




www.cnrs.fr

Neo4J

Une introduction





Sommaire



1. **Historique**
2. **Quelques rappels**
3. **Généralités sur Neo4J**
4. **Installation et première mise en œuvre**
5. **La sécurité**


Historique



Historique

🕒 Histoire des bases



○ Modèle Codasyl



Historique

🕒 Histoire des bases

○ Cobol



Historique

- ◎ **Neo4j développé par la société Neo technology depuis 2000**
 - Société suédoise basée aux US
 - Version 1.0 en 2010
- ◎ **SGBD NoSQL open source (licence GPL V3.0)**
 - Ecrit en Java
- ◎ **Utilisé par des grands comptes comme Cisco, HP, Adidas, SFR, SNCF, Accenture, LinkedIn, Meetic (;-)), etc.**
- ◎ **Dernière version stable : 3.0 en avril 2016**
- ◎ **Multi-plateformes**
- ◎ **Beaucoup d'interfaces avec les langages de programmation**
 - Java évidemment ... et Python !

Ecosystème des bases graphes

⦿ Il existe plusieurs solutions de bases graphe

- Titan : <http://thinkaurelius.github.io/titan/>
- FlockDB : <https://github.com/twitter/flockdb>
- GraphBase (commercial) : <http://graphbase.net/>
- InfiniteGraph (commercial) : <http://www.objectivity.com/>

⦿ Beaucoup de ces solutions n'ont pas eu de suite

- Segmentation des solutions sur un créneau restreint

⦿ Neo4J reste actuellement une des bases graphe parmi les plus connues

Ecosystème des bases graphes

🕒 Une base connue en effet ...



Ecosystème des bases graphes

🎯 Deux éditions de Neo4j sont disponibles :


- Une édition communautaire (Community Edition). Pas de services professionnels ni assistance. Licence gratuite GPLv3
- Une édition entreprise (Enterprise Edition). Prise en charge de la haute disponibilité, de la gestion, de l'évolutivité et de la production. Licence commerciale par abonnement, assistance incluse. **Licence gratuite sous l'AGPLv3 pour les projets open source.**

🎯 Pas de prix publics visible en décembre 2015

Ecosystème des bases graphes

Positionnement de Neo4J (<http://db-engines.com/en/ranking>)

DB-Engines Ranking of Graph DBMS




Ecosystème des bases graphes

🕒 Dernières annonces du Graph Connect 2015 sur Neo4J

- Disponibilité d'un driver officiel pour tous les langages
 - Vision du codage homogène
- Procédures stockées
- OpenCypher
 - Supports
 - DataBricks (soutien de Spark)
 - Oracle (Oracle Spatial et Oracle Graph)
 - Tableau : référence dans l'exploitation des données et le Machine Learning
 - Pourquoi OpenCypher ?
 - Le modèle relationnel a su s'imposer historiquement par rapport aux bases réseaux car il existait un langage commun de requêtage
 - Neo4J essaie de ne pas répéter la même erreur et s'adjoint de grands éditeurs pour normaliser Cypher

Quelques rappels



Pourquoi une base graphe ?

⊙ Intérêt des données

- Connexion, interactions

⊙ Evolutions actuelles

- Volume : souvent cité
- Connectivité : sous entendu mais plus rarement mis en avant
- Les deux aspects ont tendance à subir un facteur multiplicatif

⊙ **Complexité = Volume * Connectivité**

Quelques rappels

⦿ Les graphes


- Graphe fini $G = (S, A)$
- Ensemble fini de sommets $S = \{s_1, s_2, \dots, s_n\}$
- Ensemble fini d'arêtes $A = \{a_1, a_2, \dots, a_m\}$ pour les graphes non orientés
- On parle d'arcs si le graphe est orienté
- Si l'arête 'a' relie les sommets 'a' et 'b', on dira que ces sommets sont adjacents
- On appelle **ordre d'un graphe** le nombre de sommets n de ce graphe
- G , non orienté est **connexe** si, à partir de tout sommet S , il existe une suite d'arêtes permettant de rejoindre tous les autres sommets
- Un graphe est **complet** si tous les sommets sont adjacents
- Il existe plein d'algorithmes de parcours des graphes : en largeur, en profondeur ...

