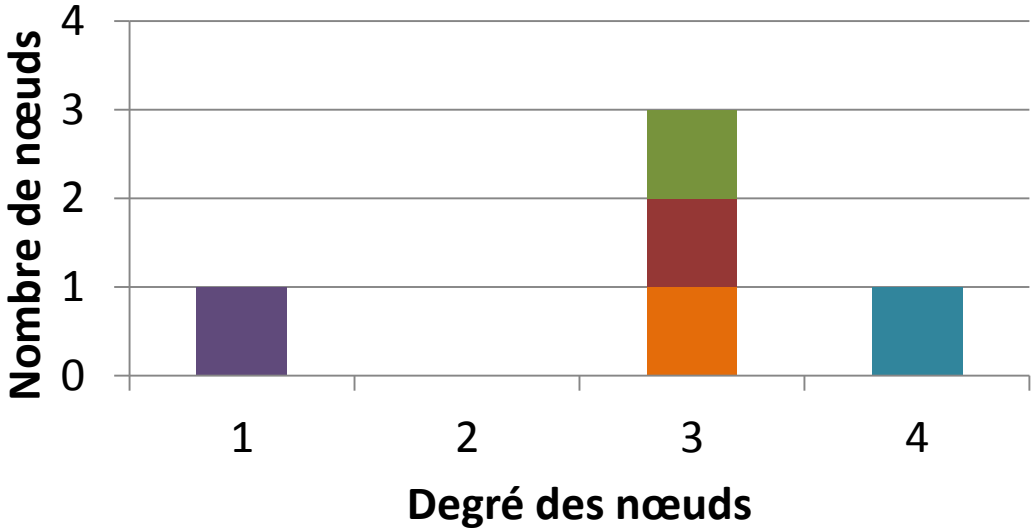

Distribution de degrés (IN vs OUT)

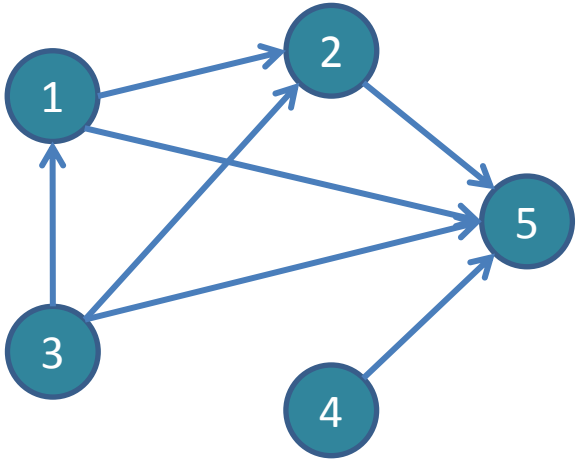

IN:

OUT:

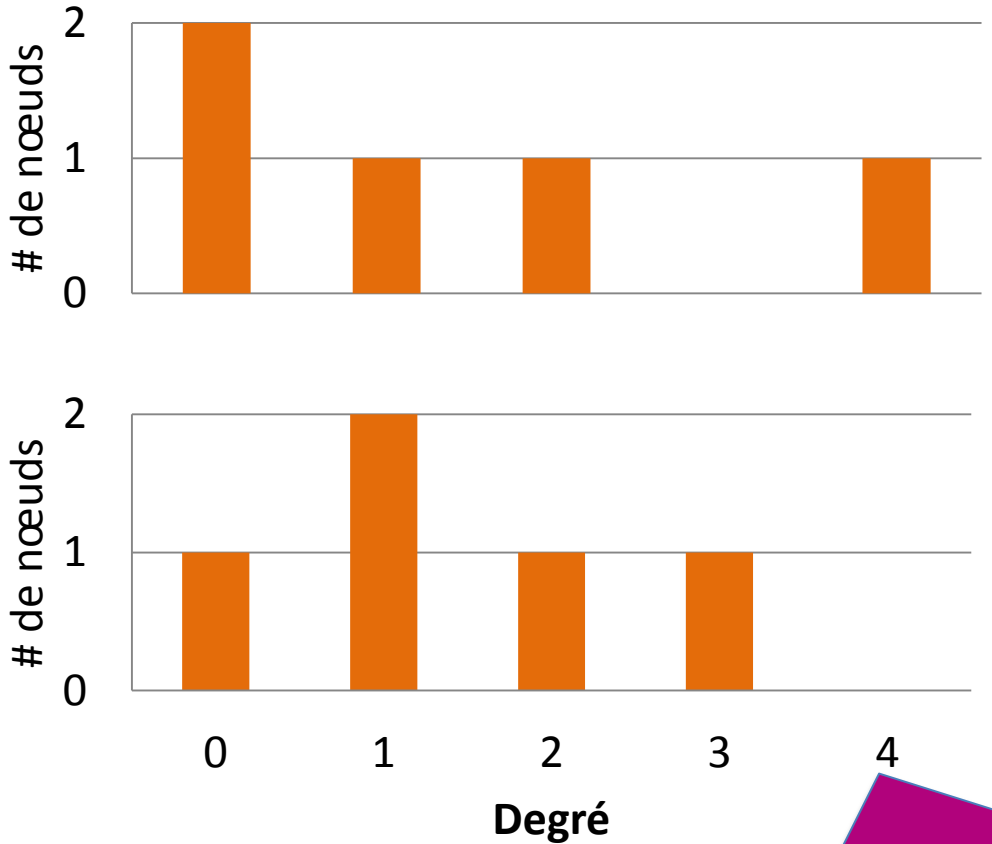

Distribution de degrés : BCE (Adm)

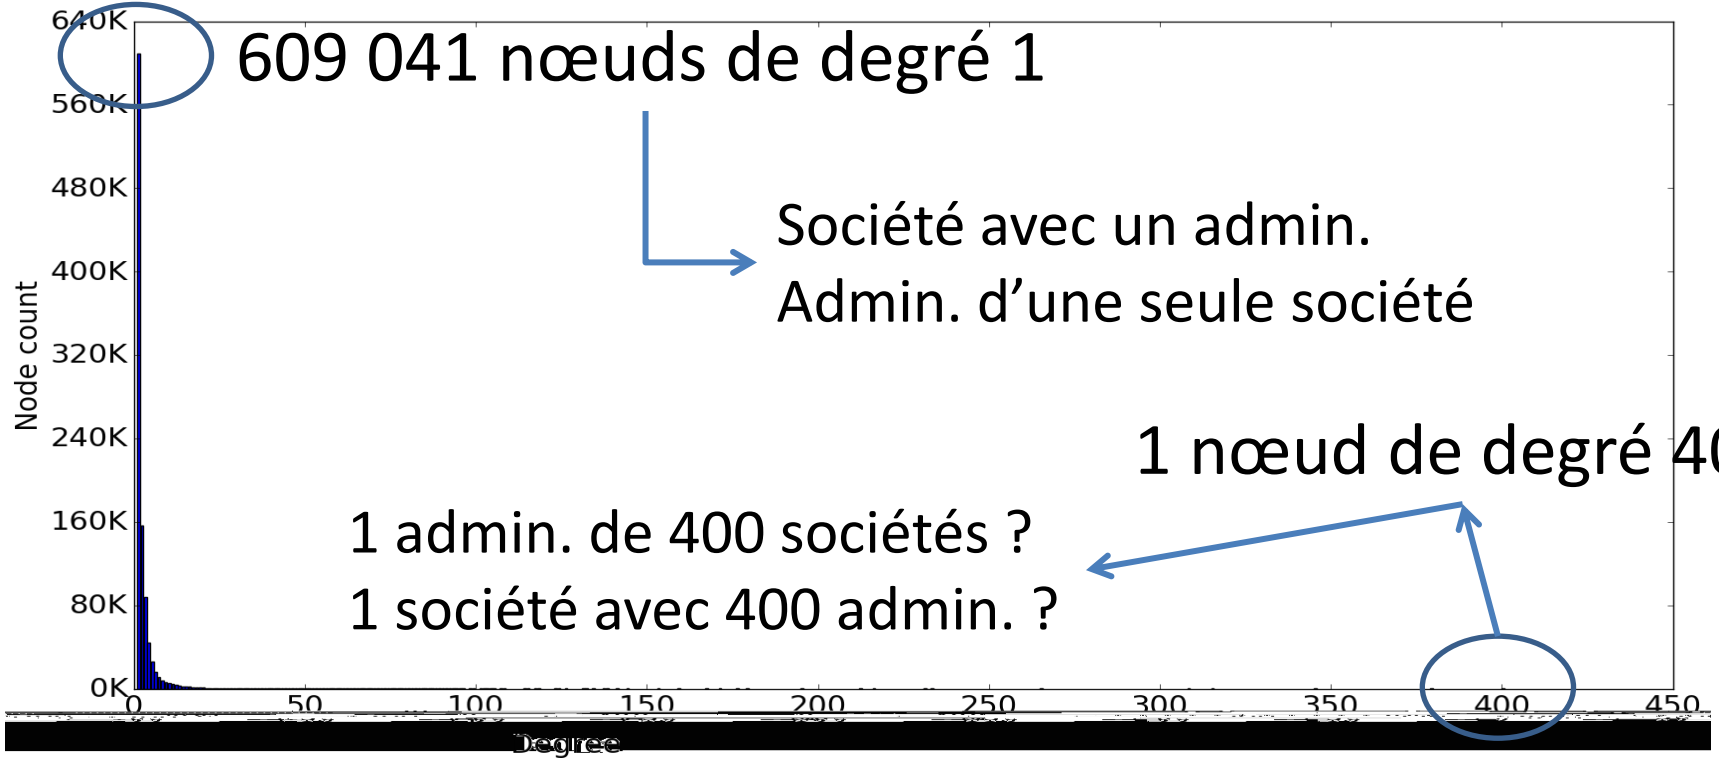

Sur une période de 10 ans

Distribution de degrés : BCE (Adm)

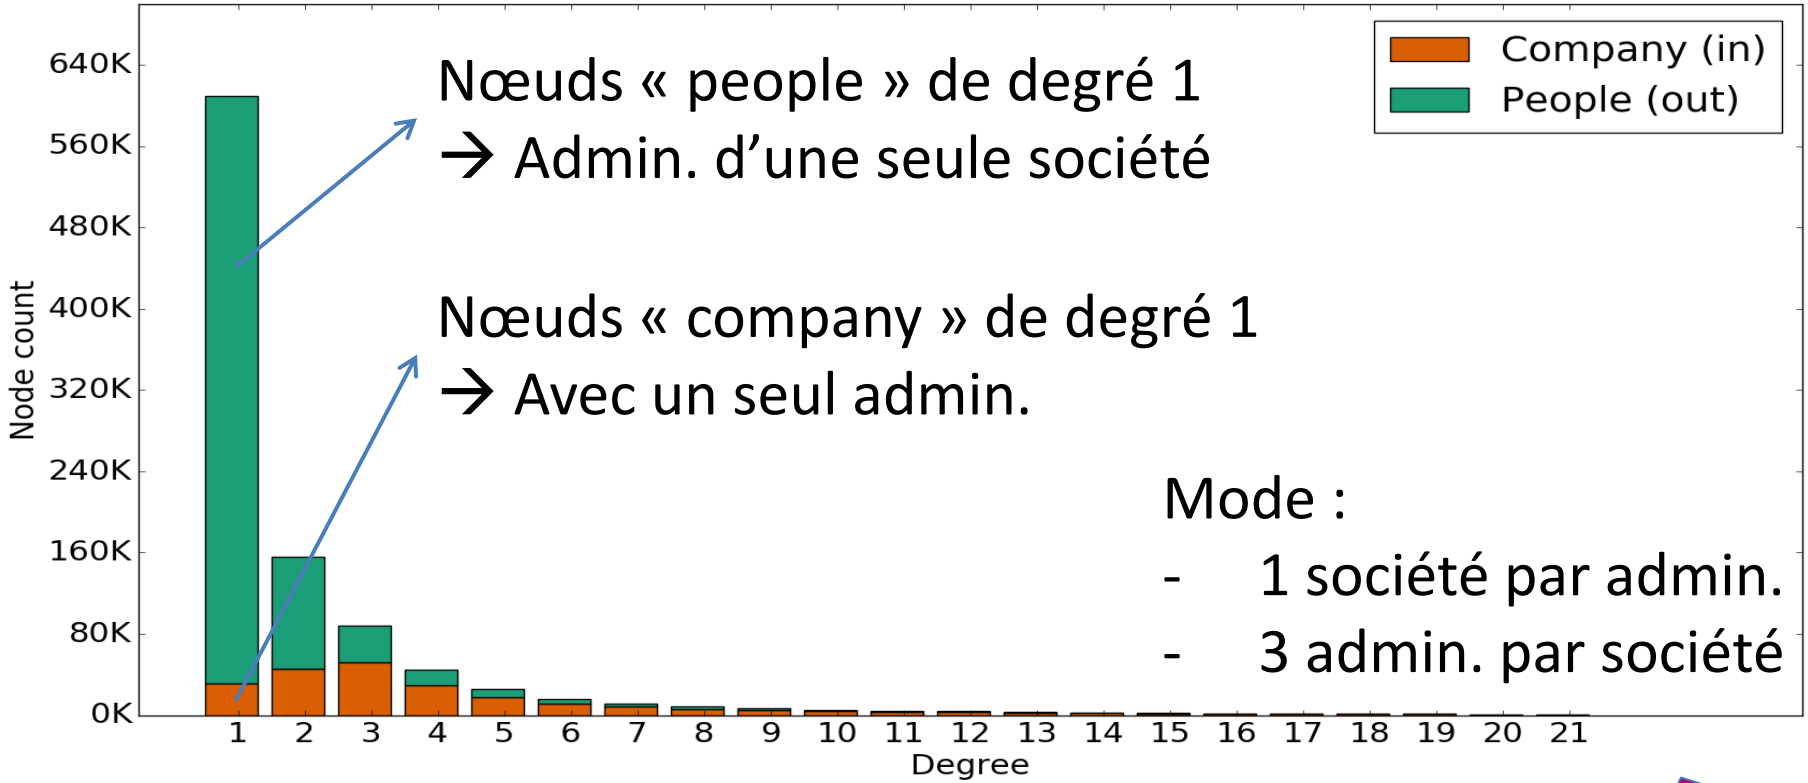

Nœuds « people » de degré 1
→ Admin. d'une seule société

Nœuds « company » de degré 1
→ Avec un seul admin.

Mode :
- 1 société par admin.
- 3 admin. par société

Suppression de 0,5% des nœuds les plus gros

Distribution de degrés : BCE (Adm)

0,003 % des nœuds les plus gros (« outliers »)

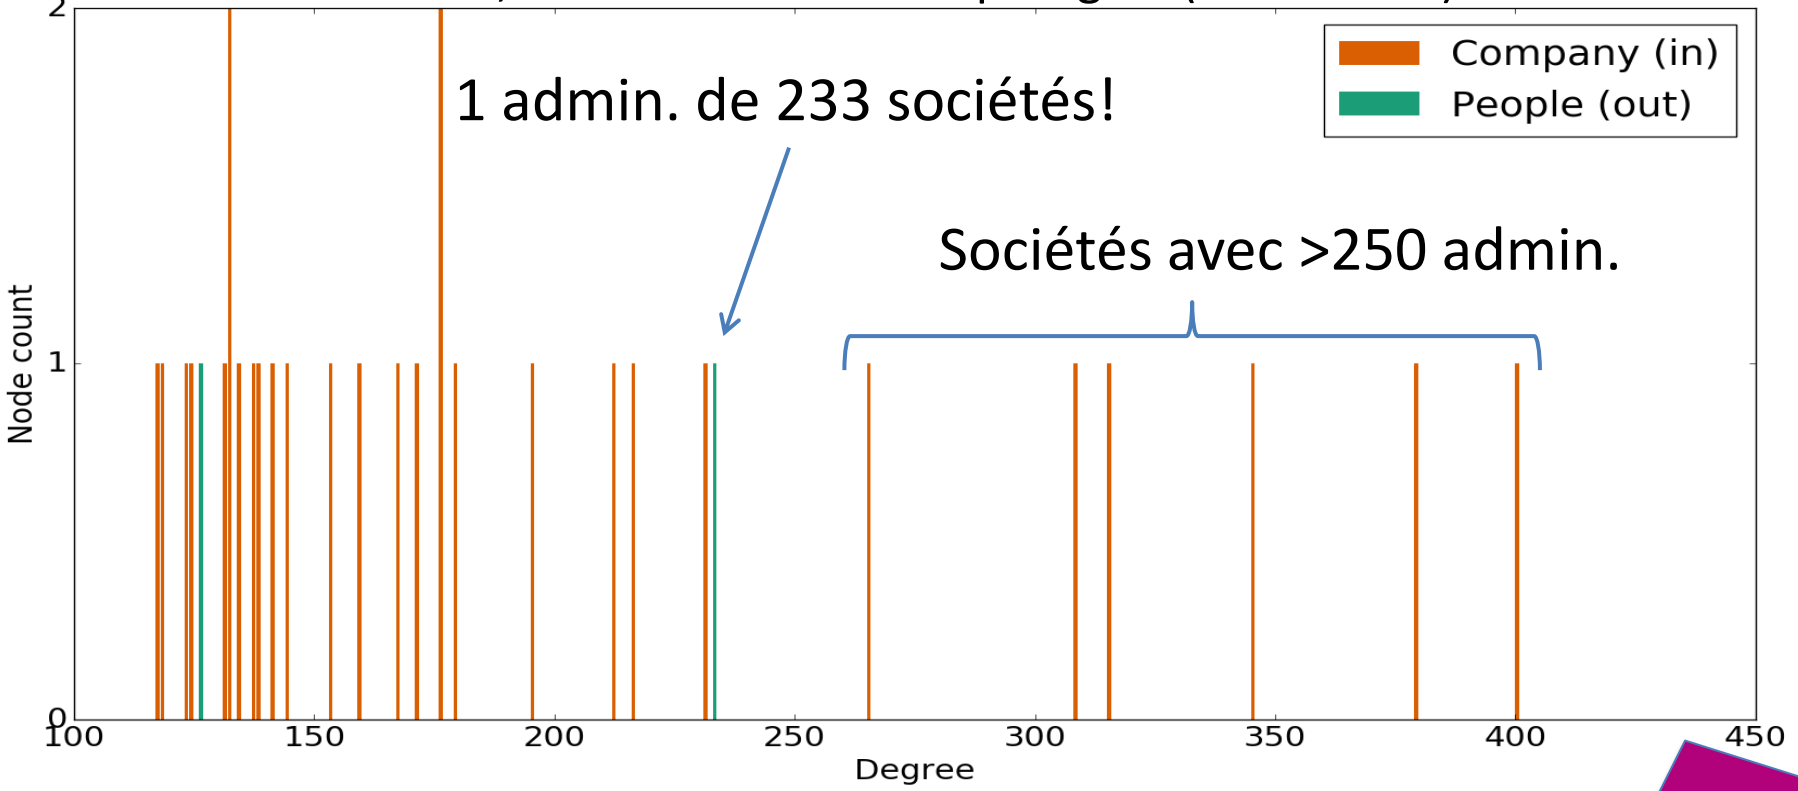

Métriques générales

- Densité : intensité des relations
- Diamètre : étalement du réseau
- Distribution de degré : « forme » du réseau