⦿ Pourquoi faire déjà ?

- Modéliser des problématiques spécifiques avec forte connectivité
- Recherche de liens optimaux

Quelques rappels

Exemples de graphes




Graphe non orienté



Graphe orienté

Quelques rappels

🕒 Exemples de graphes



▲ László Babai, lauréat
du prix Gödel 1993
et du prix Knuth 2015.



Généralités sur Neo4J




Les cas d'usage

◎ A chaque fois qu'il y a des relations 'many-to-many'

- Master Data Management (gestion des données de référence)
- Infrastructures réseaux
- Suggestions en temps réel (sites web, achats en ligne, ...)
- Détection de fraude
- Réseaux sociaux
- IAM (Identity and Access Management)


Positionnement CAP



Les cas d'usage

Un exemple concret en MySQL

- Matérialiser un réseau d'amis



<u>USER</u>		<u>USER_FRIENDS</u>		
<u>id</u>	<u>Nom</u>	<u>id</u>	<u>user 1</u>	<u>user 2</u>
1	Dupond	1	1	2
2	Durand	2	1	3
3	Richard	3	2	5
4	Roche	4	5	3
5	La joie	5	3	4

Les cas d'usage

🕒 Un exemple concret en MySQL

- Compter les amis
 - De premier niveau

```
SELECT u1.nom, count(*) FROM user u1 INNER JOIN user_friends uf1 WHERE u1.id = uf1.user1 GROUP BY nom
```

nom	count(*)
Dupont	2
Durant	1
Lajoie	1
Richard	1

- De deuxième niveau

```
select u1.nom, count(*) FROM user AS u1  
INNER JOIN user_friends AS uf1 on u1.id = uf1.user1  
INNER JOIN user_friends AS uf2 on uf1.user2=uf2.user1  
GROUP BY u1.nom
```

nom	count(*)
Dupont	2
Durant	1
Lajoie	1

Les cas d'usage

🕒 Un exemple concret en MySQL

○ Compter les amis

○ De troisième niveau

```
select u1.nom, count(*) FROM user AS u1
  INNER JOIN user_friends AS uf1 on u1.id = uf1.user1
  INNER JOIN user_friends AS uf2 on uf1.user2=uf2.user1
  INNER JOIN user_friends AS uf3 on uf2.user2=uf3.user1
GROUP BY u1.nom
```

nom	count(*)
Dupont	1
Durant	1

○ De quatrième niveau

```
select u1.nom, count(*) FROM user AS u1
  INNER JOIN user_friends AS uf1 on u1.id = uf1.user1
  INNER JOIN user_friends AS uf2 on uf1.user2=uf2.user1
  INNER JOIN user_friends AS uf3 on uf2.user2=uf3.user1
  INNER JOIN user_friends AS uf4 on uf3.user2=uf4.user1
GROUP BY u1.nom
```

nom	count(*)
Dupont	1

Les cas d'usage

🕒 Un exemple concret en MySQL

- Compter les amis
 - De cinquième niveau

```
select u1.nom, count(*) FROM user AS u1
  INNER JOIN user_friends AS uf1 on u1.id = uf1.user1
  INNER JOIN user_friends AS uf2 on uf1.user2=uf2.user1
  INNER JOIN user_friends AS uf3 on uf2.user2=uf3.user1
  INNER JOIN user_friends AS uf4 on uf3.user2=uf4.user1
  INNER JOIN user_friends AS uf5 on uf4.user2=uf5.user1
GROUP BY u1.nom
```

- Le résultat est alors vide


🕒 Au total :

- De multiples jointures sont à réaliser, en fonction du niveau de « profondeur voulu »
- Coûteux en temps et en mémoire : produit cartésien puis sélection
- Si le nombre de relations augmente, les jointures deviennent impossibles à exécuter
 - Dans Neo4J in Action ¹, avec un Intel I7 et 8 Go de RAM, il faut 92613 s pour 1000 users pour une profondeur de 5
 - Pour 1 million de users, le calcul ne finit jamais ...