Caractériser un réseau

CENTRALITÉ

Centralité

- Centralité d'un nœud = importance d'un nœud au sein du réseau
- Peut se baser sur des caractéristiques :
  - Du nœud isolé (Degree centrality)
  - Du nœud et de son voisinage immédiat (K-core)
  - De l'ensemble du réseau (Betweenness, Page-rank…)

Centralité de degré

Centralité : degré du nœud

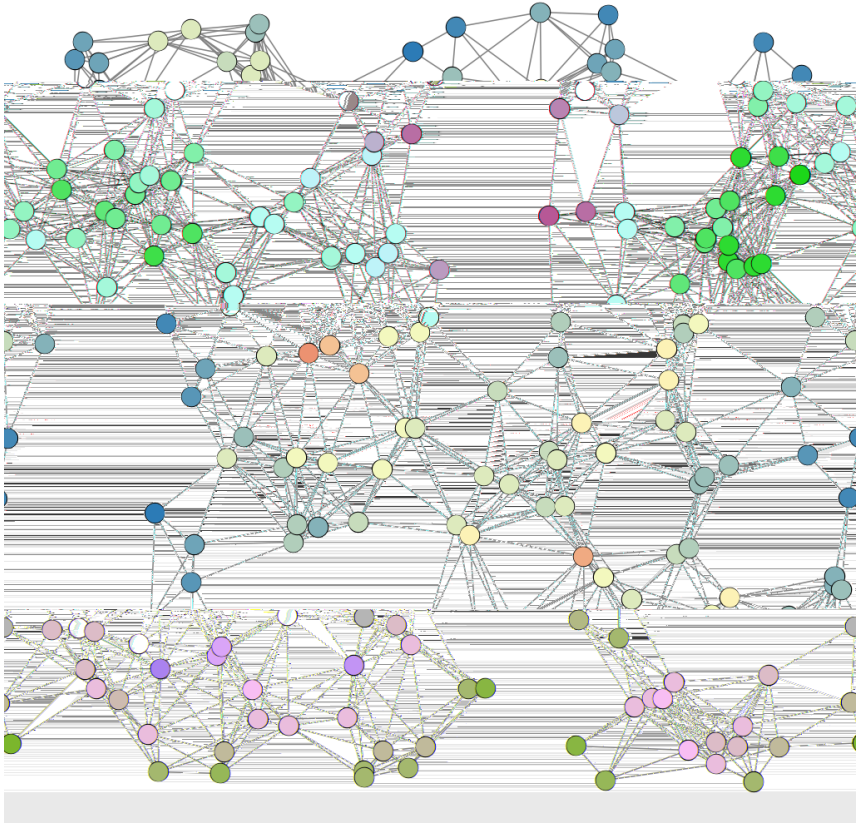

Centralité d'intermédiarité (betweenness)

Centralité : Nombre de « plus courts chemins » passant par le nœud

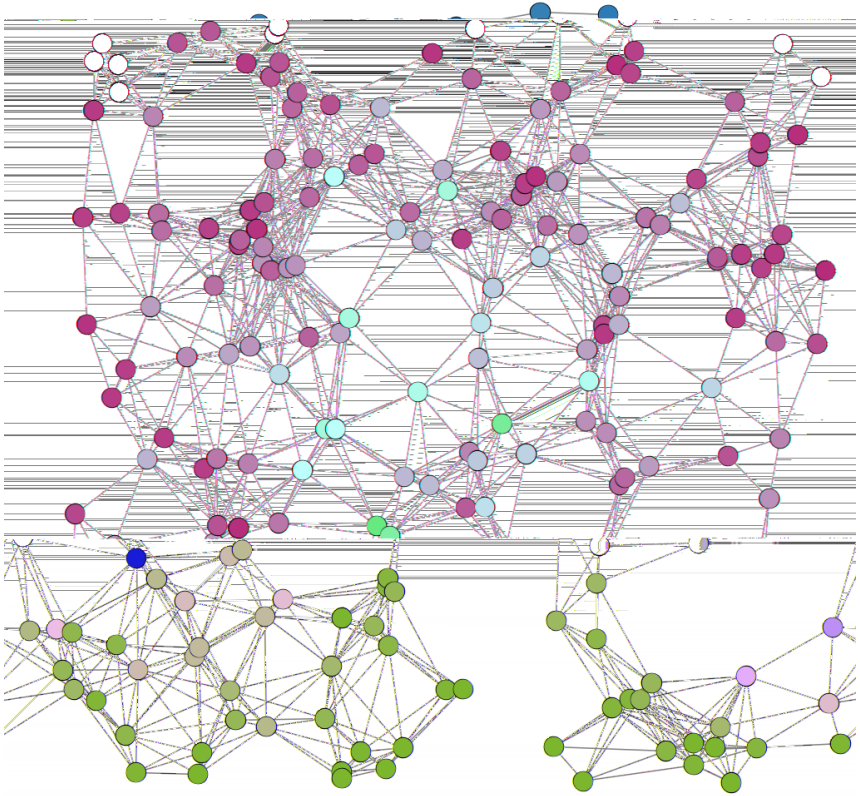

Centralité de proximité (closeness)

Centralité :
Distance moyenne de tous les autres nœuds

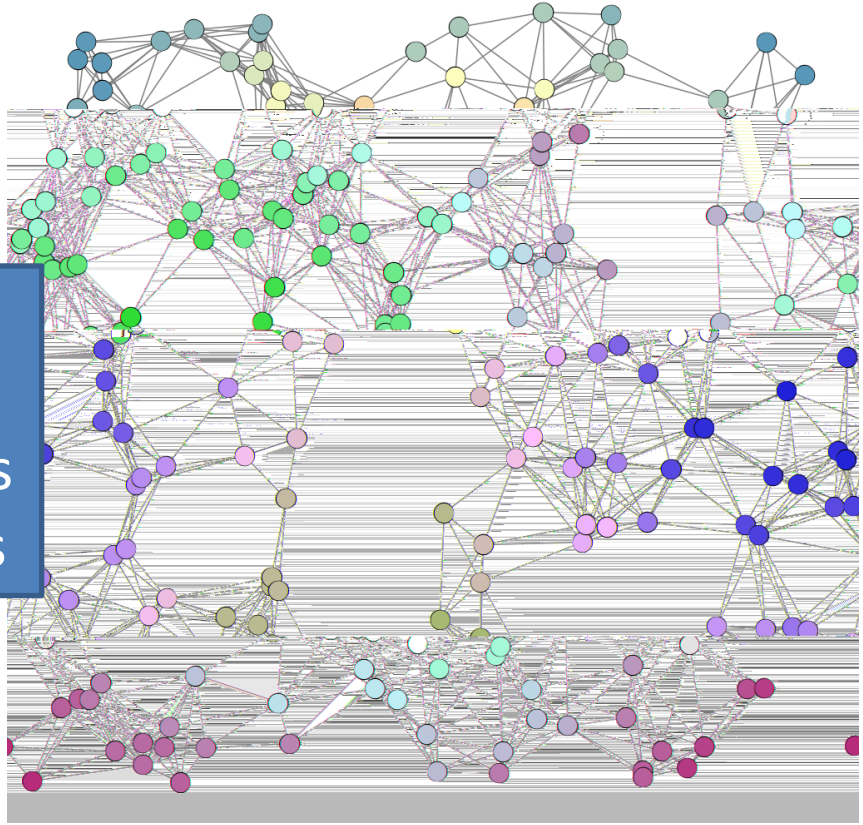

Page-rank

Page-rank (Google) : Diffusion de son importance vers ses voisins

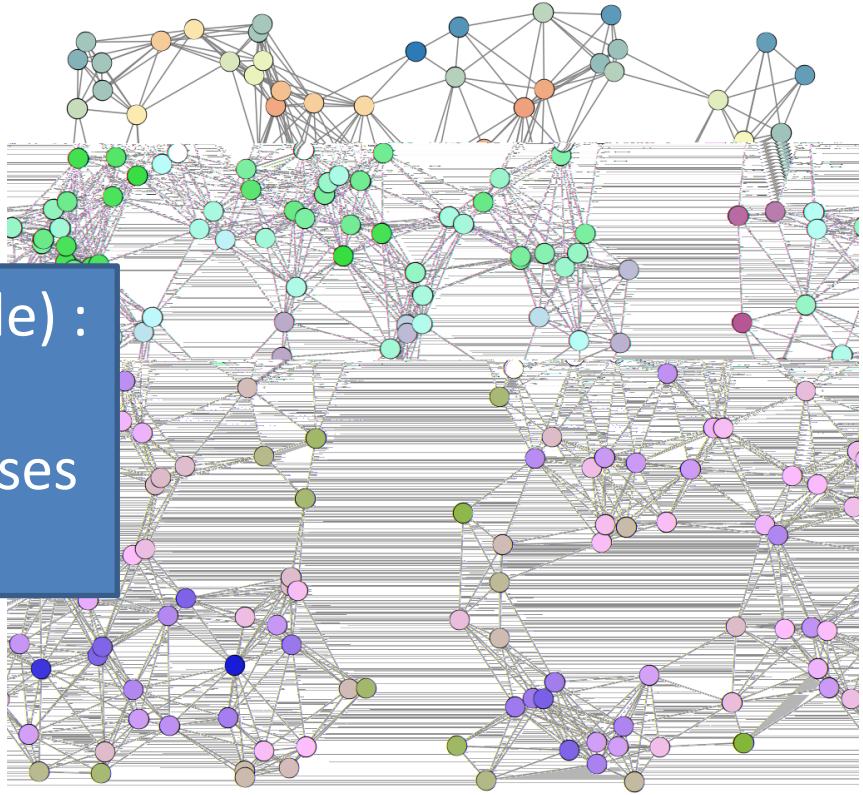

Centralité

- Degré : nombre de voisins
- Betweenness : importance en tant que relai, connecteur, intermédiaire
- Page-rank : importance par diffusion

- Quoi utiliser ? Dépend très fort du business case

- Hors présentation :
  - K-coreness : nombre de voisins de même k-coreness
  - Closeness : centralité « topologique »

Caractériser un réseau

DISTANCE/SIMILARITÉ

Plus court chemin/Distance

- Dijkstra : Calcul du « plus court chemin » entre deux nœuds
- Chaque lien possède un « poids » (longueur, coût…)
- Distance = ∑ poids (=nbr de liens si non pondéré)
- Variante « A* » : pour les réseaux géographiques (utilisé par les GPS)
- Peut ne pas être unique. Le nombre de « plus courts chemins » est aussi une métrique de proximité

Six degrees of separation

- Théorie : distance entre chaque personne sur terre ≤ 6 (via 5 connaissances intermédiaires)
- « Degré de séparation » = plus petite distance
- Facebook : moyenne des moyennes : 4,57

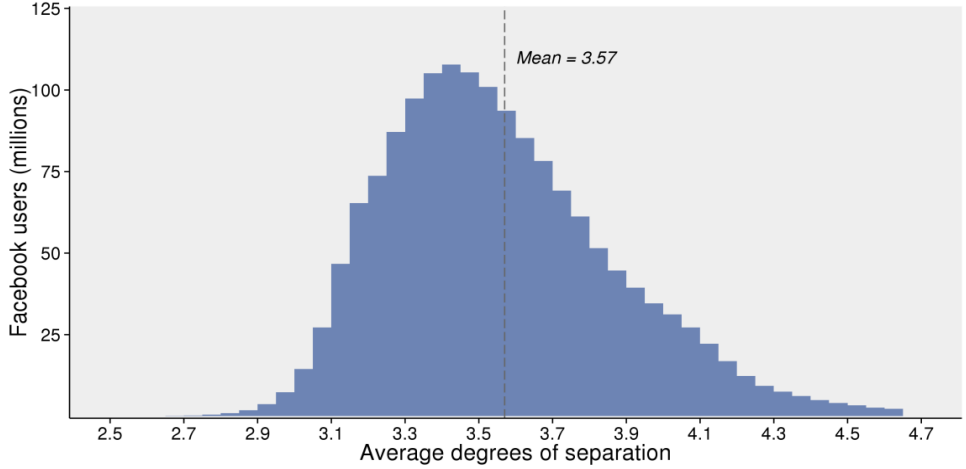

https://research.fb.com/three-and-a-half-degrees-of-separation/

Similarité de Jaccard

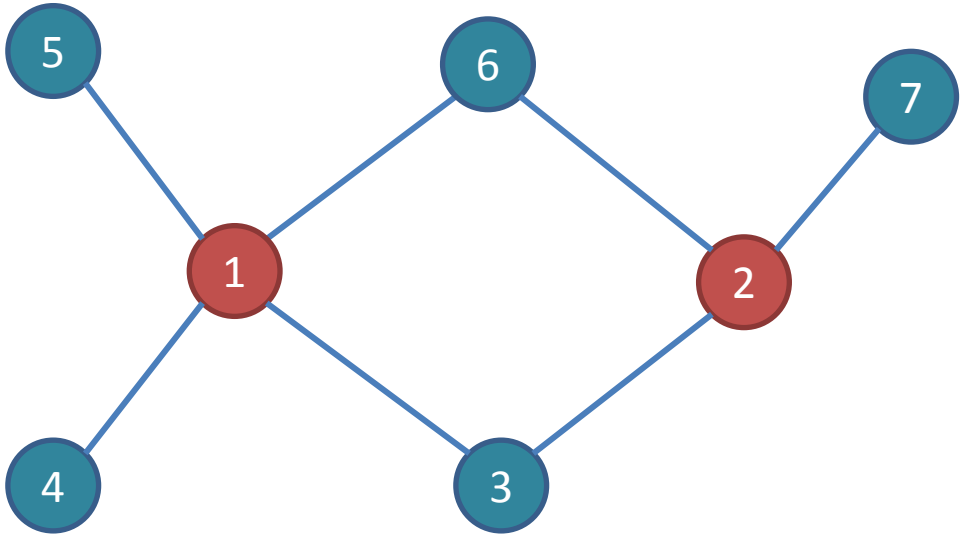

Similarité de Jaccard :

$$\frac{\#\text{ voisins communs}}{\#\text{ voisins totaux}}$$

$$2/5 = 0.4$$

Distance

- Plus court chemin
- Similarité de Jaccard

- Hors présentation :
  - Connectivité
  - Nombre de plus courts chemins
  - Dépendance sociale (social neighbors)

Caractériser un réseau

CLUSTERING

Composantes connexes

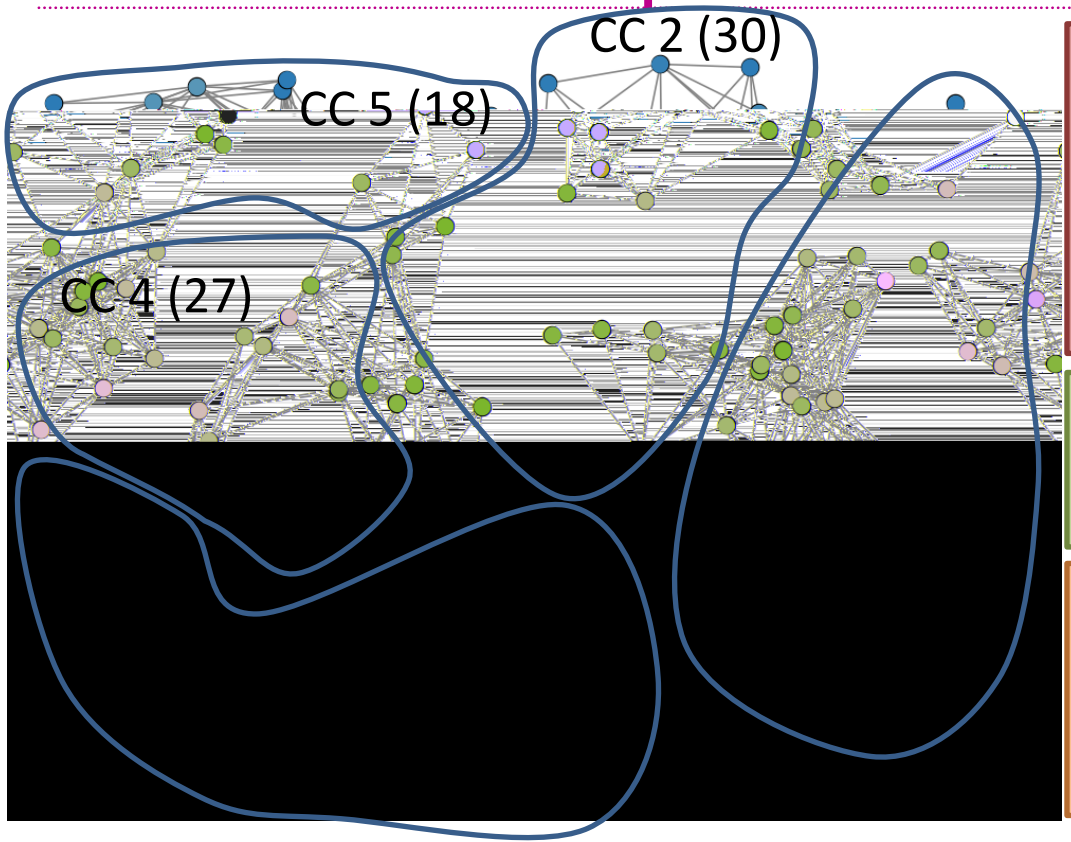

Composante connexe : ensemble (maximal) de nœuds avec un chemin entre chaque paire de nœuds

Composante géante *(giant component)* : la plus grande CC

Beaucoup d'analyses peuvent (doivent) se faire isolément sur chaque composante

Composante connexe

Dimona (all)

	Taille de la CC	Nbre de CC
1	2	25 929
2	3	5 638
3	4	1 584
4	5	614
…	…	…
35	48	1
36	55	1
37	96	1
38	6 965 132	1

25 929 situations avec :

- Un employé sans aucun autre* employeur
- Dans une entreprise sans autre* employé

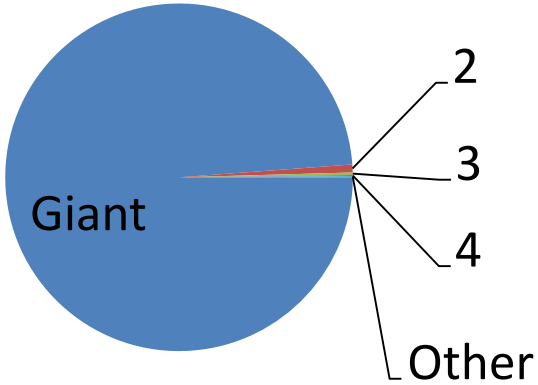

Giant component : 6,53 millions d'employés (99,3%) sont « collègues de (ex-)collègues de … » via 430K employeurs (92%)

* Dans la période considérée

Composante géante

- Diamètre : 20
- Médiane : distance = 6

- → 50 % des « couples » sont « collègue de collègue de collègue »
- Percentile 95 : distance = 8 (+1 « de collègue »)
- Il y a des « super-connecteurs » : tous les enseignants sont collègues !

Composante connexe : sub-giants

- Employeur
- Employé « BIS »
- Employé « NISS »

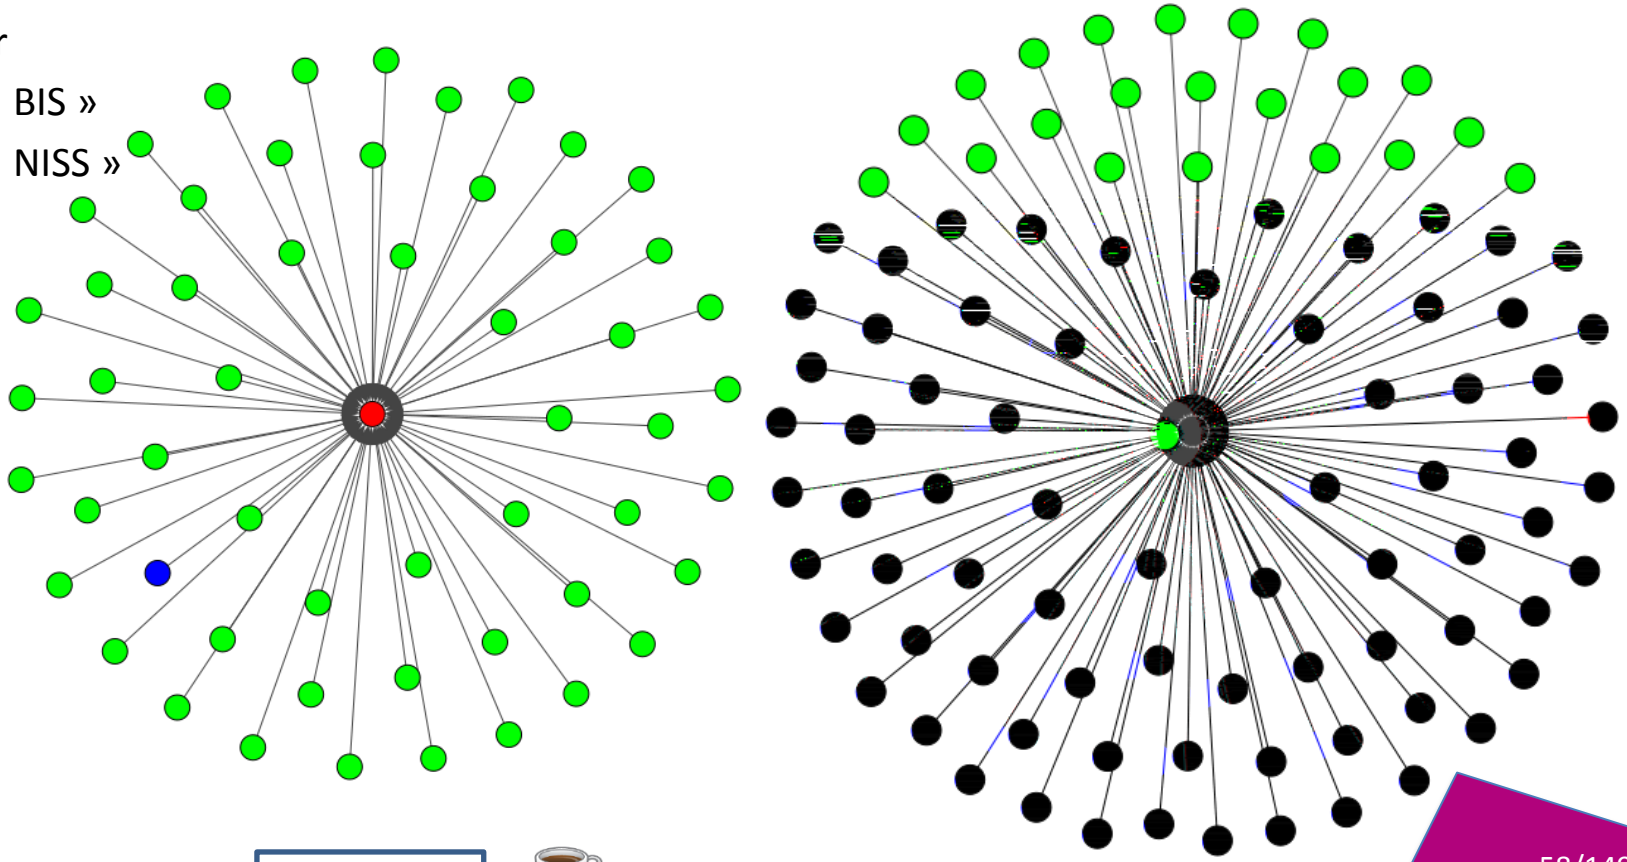

Composante connexe : sub-giants

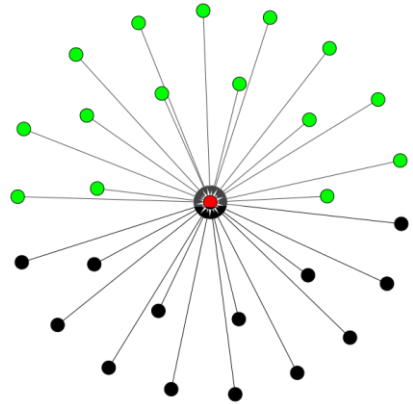
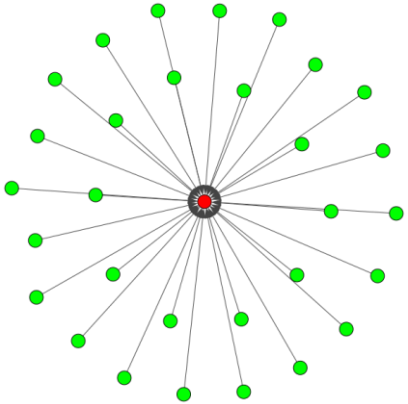
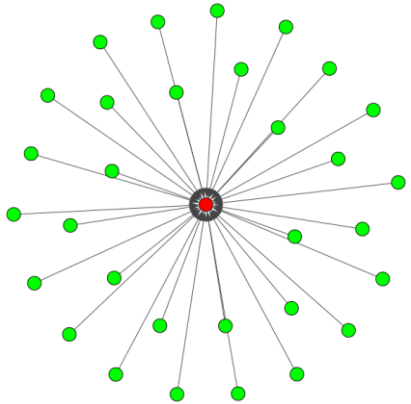
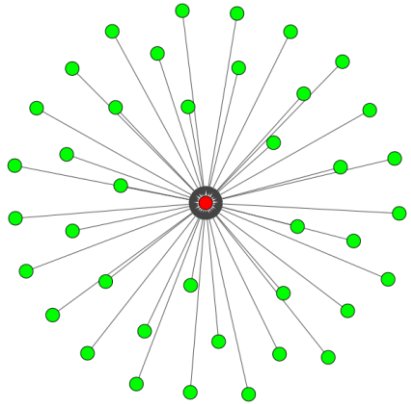
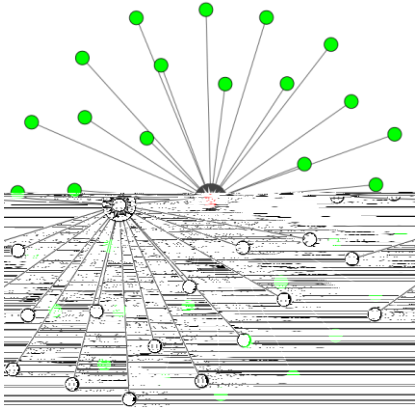
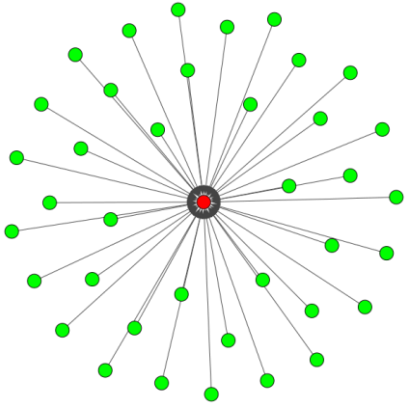
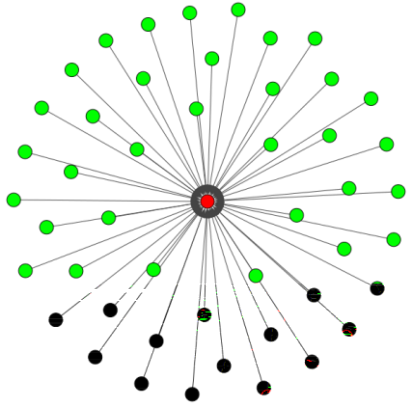
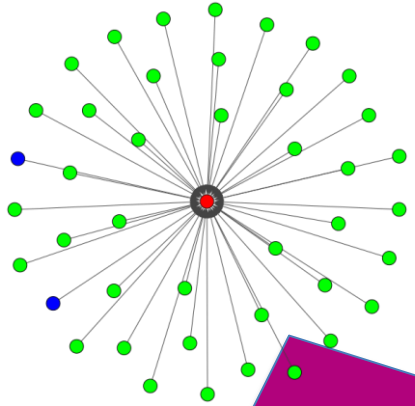

Composante connexe : sub-giants

- Employeur
- Employé « BIS »
- Employé « NISS »

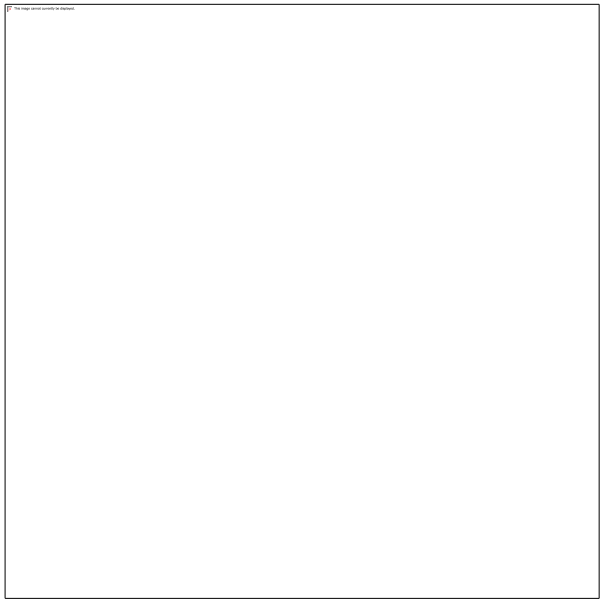

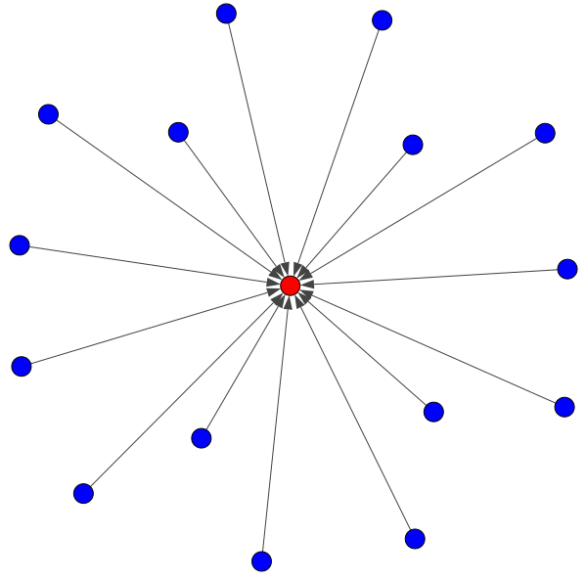

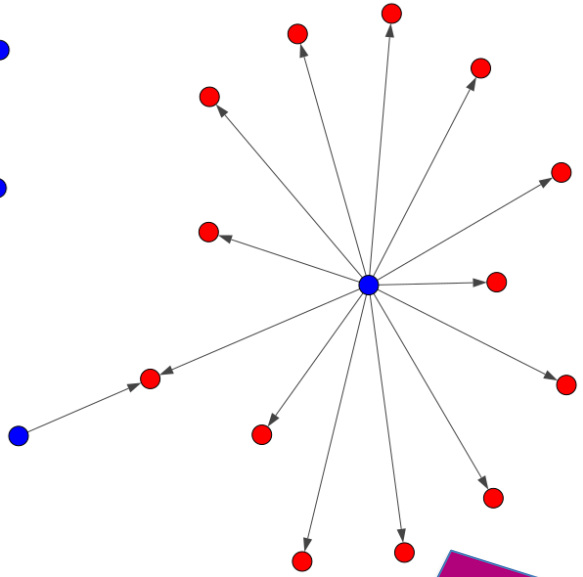

Cliques

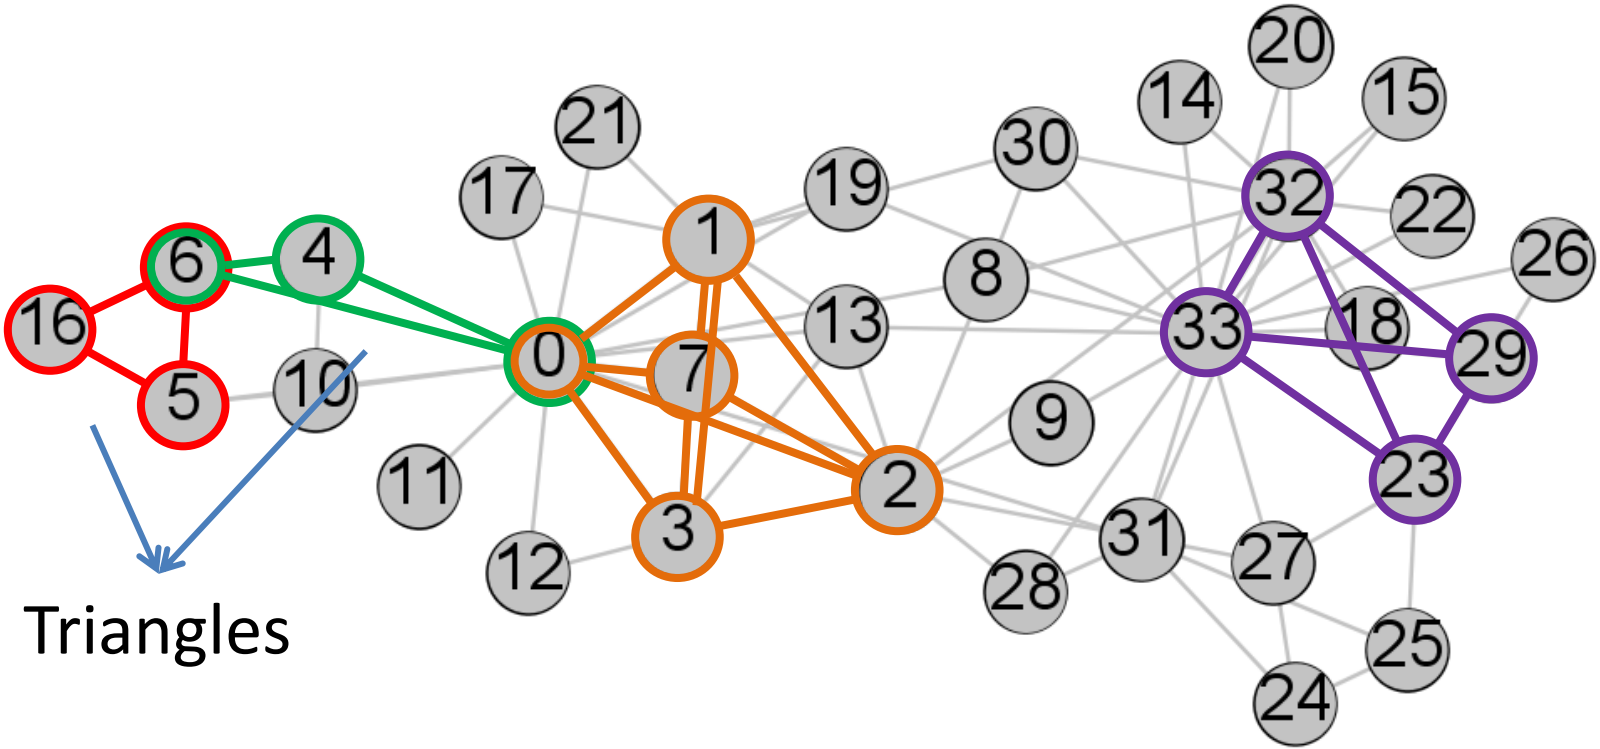
Triangles
0
1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33

Cliques

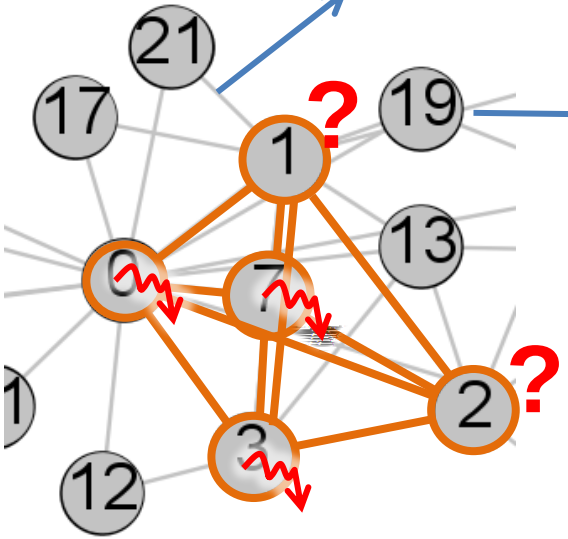

Principe utilisé pour détecter les « spider constructions » (avec une définition de « clique » un peu plus souple)

Communautés

Coefficient de modularité :
- Mesure de la qualité d'une partition
- [-1, 1], liens inter-cluster vs liens intra-cluster
- Bonne partition (coef. ≈ 1):
  liens intra-cluster >> liens inter-cluster
- Optimisation = NP-hard
- Basé sur les liens, pas sur les attributs