¹Neo4J in Action, Aleksa Vukotic and Nicki Watt, Manning, 2015

Les cas d'usage

- La vision « graphe » du même problème est toute différente



Les cas d'usage


⦿ Dans ce cas :

- Inutile de travailler sur l'ensemble des données comme dans le modèle relationnel
- Un nœud est choisi et le parcours du graphe se fait à partir de là
- C'est le principe du « **graph traversal** » de Neo4J
- Le « **graph traversal** » devient performant lorsque le volume de données est important, volume qui rend les jointures coûteuses voire impossibles
- L'image qui peut être utilisée est celle du « stade de foot »¹:
 - Compter le nombre de personnes dans un périmètre de 15 mètres autour de vous dans un stade de 1000 personnes ou 50000 personnes coûte le même temps avec un graphe

¹ Neo4J in Action, Aleksa Vukotic and Nicki Watt, Manning, 2015

Relationnel vs Neo4J

🎯 Bases de données relationnelles et bases graphes



En plus, Neo4j est ACID et transactionnel


⦿ Propriétés ACID

- **Atomicité** : opérations atomiques au niveau des sommets et des liens (arcs)
- **Cohérence** : Neo4J étant transactionnelle, la cohérence est garantie
- **Isolation** : garanti par le transactionnel
- **Durabilité**: données écrites sur disque suite à une transaction

⦿ Propriété « transactionnel »

- Neo4J respecte toutes les caractéristiques d'une base de données transactionnelle

Capacités de Neo4J



Installation et première mise en œuvre



Installation

🕒 Ajout du dépôt officiel pour Ubuntu

- `wget -O - https://debian.neo4j.org/neotechnology.gpg.key | sudo apt-key add -`
- `echo 'deb http://debian.neo4j.org/repo stable/' | sudo tee /etc/apt/sources.list.d/neo4j.list`
- `sudo apt-get update`

🕒 Installation depuis le dépôt

- `sudo apt-get install neo4j -y`

🕒 Lancement

- `sudo service neo4j start`

🕒 Connection

- `neo4j-shell`
- `http://localhost:7474/browser/` ou `http://192.168.56.4:7474/browser/`

Administration et développements

🕒 Vérifications et tests de quelques commandes

- Sur le système : `'ps auxw | grep -i neo4j'`
- En shell :
 - `'neo4j-shell'`
 - `'schema'`
 - CTRL+D pour quitter

🕒 Installations pour Python


- `pip install py2neo`
- `pip install ipython-cypher`
- `pip install python-igraph`
- `pip install plotly`

🕒 A ce stade, Neo4J est opérationnel ainsi que son environnement de développement


🕒 2 possibilités de mise en œuvre : `'embedded'` ou `'server'`

Administration et développements

- 2 possibilités de mise en œuvre : 'embedded' ou 'server'



Architecture classique



BD et traitements dans la même JVM

Administration et développements

② 2 possibilités de mise en œuvre : 'embedded' ou 'server'

- Les extensions permettent d'exécuter du code sur le serveur (~procédures stockées)
- Ces extensions sont soumises à fortes évolutions et investir de manière pérenne peut poser problème
- L'idéal reste de séparer les concepts et d'utiliser les API REST avec les drivers par langage

Syntaxe Neo4J

```

4780 GOTO 5000
4790 :
4800 REM -----
4801 REM --- DARSTELLUNG ---
4802 REM --- DES MANUALS ---
4803 REM -----
4810 :
4820 PRINT " ";
4825 W=V+1; IF W<0 THEN W=W+14;
4830 FOR X=1 TO 2:PRINT " ";
4835 FOR I=0 TO 23;
4840 PRINT MD$(I+W);
4850 NEXT I:PRINT:PRINT:
4860 PRINT " ";
4870 FOR I=0 TO 23;
4880 IF MD$(I+W)=CHR$(32) THEN PRINT MB$(I+1);:GOTO 4900;
4890 PRINT MD$(I+W);
4900 NEXT I;
4910 PRINT:PRINT " ";
4920 FOR I=2 TO 24 STEP 2;
4925 PRINT "I";
4930 IF MD$(I+W-1)=" " THEN PRINT " ";
4935 PRINT " ";
4940 NEXT I:PRINT " ";
4950 PRINT " ";
4960 FOR I=2 TO 24 STEP 2;
4965 PRINT "I";
4970 IF MD$(I+W-1)=" " THEN PRINT " ";
4975 PRINT MB$(I);
4980 NEXT I:PRINT " "

```




Syntaxe

- ◎ Le langage privilégié pour Neo4J est Cypher
- ◎ Neo4J a lancé il y a peu une initiative, OpenCypher, visant à définir un langage commun de requête pour les graphes (<http://www.opencypher.org/>)
- ◎ Cypher utilise de « l'ASCII art » et se veut un langage facilement appréhendable
- ◎ Cypher est un langage très riche et qui permet toutes les opérations sur les structures de graphes
- ◎ La « reference card » de Cypher témoigne de la richesse du langage : <http://neo4j.com/docs/stable/cypher-refcard/>
- ◎ Dans la suite, quelques exemples vont illustrer son utilisation
- ◎ Des alternatives existent
 - Gremlin (langage impératif en librairie OpenSource) : plus trop actif
 - <https://github.com/tinkerpop/gremlin>

Syntaxe

Des principes simples



Syntaxe

⊙ Un nœud

- Label
- Des propriétés


⊙ Relation

- Nœuds de départ et d'arrivée
- Label
- Des propriétés

⊙ Les propriétés utilisent des types Java : int, String, boolean, etc.

Avant de continuer : les outils

- 🕒 Il est toujours possible de travailler en mode Shell
 - Mais cela devient vite fastidieux lorsque le problème devient complexe
- 🕒 Heureusement, il existe une interface, livrée et installée avec Neo4J
 - L'accès, dans notre cas, se fait via l'URL : <http://192.168.56.4:7474/browser/>
- 🕒 Elle permet déjà de connaître quelques informations sur l'instance Neo4J



Avant de continuer : les outils

🕒 Elle permet aussi

- De saisir du code (prompt en haut à droite)
- D'utiliser des didacticiels
- De suivre l'activité du système

The screenshot displays the Neo4j Desktop application interface. On the left is a dark sidebar with icons for database information, node labels, relationship types, property keys, and database status. The main area is light gray and contains a code prompt at the top right with a '\$' symbol and navigation icons. Below the prompt, the interface is divided into three columns. The first column shows the 'neo4j COMMUNITY EDITION 3.0.0' logo. The second column, 'Learn about Neo4j', includes a graph icon and links to 'What is a graph database?', 'How can I query a graph?', and 'What do people do', with a 'Start Learning' button. The third column, 'Jump into code', features a code icon and links to 'Code walk-throughs', 'RDBMS to Graph', and 'Query templates', with a 'Write Code' button. A fourth column, 'Monitor the system', shows a heart icon and links to 'Disk utilization', 'Cache activity', and 'Cluster health and status', with a 'Monitor' button. At the bottom, a gray bar contains the text 'Got data? Learn how to import it into Neo4j.' and the footer 'Copyright © Neo Technology 2002–2016'.

Database Information

Node labels

- * **Personne**

Relationship types

- * **Est_Ami** **Est_ami**

Property keys

- age cpu duree modele name
- nom RAM type vendeur

Database

Version: 3.0.0
Name: graph.db
Size: 165.71 KiB
Information ⓘ sysinfo

\$

:play start

neo4j
COMMUNITY
EDITION
3.0.0

Learn about Neo4j
A graph epiphany awaits you.

- What is a graph database?
- How can I query a graph?
- What do people do

Start Learning

Jump into code
Use Cypher, the graph query language.

- Code walk-throughs
- RDBMS to Graph
- Query templates

Write Code

Monitor the system
Key system health and status metrics.