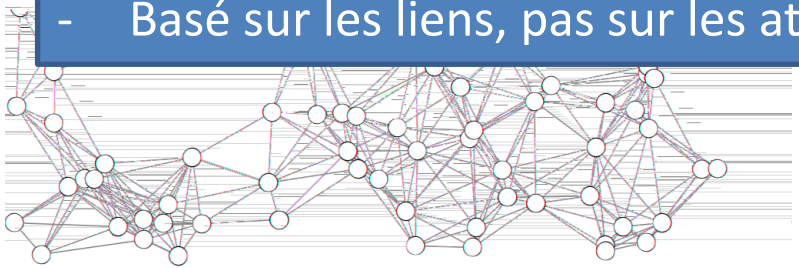

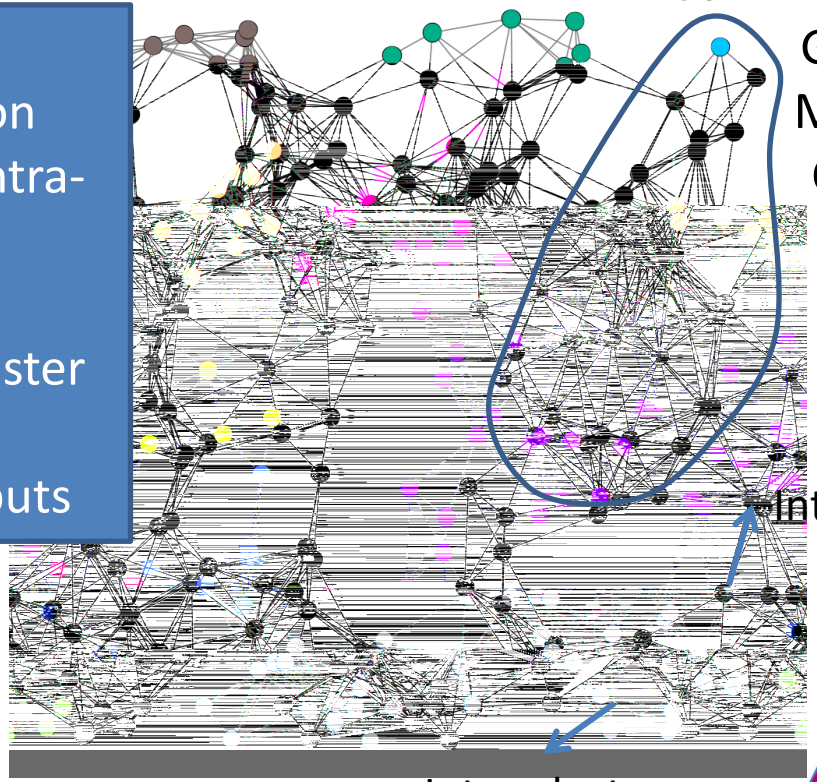

Communautés : intérêts

- Différentes communautés ont souvent des propriétés différentes de l'ensemble
- Permet l'analyse des communautés une par une
- Permet l'identification des « *missing links* » et des « *fake links* »
- Inférer des caractéristiques (attributs)
- Vue d'ensemble avec un « graphe de clusters » (+drill-down)

Algorithme de Louvain (UCL, 2008)

Phase 1

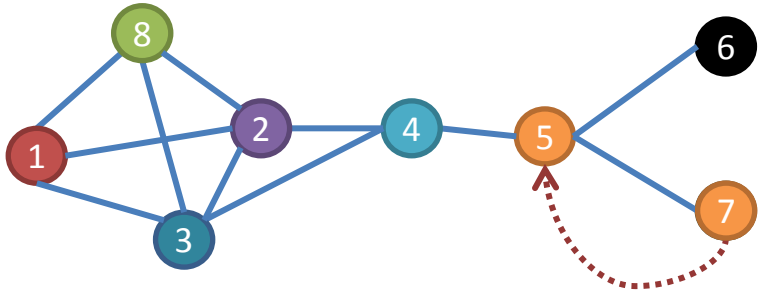

Améliore la « modularity »?
Si oui, migrer

Phase 2

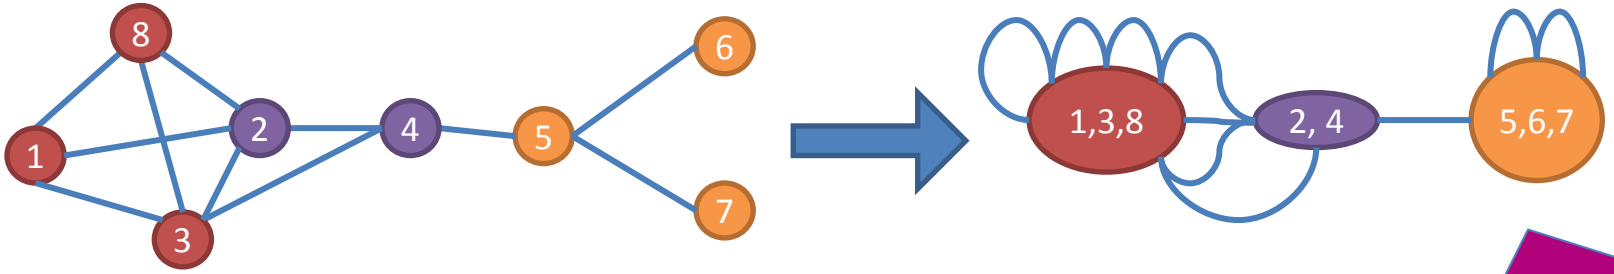

Fast unfolding of communities in large networks, V. Blondel, J.-L. Guillaume, R. Lambiotte, E. Lefebvre, 2008

Clustering

- Composantes connexes : groupes « déconnectés »
- Cliques : groupes « totalement connectés »
- Communautés : groupes « sociaux »

Hors présentation : notion de « fortement » ou « faiblement » connecté si on tient compte des réseaux dirigés

Caractériser un réseau

HOMOPHILIE

Homophilie / Assortativité

- Homophilie / Assortativité : formalisation du « qui se ressemble s'assemble »
- Réseau « homophile » : les nœuds similaires sont mieux liés que les nœuds différents
- En détection de fraude/criminalité : plus de chances de trouver des fraudeurs dans le voisinage d'un fraudeur que n'importe où

Questions ?

Pause !

Visualiser un réseau

Visualiser

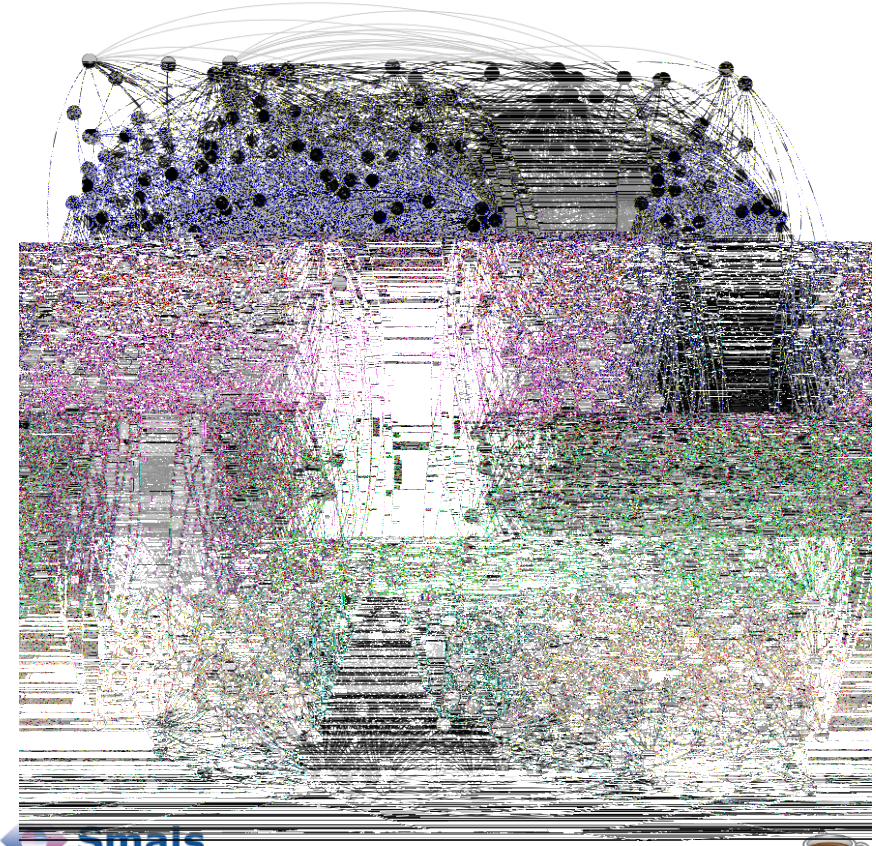

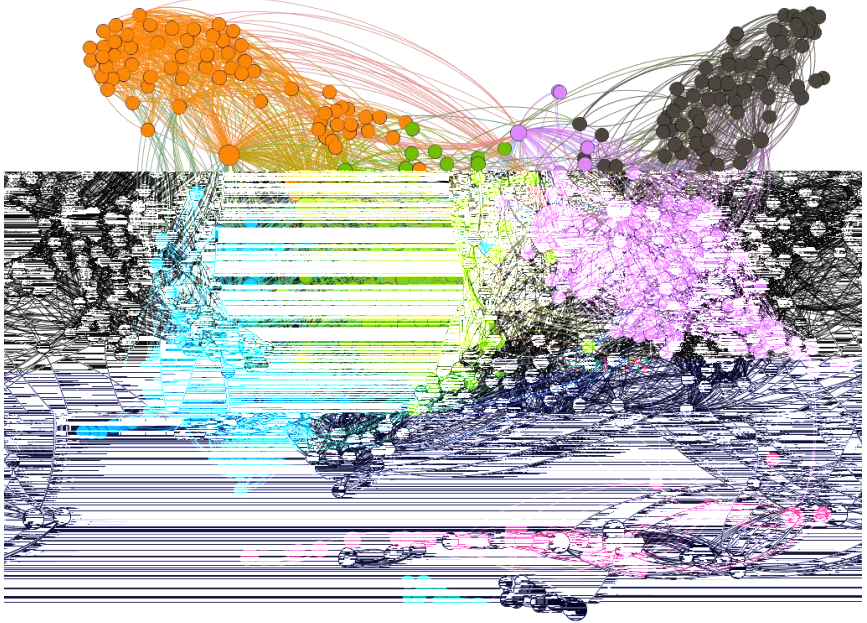

Visualiser un réseau

SPATIALISATION (LAYOUT)

Spatialisation

- Cas simple : graphe planaire = qui peut se dessiner sans croisement
- En général :
  - Minimiser les croisements
  - Rapprocher les nœuds connectés
  - Éloigner les nœuds non-connectés

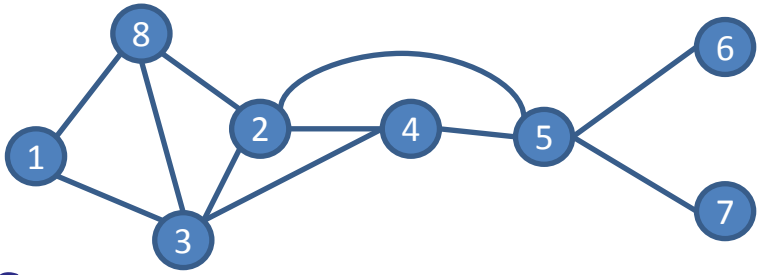

Spatialisation

- Force-directed :
  - Force attractive (spring) entre deux nœuds liés
  - Force répulsive entre tous les nœuds
- Spectral : Utilisation des vecteurs/valeurs propres (*eigenvectors/values*)
- Autres : Hiérarchiques, circulaires, linéaires…

Spatialisation

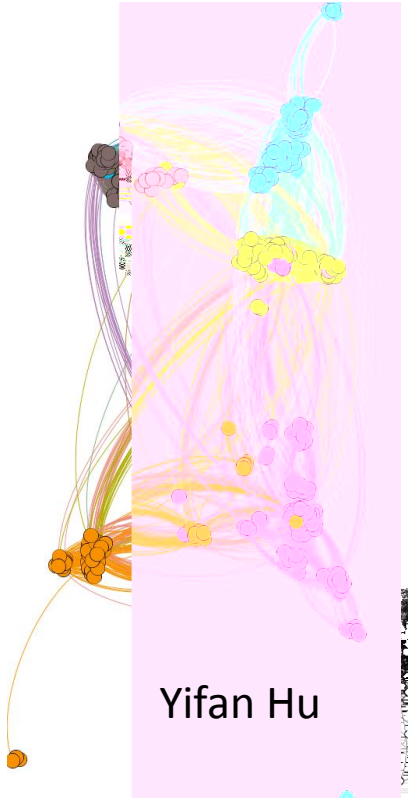

Yifan Hu

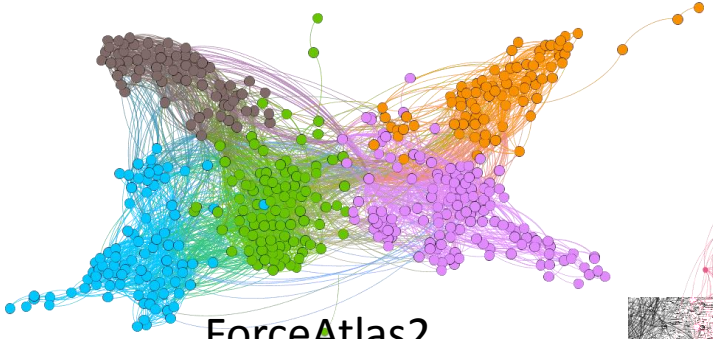

ForceAtlas2

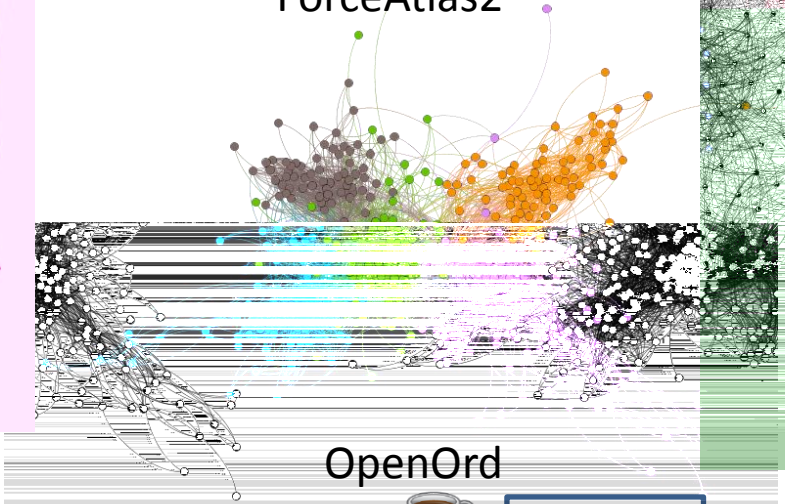

OpenOrd

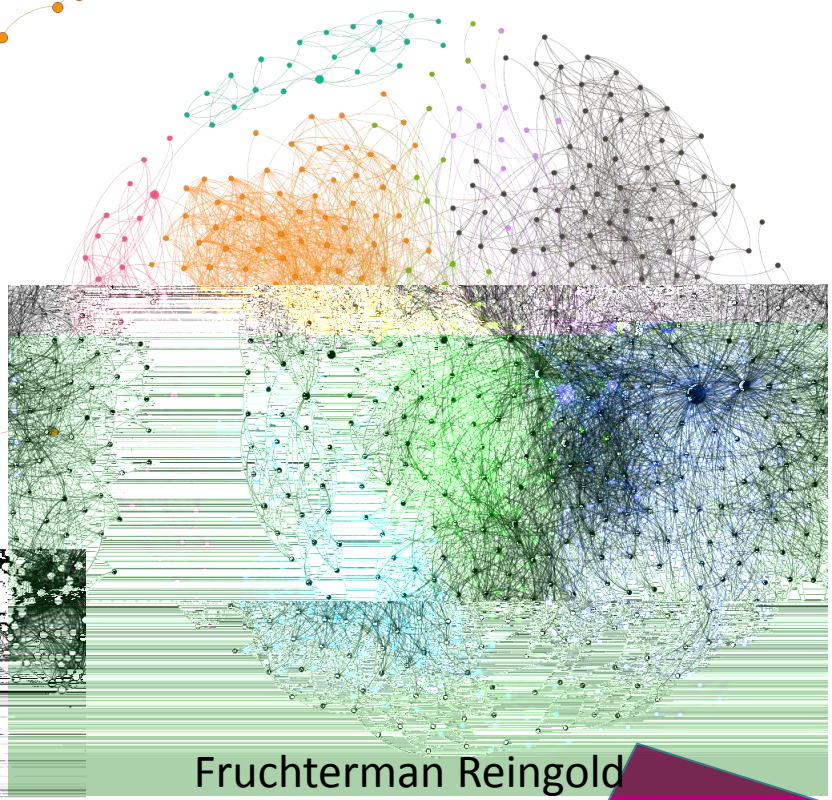

Fruchterman Reingold

Visualiser un réseau

SIMPLIFICATION

Simplification

- Au-delà de quelques centaines de nœuds, visualiser un graphe est illusoire
- Plusieurs méthodes permettent une approche
  - Découper le graphe
  - Supprimer des nœuds
  - Fusionner des nœuds

Découper le graphe

- Composantes connexes
  → Méthode naturelle, pas de perte

- Communautés
  → On perd les relations inter-communauté

Filtrer des nœuds

- Supprimer les super-connecteurs (degré élevé)
  → augmente le nombre de composantes connexes

- Supprimer les feuilles (degré/K-core faible)
  → focus sur le « backbone/core »

Fusionner des nœuds

- Contraction : fusionner des groupes
- Projection bipartite : conversion d'un graphe biparti en 2 graphes unipartis.

Contraction

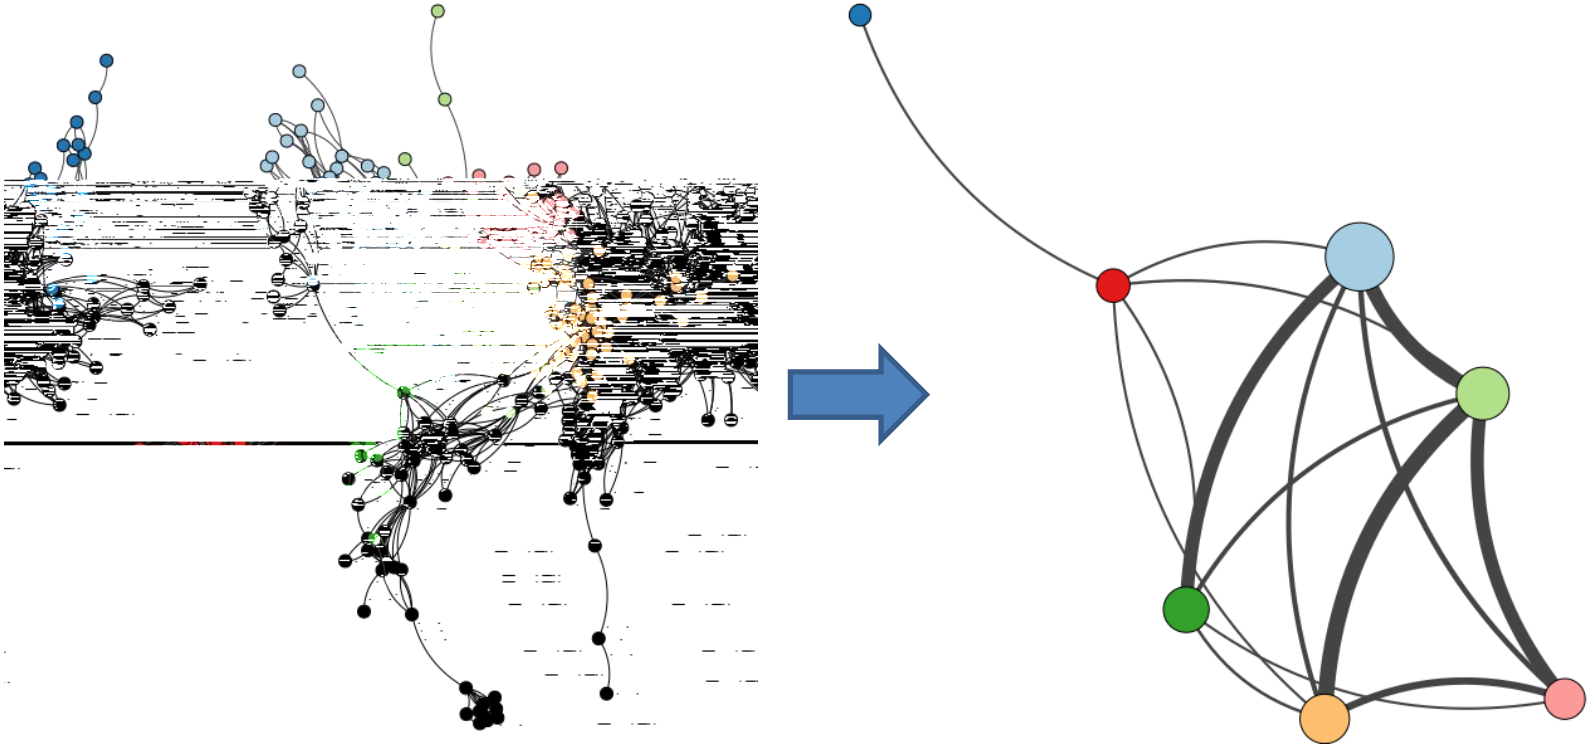

Contraction

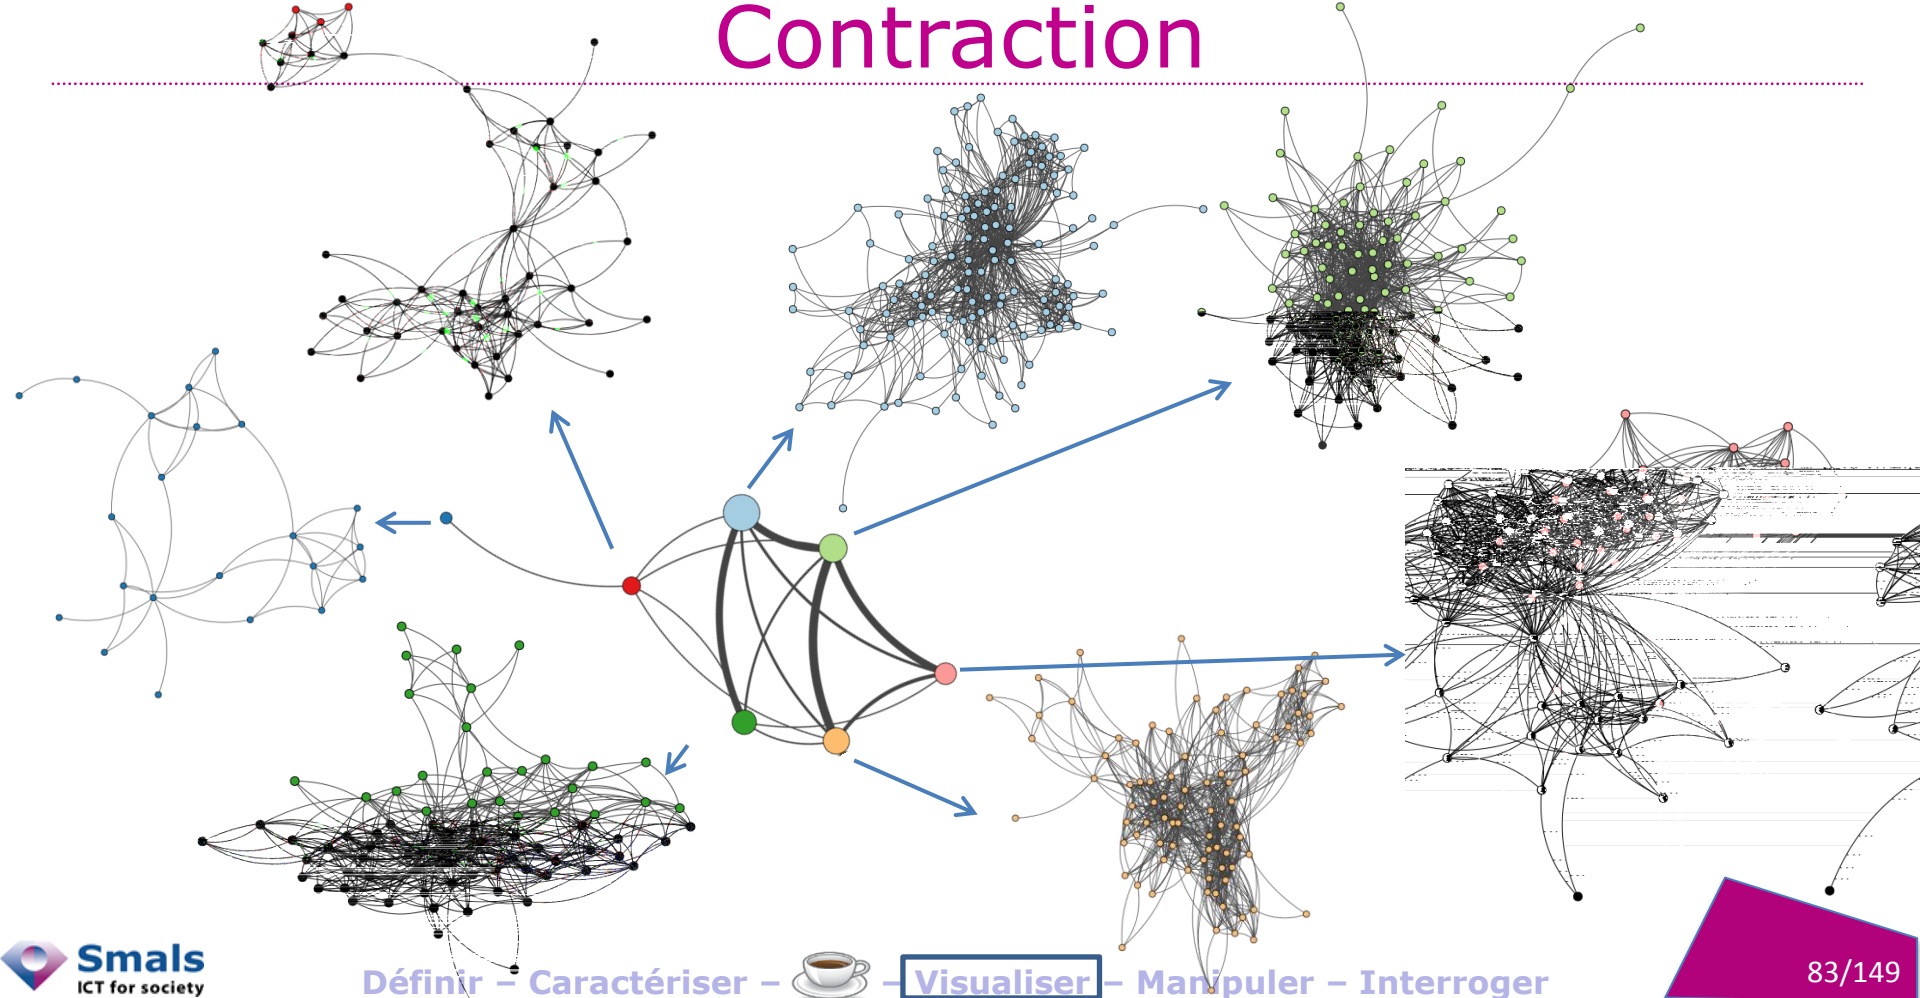

Contraction : BCE (Administrateurs)

- Administrateurs BCE :
  - Composante géante = 655.158 nœuds (sur ~10^6)
- On applique Louvain :
  - 743 communautés (~10” en mono-thread)

Contraction : BCE (Administrateurs)

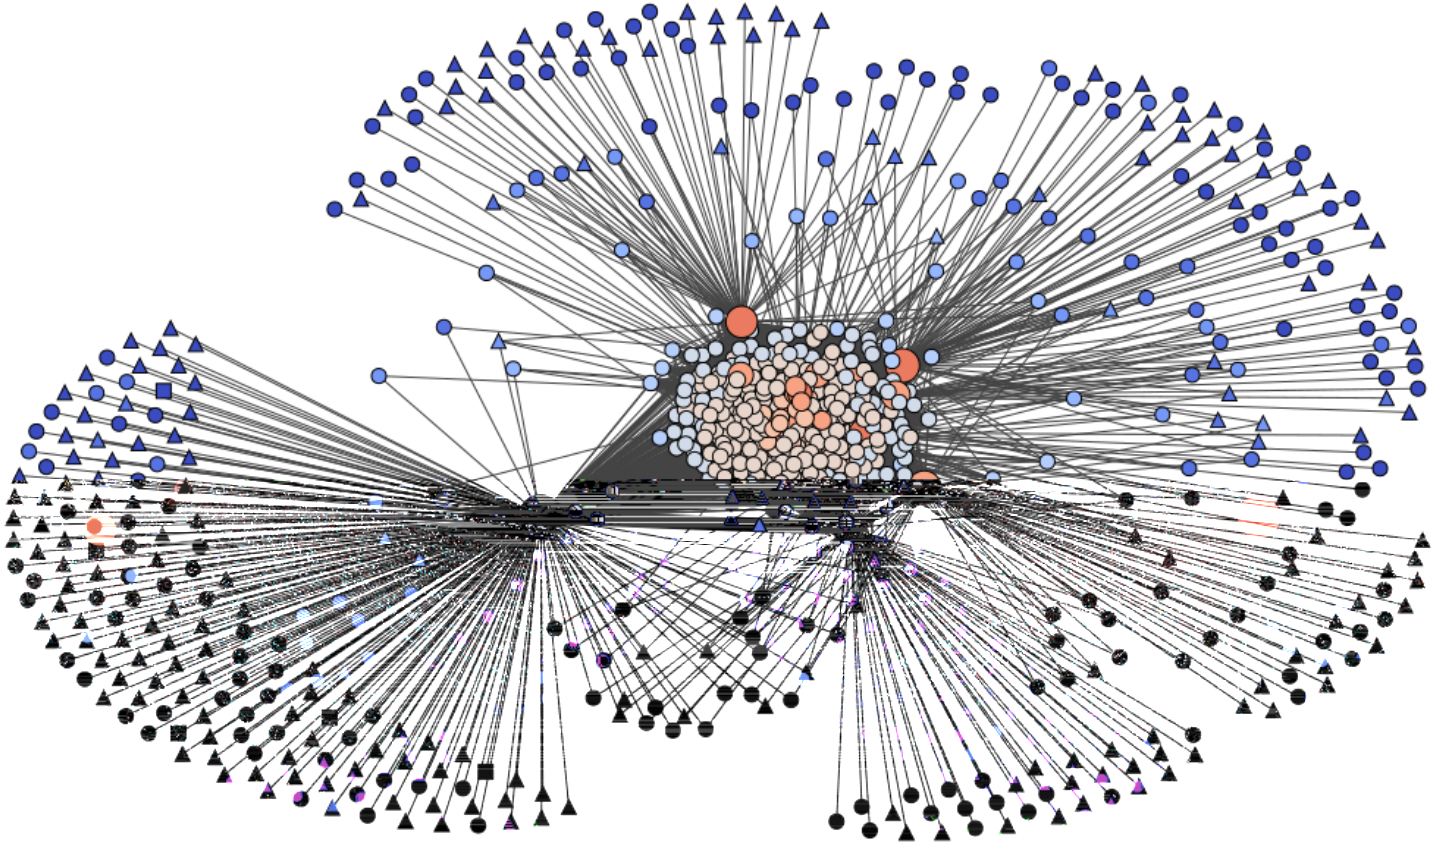

Projection bipartite

Travailleur Employeurs

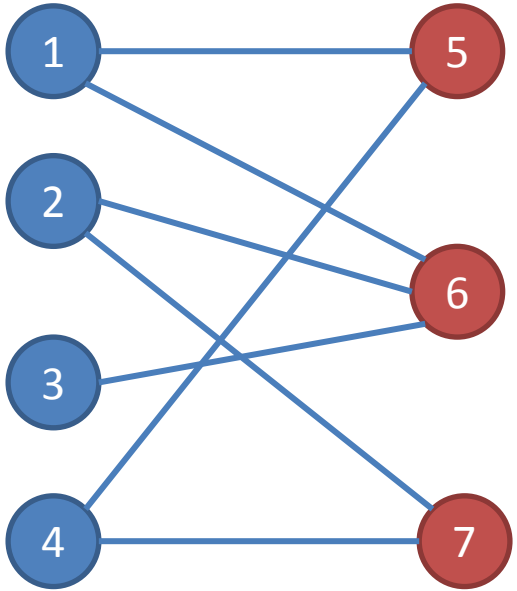

Collègues

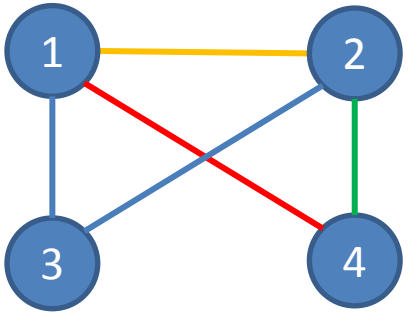

Travailleurs communs

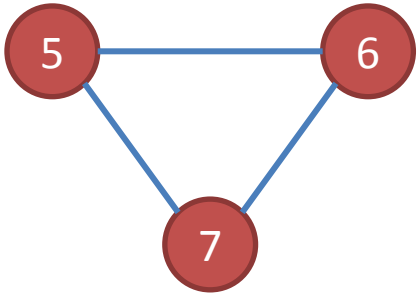

Visualiser un réseau

OUTIL DESKTOP : GEPHI

Gephi

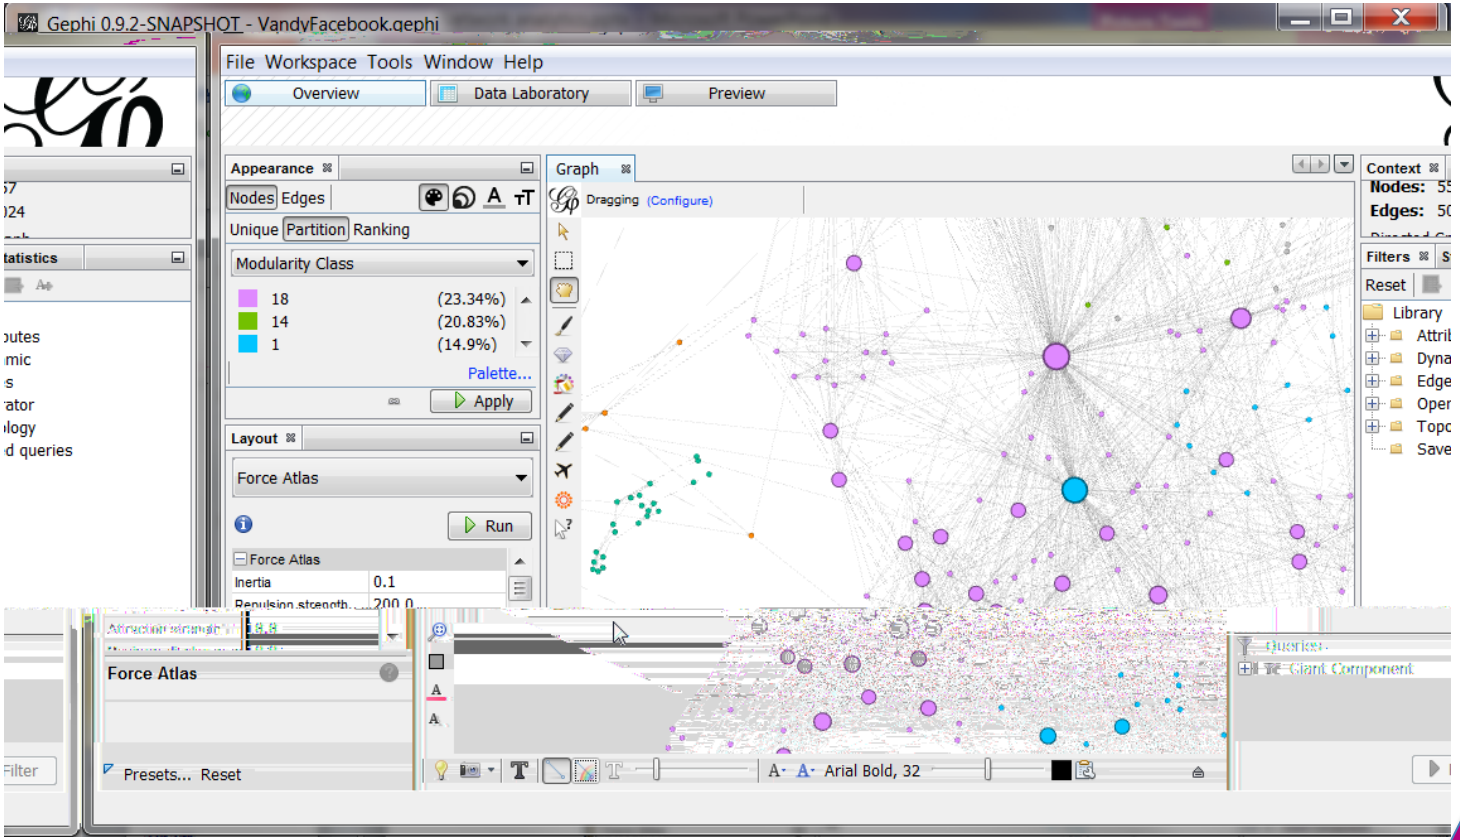
Gephi 0.9.2-SNAPSHOT - VandyFacebook.gephi
File Workspace Tools Window Help
Overview
Data Laboratory
Preview
Appearance
Nodes Edges
Unique Partition Ranking
Modularity Class
18 (23.34%)
14 (20.83%)
1 (14.9%)
Palette...
Apply
Layout
Force Atlas
Run
Force Atlas
Inertia 0.1
Graph
Dragging (Configure)
Context
Nodes:
Edges:
Filters
Reset
Library
Force Atlas
Presets... Reset
Arial Bold, 32