- Disk utilization
- Cache activity
- Cluster health and status

Monitor

Got data? Learn how to import it into Neo4j.

Copyright © Neo Technology 2002–2016

Syntaxe

Commençons par créer un nœud simple :

You can play !!

```
$ create (p : Personne)
```

Rows	Added 1 label, created 1 node, statement executed in 105 ms.
Code	

create (p:Personne)

Créons un deuxième nœud :

```
$ create (pj : Projet)
```

Rows	Added 1 label, created 1 node, statement executed in 37 ms.
Code	

create (pj:Projet)

A ce stade, il existe 2 nœuds avec les labels Personne et Projet

Syntaxe

🕒 Voyons le résultat graphique :

```
$ MATCH (n) RETURN n LIMIT 25
```



match (n) return n limit 25

🕒 Comment retrouver le nœud relatif à la personne :

```
$ match (u:Personne) return u
```



match (u:Personne) return u

Syntaxe

🎯 Tout détruire (à utiliser maintenant ;-)) :

```
$ MATCH (n) OPTIONAL MATCH (n)-[r]-() DELETE n,r
```



Rows



Code

Deleted 2 nodes, statement executed in 77 ms.

```
match (n)optional match (n)-[r]-() delete n,r
```

Syntaxe

- 🎯 Créons les mêmes nœuds mais un peu plus complexes :

```
$ create (p:Personne {nom:'Dupond'}) return p
```

The screenshot displays the Neo4j Cypher query editor interface. The query entered is `$ create (p:Personne {nom:'Dupond'}) return p`. The interface shows three views: Graph, Rows, and Code. The Graph view displays a single node labeled 'Dupond'. The Rows view shows a table with one row: 'Personne(1)'. The Code view shows the query. The bottom toolbar includes a 'Personne' button, a 'Color' selector (with blue selected), a 'Size' selector, a 'Caption' field with '<id>', and a 'nom' field.

```
create (p: Personne{nom:"Dupond"}) return p
```

Libellé

Code couleur

Syntaxe

🎯 Même action pour le projet :

`$ MATCH (n) RETURN n LIMIT 25`

Match permet de faire un select


The screenshot shows the Neo4j Cypher query editor interface. At the top, the query `$ MATCH (n) RETURN n LIMIT 25` is entered. A blue arrow points from the text "Match permet de faire un select" to the `MATCH` keyword in the query. Below the query, the interface is divided into three main sections: a sidebar on the left with icons for 'Graph', 'Rows', and 'Code'; a top bar with filter buttons labeled `*(2)`, `Personne(1)`, and `Projet(1)`; and a central graph view. The graph view displays two nodes: a blue circle labeled 'Dupond' and a red circle labeled 'Neo4J'.

```
create (pj:Projet{nom:"neo4j"})
match (n) return n limit 25
```

Syntaxe

🕒 Créons maintenant une relation entre 'p' et 'pj' :

```
$ match (p:Personne {nom:'Dupond'}),(pj:Projet {nom:'Neo4J'}) create (p)-[relation:Participe]->(pj) return relation,p,pj
```



```
match (p:Personne{nom:'Dupond'}),(pj:Projet{nom:'neo4j'}) create (p)-[relation:Participe]->(pj)
return relation, p,pj
```

🕒 Détruisons cette relation entre 'p' et 'pj' :

```
$ match (p:Personne {nom:'Dupond'})-[r:Participe]->(pj:Projet {nom:'Neo4J'}) delete r
```



Rows




Code

Deleted 1 relationship, statement executed in 511 ms.

```
match (p:Personne{nom:'Dupond'})-[r:Participe]->(pj:Projet{nom:'neo4j'}) delete r
```

Syntaxe


- Créons maintenant le graphe qui a servi d'exemple SQL



Syntaxe

🕒 Cela donne :

```
$ MATCH (n:Personne) RETURN n LIMIT 25
```



Syntaxe

🕒 Qui est ami avec Dupond ?

```
$ match (p:Personne)-[:Est_Ami]->(amis) where p.nom='Dupond' return amis.nom
```