Visualiser un réseau

LIBRAIRIE JS: VIS.JS

vis.js

```
<div id="graph"></div>
<script type="text/javascript">
var nodes = new vis.DataSet([
    {id: 1, label: 'Node 1'},
    {id: 2, label: 'Node 2'},
    {id: 3, label: 'Node 3'},
]);
var edges = new vis.DataSet([
    {from: 1, to: 3},
    {from: 1, to: 2},
    {from: 3, to: 3}
]);
var container =
document.getElementById('graph');
var data = {
  nodes: nodes,
  edges: edges
};
var options = {};
var network =
  new vis.Network(container,
                  data,
                  options);
</script>
```

http://visis.org/examples/network/basicUsage.html

Visualiser un réseau

OUTIL WEB : LINKURIOUS

Linkurio.us

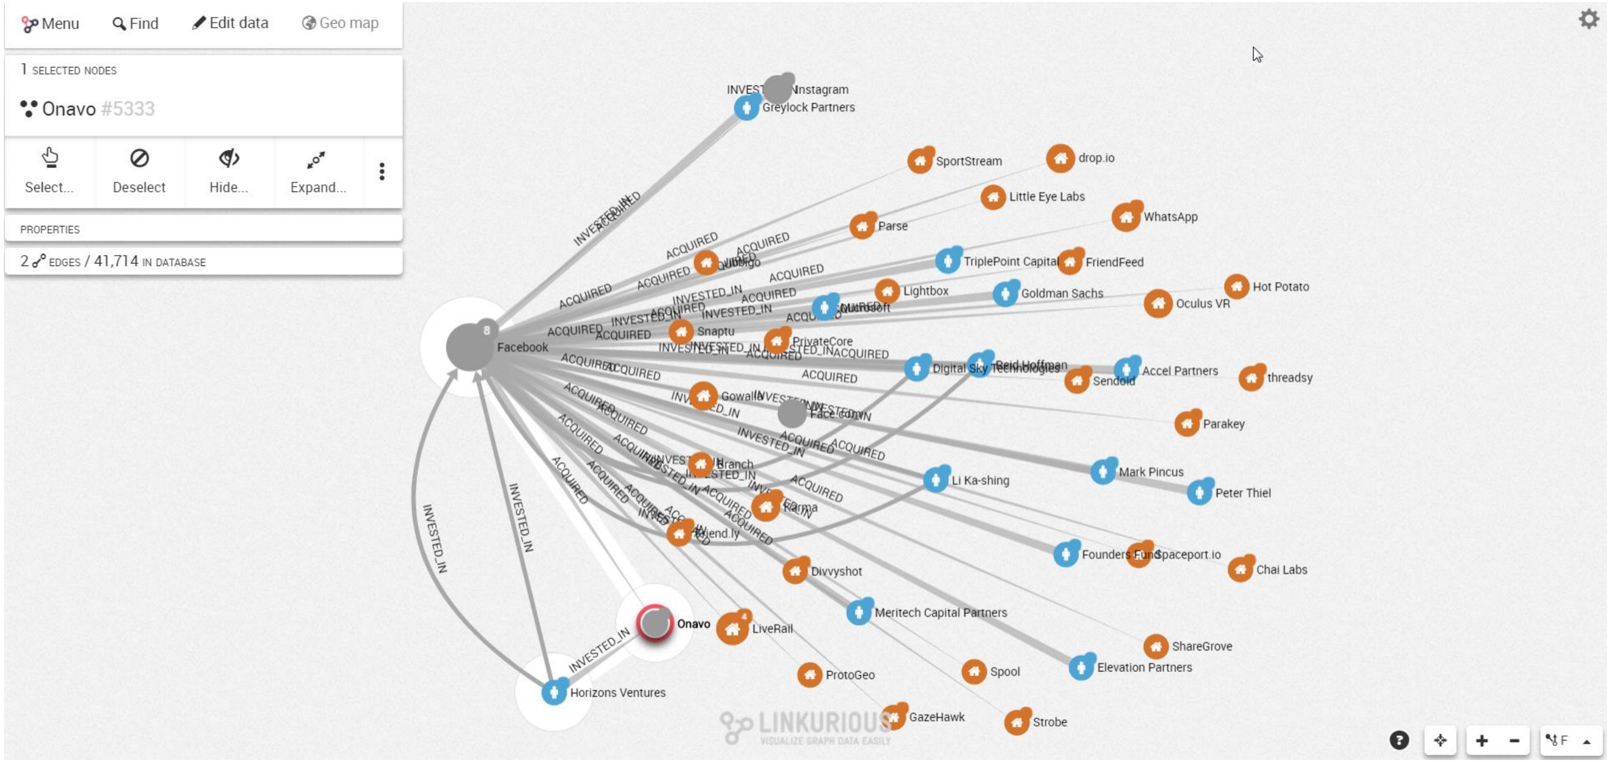
Menu
Find
Edit data
Geo map
1 SELECTED NODES
Onavo #5333
Select...
Deselect
Hide...
Expand...
PROPERTIES
2 EDGES / 41,714 IN DATABASE
Instagram
Greylock Partners
SportStream
drop.io
Little Eye Labs
WhatsApp
Parse
TriplePoint Capital
FriendFeed
Lightbox
Goldman Sachs
Hot Potato
Oculus VR
Snaptu
PrivateCore
Facebook
Digital Sky Technologies
Sendoid
Accel Partners
threadsy
Gowalla
Parakey
Branch
Mark Pincus
Li Ka-shing
Peter Thiel
Karma
Friend.ly
Founders Fund
Spaceport.io
Chai Labs
Divvyshot
Meritech Capital Partners
Onavo
LiveRail
ShareGrove
Elevation Partners
Horizons Ventures
ProtoGeo
Spool
GazeHawk
Strobe
ACQUIRED
INVESTED_IN
LINKURIOUS
VISUALIZE GRAPH DATA EASILY

Visualiser un réseau

AUTRES OUTILS

Outils desktop

- Gephi https://gephi.org OS
- TouchGraph http://www.touchgraph.com €
- Cytoscape http://www.cytoscape.org OS
- Maltego https://www.paterva.com
- NodeXL https://nodexl.codeplex.com OS

- SAS Network Analytics €
- IBM i2 €

Outils Cloud

- Linkurio.us https://linkurio.us €
- Keylines https://cambridge-intelligence.com/keylines €

Librairies web

- Vis.js http://visjs.org OS
- Cytoscape.js http://js.cytoscape.org OS
- Sigma.js http://sigmajs.org OS
- D3.js https://d3js.org OS
- OGMA (Linkurio.us SDK) €

Visualiser un réseau

USE CASE : SOCDUMPV2

SocDumpv2 : Contexte

- Pour différents services d'inspection, on veut visualiser le réseau d'un groupe de personnes ou entreprises (suspectées de *dumping social* ou autre fraude)
- À partir de données de (principalement) :
  - Dimona : relations employeurs – employés (en Belgique)
  - BCE/KBO : relations sociétés – mandataires
  - Limosa : Travailleurs étrangers travaillant en Belgique
  - DDT : Sociétés – Chantiers – Sous-traitants
  - CAW : Chantiers – Travailleurs – Sociétés

SocDumpv2 : modules

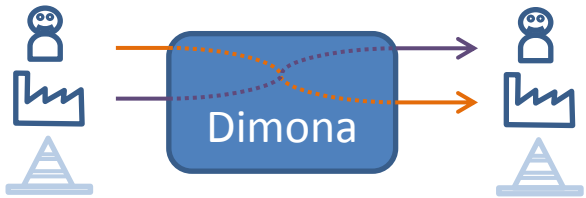

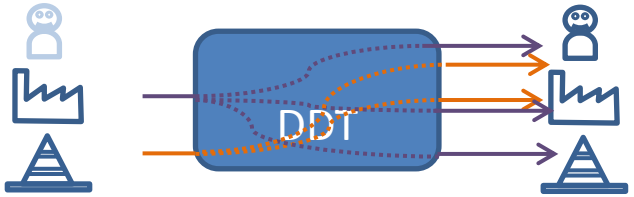

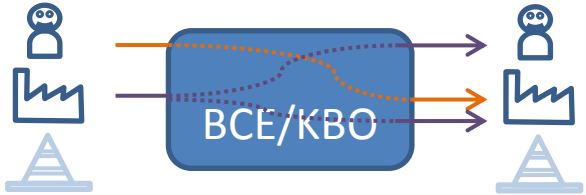

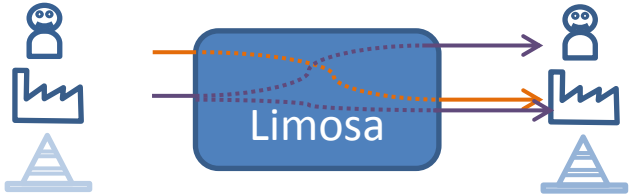

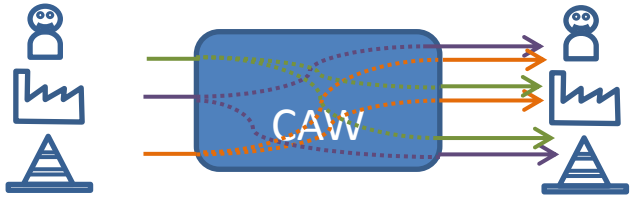

SocDumpv2 : modules

- Chaque module produit 2 types d'outputs :
  - Des nœuds : personnes, entreprises, POW
  - Des relations
- Les nœuds d'outputs de chaque module peuvent servir d'input pour un autre
- Exemple :

  NISS –[BCE]-> Entreprises –[Dimona]-> Employés

SocDumpv2 : qualité

- La qualité n'est pas toujours au rendez-vous !
- Une entreprise peut être désignée soit par un identifiant « source authentique » (numéro BCE, matricule…), soit par une un numéro interne à l'application (principalement DDT, Limosa)
- Idem pour les personnes : numéro NISS, ou numéro interne

SocDumpv2 : Flux

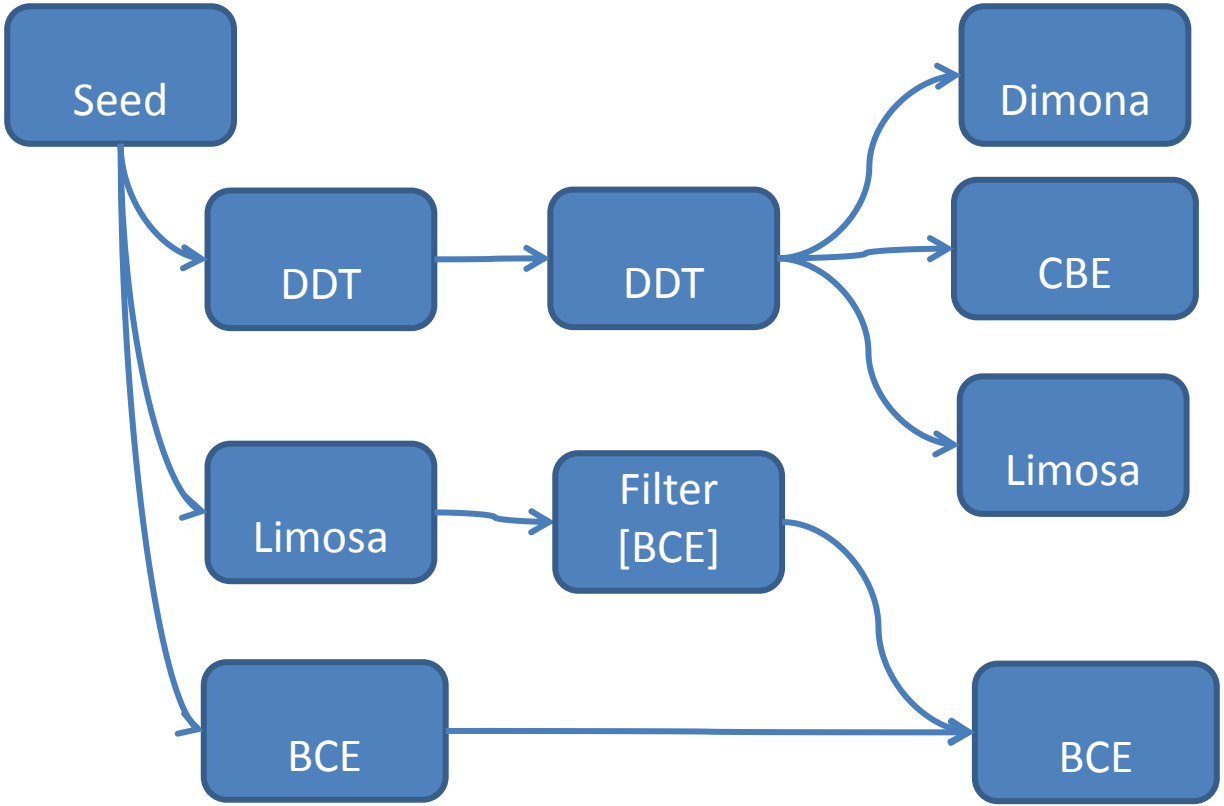

SocDumpv2

- Après la recherche des données, on va :
  - Collecter les adresses des entreprises
  - Enrichir les nœuds (nom des entreprises et des personnes, dates de naissance)
  - Détecter et (éventuellement) fusionner les doublons
  - Calculer une série de métriques (distance, centralité…)
- On visualise ensuite le résultat : Gephi, TouchGraph…

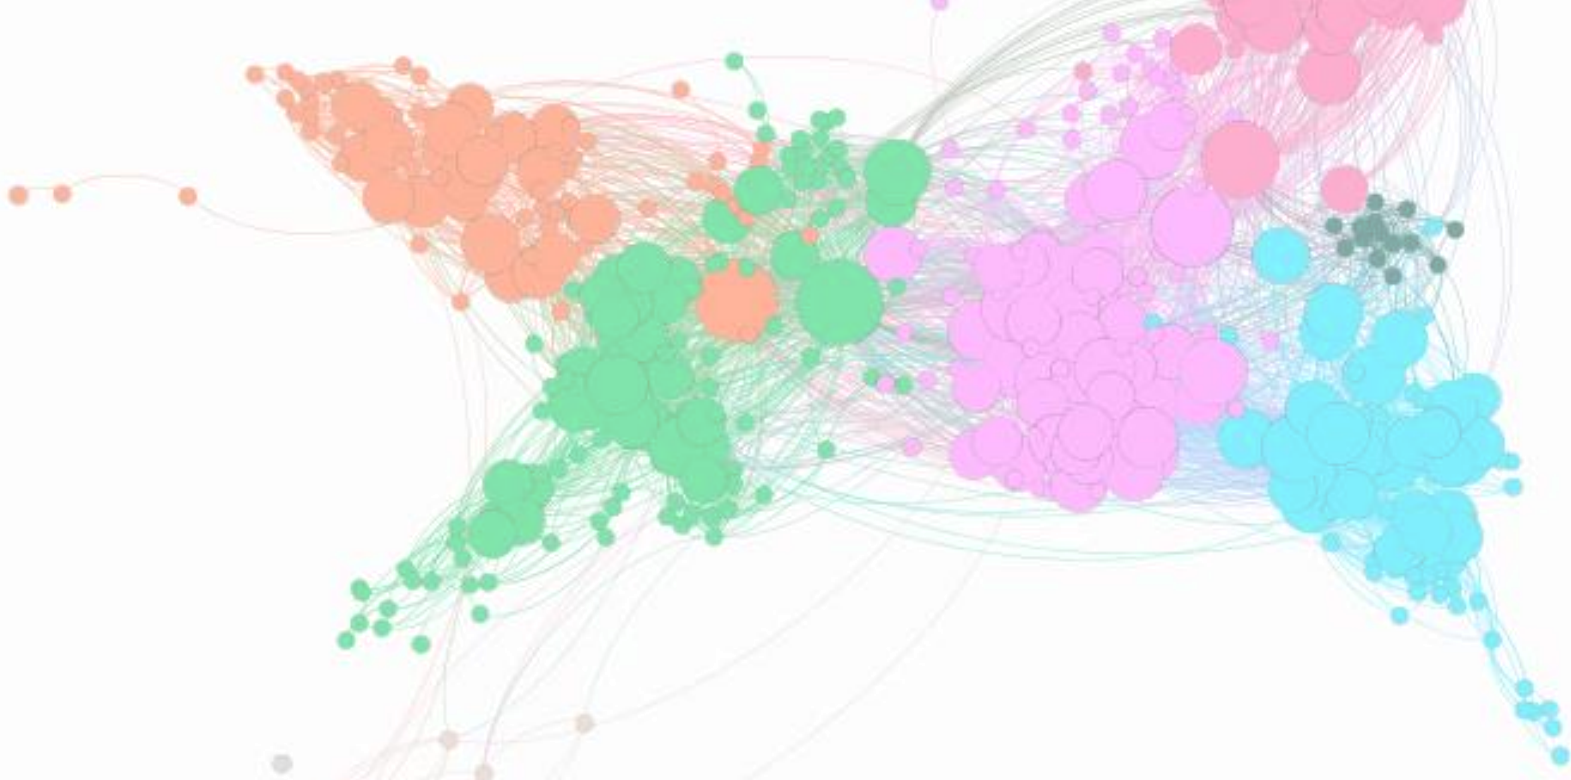

Manipuler un réseau

Manipuler un réseau

IGRAPH (PYTHON/R)

iGraph

- iGraph : librairie C de création, manipulation et analyse de graphes
- Interfacé avec R, Python, Mathematica
- Open Source, GNU GPL v2
- Très populaire dans la communauté scientifique

- \+ : standard, multi-langage, natif, très riche
- \- : mono-cpu, installation pas toujours aisée

iGraph : fonctions

- Génération : de nombreux modèles
- Analyse : centralité, chemins, communauté, recherche de pattern/motifs, comparaison isomorphique…
- Modification : projection bipartite, extraction
- Visualisation : layout, génération d'image
- Import/Export

iGraph, Python vs R.

Python

```
g = ig.Graph()
g.add_vertices(["a","b","c"])
g.add_edges([("a", "b"),
             ("a", "c")])

g.vs["label"] = ["x","y","z"]

g.vs[2]["name"] = "C"
```

R

```
g <-graph(edges =
       c("a", "b", "a", "c"))

V(g)$label = c("x", "y", "z")

V(g)$name[2] = "C"
```

Manipuler un réseau

BIG DATA: GIRAPH & GRAPHX

GraphX

http://spark.apache.org/graphx/

- Librairie de manipulation de graphes pour Spark (framework open source de calcul distribué/Big Data)
- Spark :
  - Souvent utilisé sur Hadoop (pour HDFS)
  - En Scala, Java ou Python
  - GraphX : Uniquement en Scala
- Basé sur les RDDs (non-modifiables)
- + : Permet la manipulation de très gros graphes
- - : Librairie très limitée (à ce stade)

GraphX

```
// Create an RDD for the vertices
val users: RDD[(VertexId, (String, String))] =
sc.parallelize(Array((3L, ("rxin", "student")),
                     (7L, ("jgonzal", "postdoc")),
                     (5L, ("franklin", "prof")))))
// Create an RDD for edges
val relationships: RDD[Edge[String]] =
sc.parallelize(Array(Edge(3L, 7L, "collab"),
                     Edge(5L, 3L, "advisor"),
                     Edge(5L, 7L, "pi")))
Graph val graph = Graph(users, relationships, defaultUser)
```

Giraph

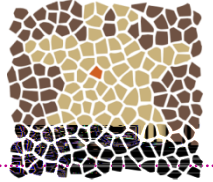

APACHE GIRAPH

http://giraph.apache.org

- "*Apache Giraph* is an iterative graph processing system built for high scalability."
- Extension de Pregel (Google)
- Utilisé par Facebook
- Basé sur MapReduce (Hadoop)

GraphX vs Giraph

- GraphX créé pour être plus performant que Giraph (moins de passage par le disque)
- Benchmark par GraphX largement en sa faveur…
- Mais des benchmarks de Facebook montrent le contraire

https://code.facebook.com/posts/319004238457019/
https://amplab.cs.berkeley.edu/wp-content/uploads/2014/09/graphx.pdf

Interroger un réseau

Interroger un réseau

GRAPH DATABASES

RDBMS et relations

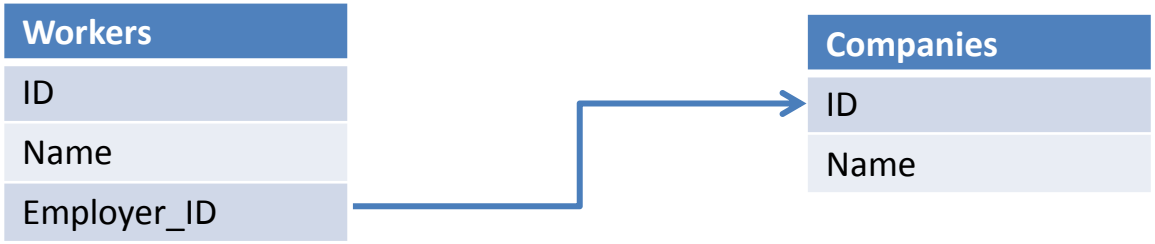

Comment les relations sont implémentées

Employés de Smals ?

Ce qui intéresse le développeur

```
SELECT  Workers.Name
FROM    Workers
JOIN    Companies
  ON    Workers.Employer_ID = Companies.ID
WHERE   Companies.Name = 'Smals'
```

RDBMS et relations

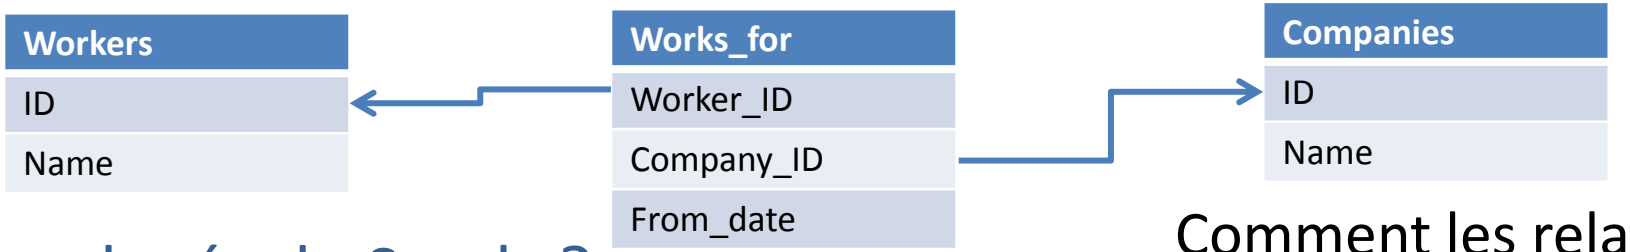

Employés de Smals ?

Comment les relations sont implémentées

Ce qui intéresse le développeur

```
SELECT  Workers.Name
FROM    Workers
JOIN    Works_for
  ON    Workers.ID = Works_for.Worker_ID
JOIN    Companies
  ON    Works_for.Company_ID = Companies.ID
WHERE   Companies.Name = 'Smals'
```

RDBMS et relations

ID	Name
1	Alice
2	Bob
3	Camille
4	Zoé

Liker_ID	Liked_ID
1	3
2	1
2	3
3	2
3	4

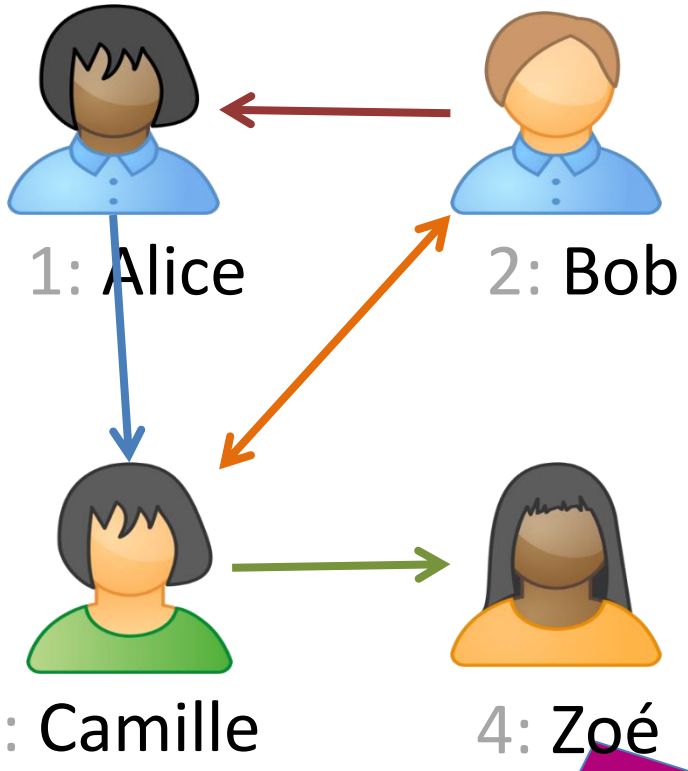


```
SELECT  p1.Name
FROM    People p1
JOIN    Likes
  ON    Likes.Liked_ID = p1.ID
JOIN    People p2
  ON    Likes.Liker_ID = p2.ID
WHERE   p2.Name = "Bob"
```

Qui Bob aime ?

RDBMS et relations

ID	Name
1	Alice
2	Bob
3	Camille
4	Zoé

Liker_ID	Liked_ID
1	3
2	1
2	3
3	2
3	4

```
SELECT  p1.Name
FROM    People p1
JOIN    Likes l1
   ON   l1.Liked_ID = p1.ID
JOIN    Likes l2
   ON   l1.Liker_ID = l2.Liked_ID
JOIN    People p2
   ON   l2.Liker_ID = p2.ID
WHERE   p2.Name = "Bob"
```

Qui Bob (aime)² ?

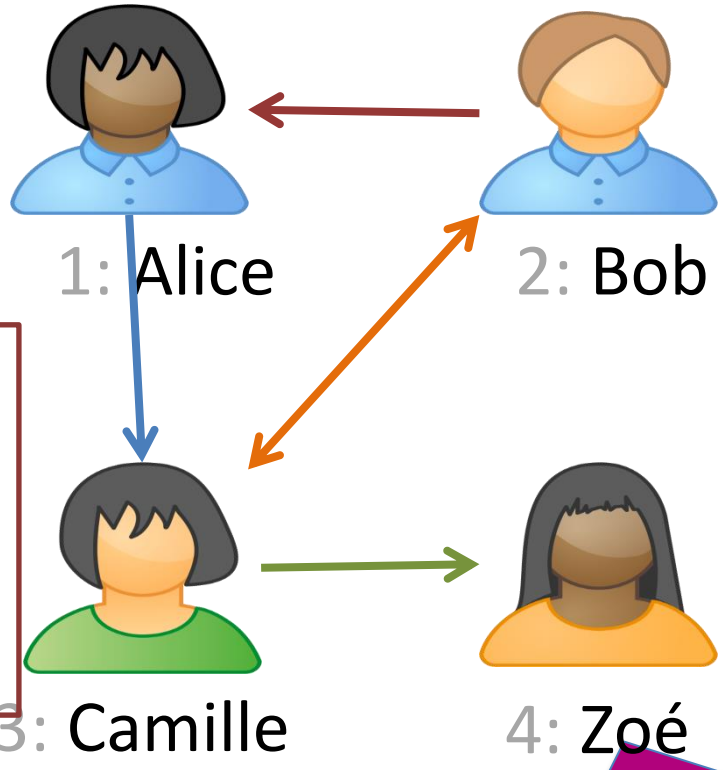

RDBMS et relations : limitations

Relations 1-n

Foreign key:

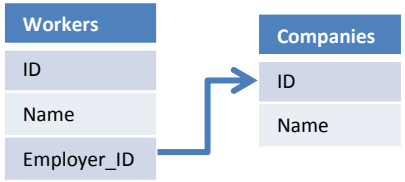

- Détourne le rôle d'un attribut
- Pas de type « Key »

Relations m-n

(ou 1-n avec attributs)

Join table:

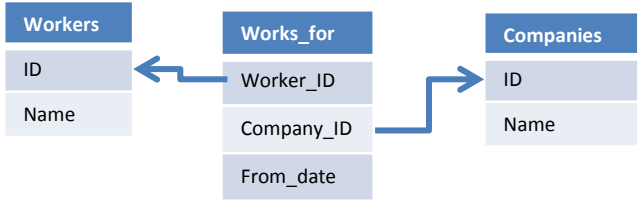

- Détourne le rôle d'une table
- Pas distinguable des autres

- Contrainte d'intégrité possible (externe à la table)
- Structure de la relation à préciser à chaque requête
- Join : Lourd en écriture et en exécution

Solutions NoSQL

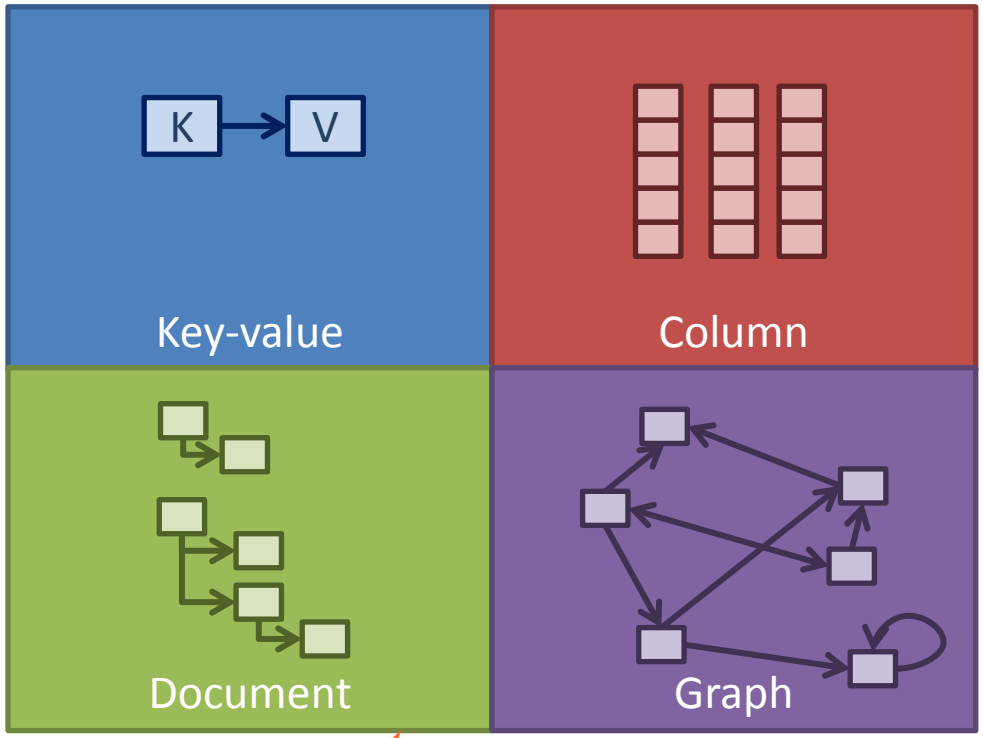

GraphDB : objectifs

Objectifs des *bases de données orientées graphes* :

Querying language qui sépare la définition **des relations** (à la création) et la recherche de « **matching** »

Moteur efficace pour le parcours des **relations**

```
SELECT p1.Name
FROM   People p1
JOIN   Likes l1
   ON  l1.Liked_ID = p1.ID
JOIN   Likes l2
   ON  l1.Liker_ID = l2.Liked_ID
JOIN   People p2
   ON  l2.Liker_ID = p2.ID
WHERE  p2.Name = "Bob"
```

Cypher (Neo4j)

```
MATCH
   (:People {Name:"Bob"})
   -[:Likes*2]->
   (p:People)
RETURN p.Name
```

GraphDB: moins de code

```
 (SELECT T.directReportees AS directReportees, sum(T.count) AS count
FROM (
SELECT manager.pid AS directReportees, 0 AS count
  FROM person_reportee manager
  WHERE manager.pid = (SELECT id FROM person WHERE name = "fName lName")
UNION
  SELECT manager.pid AS directReportees, count(manager.directly_manages) AS count
FROM person_reportee manager
WHERE manager.pid = (SELECT id FROM person WHERE name = "fName lName")
GROUP BY directReportees
UNION
SELECT manager.pid AS directReportees, count(reportee.directly_manages) AS count
FROM person_reportee manager
JOIN person_reportee reportee
ON manager.directly_manages = reportee.pid
WHERE manager.pid = (SELECT id FROM person WHERE name = "fName lName")
GROUP BY directReportees
UNION
SELECT manager.pid AS directReportees, count(L2Reportees.directly_manages) AS count
FROM person_reportee manager
JOIN person_reportee L1Reportees
ON manager.directly_manages = L1Reportees.pid
JOIN person_reportee L2Reportees
ON L1Reportees.directly_manages = L2Reportees.pid
WHERE manager.pid = (SELECT id FROM person WHERE name = "fName lName")
GROUP BY directReportees
) AS T
GROUP BY directReportees)
UNION
(SELECT T.directReportees AS directReportees, sum(T.count) AS count
FROM (
SELECT manager.directly_manages AS directReportees, 0 AS count
FROM person_reportee manager
WHERE manager.pid = (SELECT id FROM person WHERE name = "fName lName")
UNION
SELECT reportee.pid AS directReportees, count(reportee.directly_manages) AS count
FROM person_reportee manager
JOIN person_reportee reportee
ON manager.directly_manages = reportee.pid
WHERE manager.pid = (SELECT id FROM person WHERE name = "fName lName")
GROUP BY directReportees
UNION
```

```
SELECT depth1Reportees.pid AS directReportees,
count(depth2Reportees.directly_manages) AS count
FROM person_reportee manager
JOIN person_reportee L1Reportees
ON manager.directly_manages = L1Reportees.pid
JOIN person_reportee L2Reportees
ON L1Reportees.directly_manages = L2Reportees.pid
WHERE manager.pid = (SELECT id FROM person WHERE name = "fName lName")
GROUP BY directReportees
) AS T
GROUP BY directReportees)
UNION
(SELECT T.directReportees AS directReportees, sum(T.count) AS count
  FROM(
  SELECT reportee.directly_manages AS directReportees, 0 AS count
FROM person_reportee manager
JOIN person_reportee reportee
ON manager.directly_manages = reportee.pid
WHERE manager.pid = (SELECT id FROM person WHERE name = "fName lName")
GROUP BY directReportees
UNION
SELECT L2Reportees.pid AS directReportees, count(L2Reportees.directly_manages)
AS count
FROM person_reportee manager
JOIN person_reportee L1Reportees
```

```
MATCH
   (boss)-[:MANAGES*0..3]->(sub),
   (sub)-[:MANAGES*1..3]->(report)
WHERE boss.name = "John Doe"
RETURN sub.name AS Subordinate,
       count(report) AS Total
```

GraphDB : moins de code

"We found Neo4j to be literally thousands of times faster than our prior MySQL solution, with queries that require 10-100 times less code. Today, Neo4j provides eBay with functionality that was previously impossible."

https://neo4j.com/news/graph-databases-provide-crystal-ball-online-recommendations-wal-mart-ebay/

Interroger un réseau

NEO4J

Requête Neo4j

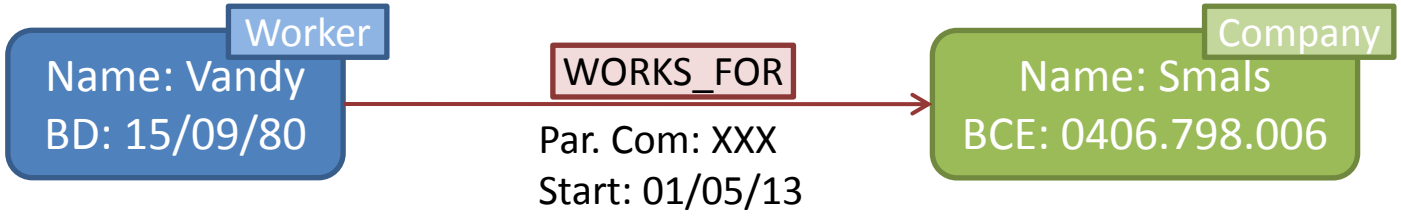

Nœud de type « Worker »

Relation de type « WORKS_FOR »

Nœud de type « Company »

```
MATCH   (w:Worker)  -[r:WORKS_FOR]->  (c:Company)
WHERE   c.Name = "Smals"
RETURN  w.Name, w.BD, r.Start
```

Variante :

```
MATCH
  (w:Worker)
  -[r:WORKS_FOR]->
  (c:Company {Name:"Smals"})
RETURN …
```

Liste des employés de Smals

Requête Neo4j

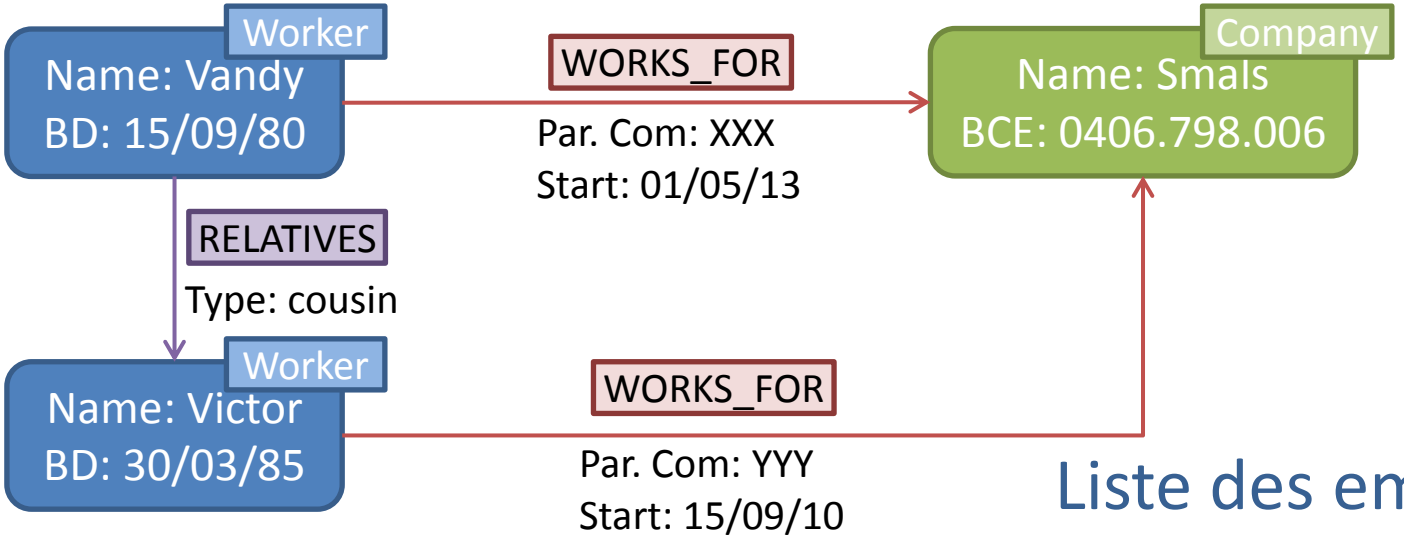

Liste des employés de Smals apparentés

```
MATCH
    (w1:Worker)-[:WORKS_FOR]->(c:Company {Name:"Smals"}),
    (w2:Worker)-[:WORKS_FOR]->(c),
    (w1)-[:RELATIVES]->(w2)
RETURN w1.Name, w2.Name
```