Rows

amis.nom

Richard



Code

Durant

```
match (p:Personne)-[:Est_ami]->(amis:Personne) where p.nom='Dupond' return amis.nom
```

🕒 Ce sont les amis de « premier niveau »

Syntaxe

🕒 Qui est ami avec Dupond ?

```
$ match (p:Personne)-[:Est_Ami*2]->(amis) where p.nom='Dupond' return amis.nom
```



Rows

amis.nom

Lajoie

Roche



Code

```
match (p:Personne)-[:Est_ami*2]->(amis:Personne) where p.nom='Dupond' return amis.nom
```

La subtilité est ici !

🕒 Ce sont les amis de « deuxième niveau »

Syntaxe

🕒 Quels sont tous les amis de Dupond (premier et deuxième niveau) ?

```
$ match (p:Personne)-[:Est_Ami*1..2]->(amis) where p.nom='Dupond' return amis.nom
```



Rows

amis.nom

Durant



Code

Lajoie

Richard

Roche

```
match (p:Personne)-[:Est_ami*1..2]->(amis:Personne) where p.nom='Dupond' return amis.nom
```

Syntaxe

🎯 Quels sont tous les amis de Dupond ?

```
$ match (p:Personne)-[:Est_Ami*]->(amis) where p.nom='Dupond' return amis.nom
```

	amis.nom
Rows	Durant
Code	Lajoie
	Richard
	Roche
	Richard
	Roche

```
match (p:Personne)-[:Est_ami*]->(amis:Personne) where p.nom='Dupond' return amis.nom
```

🎯 Il existe des doublons qui sont éliminés simplement :

```
$ match (p:Personne)-[:Est_Ami*]->(amis) where p.nom='Dupond' return distinct amis.nom
```

	amis.nom
Rows	Durant
Code	Lajoie
	Richard
	Roche

distinct

```
match (p:Personne)-[:Est_ami*]->(amis:Personne) where p.nom='Dupond' return distinct amis.nom
```

Syntaxe

🎯 Ajoutons quelques propriétés (nœuds) :

```
$ match (p:Personne) where p.nom='Dupond' set p.age=35 return p
```

The image shows the Cypher Studio interface. On the left is a sidebar with icons for Graph, Rows, and Code. The main area displays a graph with a single blue circular node labeled 'Dupond'. Above the graph, a tab shows '* (1)' and 'Personne(1)'. At the bottom, a details bar for the 'Personne' entity lists the properties: '<id>: 18', 'age: 35', and 'nom: Dupond'.

```
match (p:Personne)where p.nom='Dupond' set p.age=35 return p
```

Syntaxe


🎯 Ajoutons quelques propriétés (relations) :

```
$ match (p1:Personne)-[r:Est_Ami]->(p2:Personne) where p1.nom='Dupond' and p2.nom='Durant' set r.duree=30 return r
```

*(2) **Personne(2)**

```
match (p1:Personne)-[r:Est_ami]->(p2:Personne) where p1.nom='Dupond'  
and p2.nom='Durand' set r.duree=30 return r
```

*(1) **Est_Ami(1)**



Des amis de 30 ans




Est_Ami <id>: 6 **duree: 30**

Syntaxe

- Mettons à zéro cette propriété pour toutes les autres relations qui n'ont pas de valeurs:

```
$ match (p1:Personne)-[r:Est_Ami]->(p2:Personne) set r.duree=coalesce(r.duree,0) return r,p1,p2
```



```
match (p1:Personne)-[r:Est_ami]->(p2:Personne) where r.duree=coalesce(r.duree,0) return r,p1,p2
```

Syntaxe

🎯 Sélectionnons les amitiés de plus de 10 ans :

```
$ match (p1:Personne)-[r:Est_Ami]->(p2:Personne) return p1,p2,r
```



	p1	p2	r
Graph			
Rows	age 35 nom Dupond	nom Richard	duree 3
Code	age 35 nom Dupond	nom Durant	duree 30
	nom Durant	nom Lajoie	duree 24
	nom Richard	nom Roche	duree 6
	nom Lajoie	nom Richard	duree 28
Returned 5 rows in 438 ms.			

```
match (p1:Personne)-[r:Est_ami]->(p2:Personne) return r,p1,p2
```