Requête Neo4j

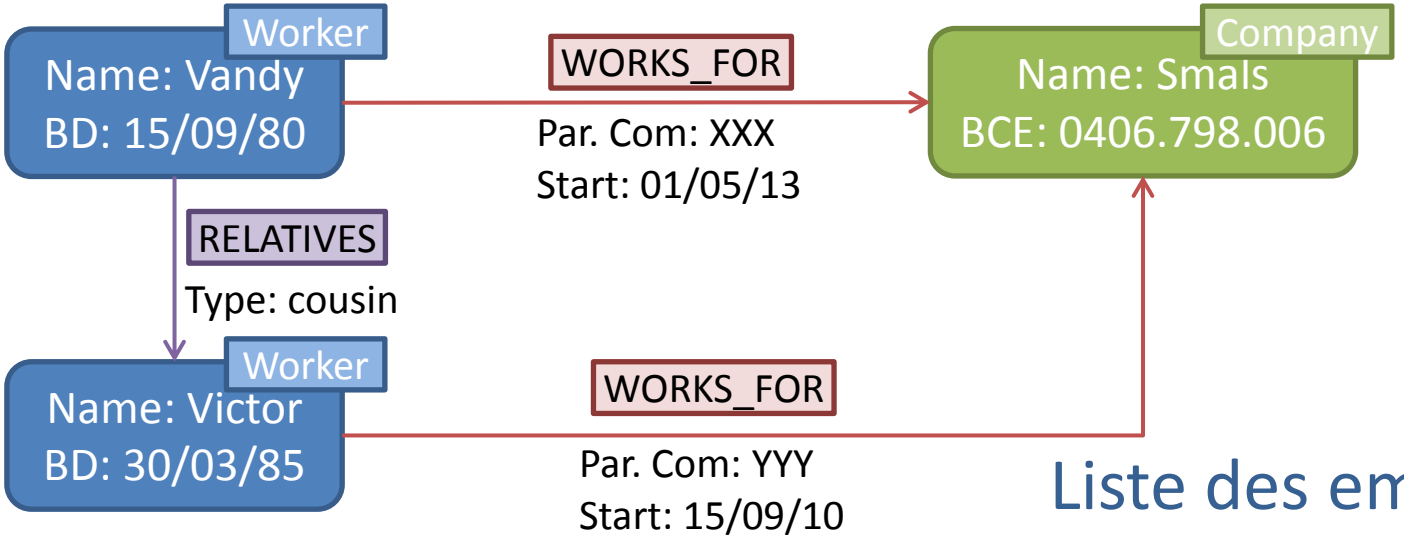

Liste des employés de Smals apparentés

```
MATCH
    (w1:Worker)-[:WORKS_FOR]->(c:Company {Name:"Smals"})
     <-[:WORKS_FOR]-(w2:Worker)-[:RELATIVES]->(w1)
RETURN w1.Name, w2.Name
```

Fonctionnement

	RDBMS	Graph DB
schema	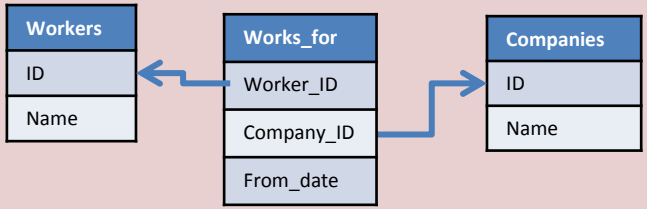	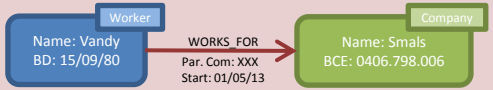
WHERE …	Search in Companies (with index): O(log([Table size])	Search in nodes (with index) : O(log([DB size])
Relation	JOIN : - Search in Works_for : O(log([Table size])) - Search in Workers : O(log([Table size]) x [nb res])	Follow pointers in node : O([nb of employees])

Performance

- Réseau social de 10^6 de nœuds
- ~50 voisins par nœuds
- Recherche des « amis d'amis »

Scénario très favorable aux graph DB !

Depth	MySQL	Neo4j	# results
2	0,02	0,01	2 500
3	30,27	0,17	110 000
4	1543,51	1,36	600 000
5	Unfinished	2,13	800 000

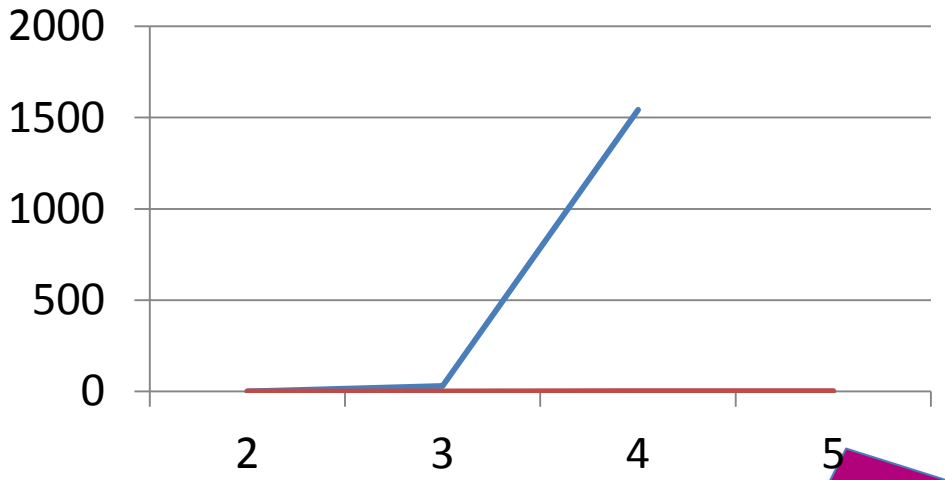

Graph Databases, I. Robinson et al.

Neo4j : Création des données

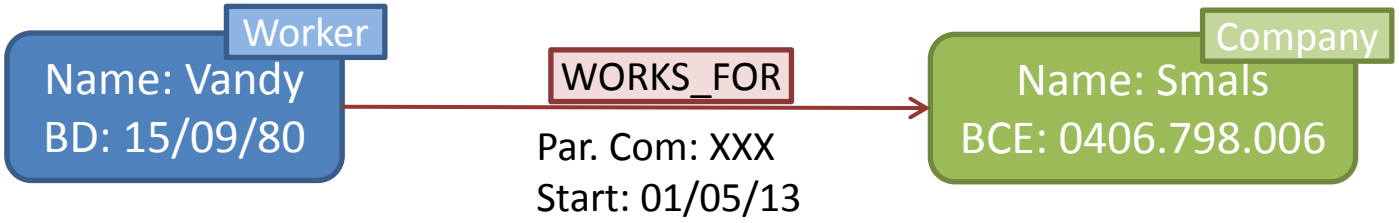


```
CREATE  (:Person   {Name:"Vandy", BD:"15/09/80"})
CREATE  (:Company  {Name:"Smals", BCE:"0406…"})

MATCH   (p:Person  {Name: "Vandy"}),
        (c:Company {Name: "Smals"})
CREATE  (p)-[:WORKS_FOR {Start:…}]->(c)
```

OU:

```
CREATE  (:Person  {Name:"Vandy", BD:"15/09/80"})
  -[:WORKS_FOR {Start:…}]->(:Company {Name:"…", …})
```

Neo4j : importation de données

- Dans la pratique : importation de fichiers CSV (à préparer !!)
- Via une commande *Cypher* (**`LOAD CSV FROM`**…)
  - Facile pour des petits fichiers
  - Lent à l'exécution
- En *command line*
  - Beaucoup plus rapide
  - Mal documenté

Interroger un réseau

GRAPHDB : LA SOLUTION ?

RDBMS et GraphDB ?

1

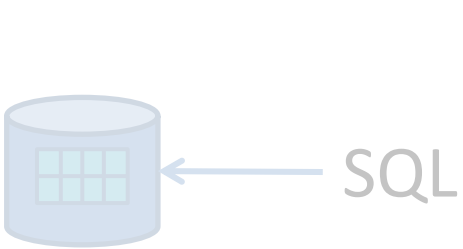

2

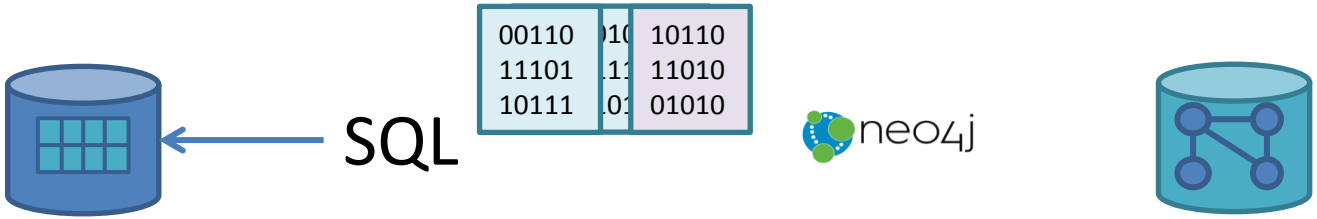

3

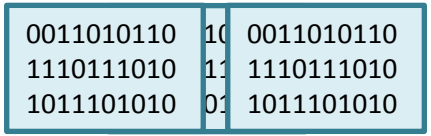

GraphDB : Avantages

- Langage plus proche du modèle
- Pas de clés à gérer, ni de contrainte d'intégrité
- Pas de structures de relations à chaque requête
- Très efficace pour le parcours de relations
- Beaucoup de champs d'application : recommandation, fraude, infra, MDM, KM…
- Neo4J: ACID, schema-less

GraphDB : limitations

- Pas la maturité des RDBMS (robustesse, haute dispo., communauté…)
- Pas de standard
- Survie à l'effet de mode ? (cf OO DB)
- Pas optimal pour des recherches, agrégation, batch process, transactionnel
- Pas une alternative, plutôt un complément (ne résout pas les mêmes problèmes)

Interroger un réseau

USE CASE : SUPERBONUS

Superbonus : contexte

- Avec le TaxShift (2016), des avantages sont donnés aux nouveaux employeurs
- Beaucoup d'employeurs existants se recréent pour profiter de ces avantages
- Le « Network Analytics » permet d'identifier beaucoup de ces cas

Data collection

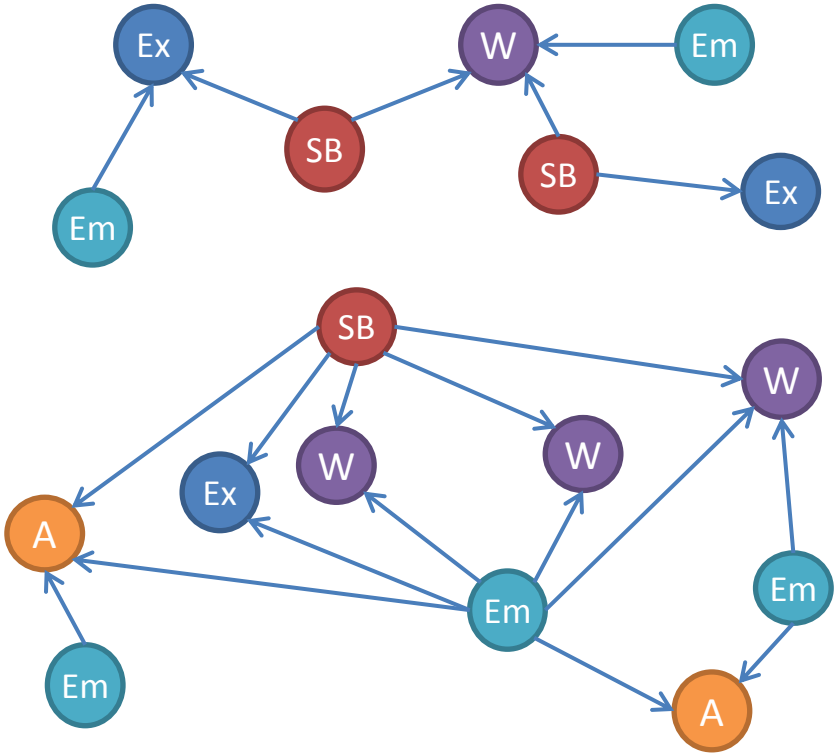

DmfA: **S**uper**B**onus requestors

11078 employers

Dimona: **W**orker in Periods 2015-2016

27056 workers

Dimona: **Em**ployers in Periods 2015

15416 employers

BCE: **Ex**ecutors + other companies

BCE: **A**ddresses (3296 addr.) + cotenant

Full transfert

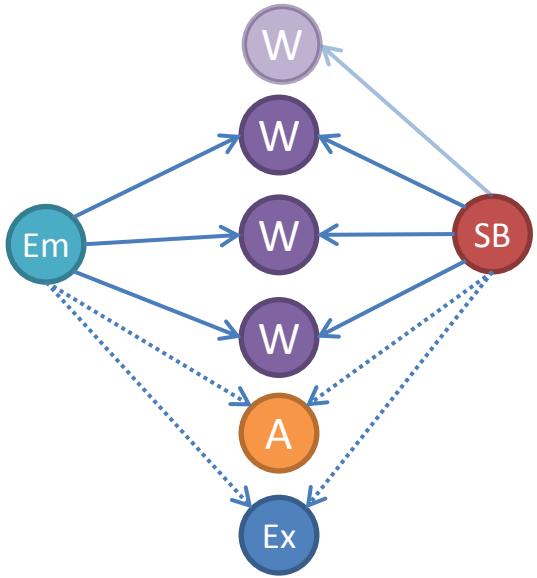

COUNT(W) > Em.Worker_Cnt_2015 * 80%
COUNT(W) > SB.Worker_Cnt_2016 * 80%

```
MATCH   (c_sb:SB)--(w:Worker)--(c_old:Company)
WHERE   c_sb <> c_old
OPTIONAL MATCH (c_sb)--(e:Executor)--(c_old)
OPTIONAL MATCH (c_sb)--(a:Address)--(c_old)
WITH    c_sb, c_old,
        COUNT(DISTINCT w) AS w_count
WHERE
   w_count > c_sb.WORKER_CNT_16 * 0.8 AND
   w_count > c_old.WORKER_CNT_15 * 0.8
RETURN c_sb, c_old, w_cnt
```

W Worker Em Employer without SB SB Employer with SB A Address Ex Executor

Shared admin and (worker or address)

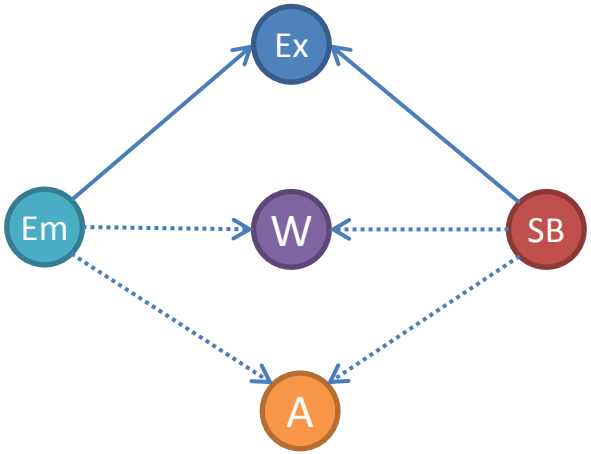

COUNT(W) > 0 **OR** COUNT(A) > 0

```
MATCH   (sb:SB)--(e:Executor)--(comp:Company)
WHERE   sb <> comp
OPTIONAL MATCH (sb)--(w:Worker)--(comp)
OPTIONAL MATCH (sb)--(a:Address)--(comp)
WITH sb, comp,
     COUNT(DISTINCT w) AS Workers_count,
     COUNT(DISTINCT a) AS Addresses_count
WHERE (Workers_count>0 OR Addresses_count>0)
RETURN sb, comp, …
```

W Worker Em Employer without SB SB Employer with SB A Address Ex Executor

Conclusions

En résumé

Caractériser (théorie) : tout un réseau, un nœud (centralité), deux nœuds (distance), un groupe de nœuds (clustering)

Visualiser : Desktop, Javascript, Cloud

Manipuler (coding) : Envir. classiques ou Big Data

Interroger (graph DB) : focus sur les relations

Application : fraude, gestion des infras/logicielle, recommandation, intelligence, KM…

Conclusions

- De la place pour les graph analytics/graph DB dans nos institutions
- Pas uniquement pour la fraude !
- Pour les data-scientists/BI :
  - nouvelle façon de réfléchir, centré sur les relations
- Pour les DBA/développeurs :
  - nouvelle famille de DB, complémentaires
- Pour les analystes/business :
  - inspiration pour de nouveaux use cases

Conclusions : expérience personnelle

- Préparation des données :
  - R/Python + igraph/graphx
- Première analyse :
  - Gephi/TouchGraph
- Production :
  - GraphDB (Neo4j…)
- Pour le client :
  - Interactif (futur) : libraire JS / outils « à la » Linkurio.us
  - Statique : Gephi/TouchGraph, igraph → Excel, PDF…

Références : www.smalsresearch.be

- Blogs :
  - https://www.smalsresearch.be/un-fraudeur-ne-fraude-jamais-seul/
  - https://www.smalsresearch.be/un-fraudeur-ne-fraude-jamais-seul-partie-2/
  - https://www.smalsresearch.be/bases-de-donnees-relationnelles-adequates-pour-des-relations/
  - https://www.smalsresearch.be/graph-db-vs-rdbms/
- Autres :
  - NoSQL - Hype ou Innovation, Grégory Ogonowski, https://www.smalsresearch.be/publications/document/?docid=59

Références

- **Graph Databases**, *Robinson & all*, O'Reilly 2015
- **Fraud Detection: Discovering Connections with Graph Databases**, *Neo4j*, Sodawksi & Rathle
- **Fraud Analytics Using Descriptive, Predictive, and Social Network Techniques: A Guide to Data Science for Fraud Detection**, *Bart Baesens, Veronique Van Vlasselaer, Wouter Verbeke*, Willey, 2015

Vandy Berten
02/787.57.32
vandy.berten@smals.be

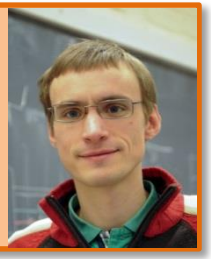

More on Smals Research :
Website : www.smalsresearch.be
Blog : www.smalsresearch.be/blog
Twitter : @SmalsResearch