Syntaxe

🎯 Sélectionnons les amitiés de plus de 10 ans :

```
$ match (p1:Personne)-[r:Est_Ami]->(p2:Personne) where r.duree >=10 return r,p1,p2
```



	r	p1	p2
Graph	duree 30	age 35 nom Dupond	nom Durant
Rows	duree 24	nom Durant	nom Lajoie
Code	duree 28	nom Lajoie	nom Richard
Returned 3 rows in 1515 ms.			

```
match (p1:Personne)-[r:Est_ami]->(p2:Personne) where r.duree >= 10 return r,p1,p2
```

Syntaxe

🎯 Comptons, par personne, le nombre d'amitiés :

```
$ match (p1:Personne)-[r:Est_Ami]->(Personne) with p1,count(r) as nombre order by nombre desc return p1,nombre
```

p1	nombre
age 35 nom Dupond	2
nom Lajoie	1
nom Durant	1
nom Richard	1

```
match (p1:Personne)-[r:Est_ami]->(Personne) with p1, count(r) as nombre  
order by nombre desc return p1,nombre
```

Syntaxe

🎯 Classement par la moyenne des durées d'amitiés :

```
$ match (p1:Personne)-[r:Est_Ami]->(:Personne) with p1, avg(r.duree) as moy_duree order by moy_duree desc return p1, moy_duree
```

p1	moy_duree
nom Lajoie	28
nom Durant	24
age 35 nom Dupond	16.5
nom Richard	6

```
match (p1:Personne)-[r:Est_ami]->(:Personne) with p1, avg(r.duree) as moy_duree  
order by moy_duree desc return p1, moy_duree
```

Syntaxe : récapitulatif

⊙ Les bases

- Les nœuds sont représentés par : ()
 - Il est aussi possible de spécifier : (monNoeud:monLabel)
- Les relations entre nœuds sont représentées par : --[]->
 - Il est aussi possible de spécifier : -[maRelation:mon_Type]->

Syntaxe : récapitulatif


◉ Quelques exemples de graphes simples

Simple




$(a) - [:\text{lien}] \rightarrow (b)$

Double



$(a) - [:\text{lien1}] \rightarrow (b), (a) - [:\text{lien2}] \rightarrow (c)$

Cycle



$(a) - [:\text{lien1}] \rightarrow (b) - [:\text{lien2}] \rightarrow (c) - [:\text{lien3}] \rightarrow (a)$

Note: la relation est dans les 2 sens

$() - [:\text{lien}] \rightarrow ()$ ou $() \leftarrow [:\text{lien}] - ()$

Syntaxe : récapitulatif

🕒 Il y a ensuite des opérations de base

- Match/where :
 - MATCH (n)-->(m) WHERE NOT (m)-->()
- Return : identique au 'select' en SQL
 - RETURN personne.nom as userName ORDER BY userName LIMIT 3
- With : identique à Return mais avec la capacité de poursuivre le traitement
 - MATCH (n:Personne)-[:Ami]-(a) WITH count(a) as s, n MATCH (n)-[:Ami]-(f)-[:Ami]-(fof) RETURN n, s, fof
- Create
 - CREATE (n1)-[:Lien]->(n2)
- Agrégation : count, sum, avg, ...
 - MATCH (n1)-->(n2) RETURN n, count(1)
- Etc.


🕒 Le langage subit quand même de fortes évolutions

- Il existe même la possibilité la version de Cypher qui doit être utilisée
- CYPHER 1.8 MATCH (p)-[r]->()

Mode de parcours du graphe

- ⦿ **Dans les graphes, il existe 2 modes de parcours**
 - En profondeur d'abord
 - En largeur d'abord
- ⦿ **Avec Cypher, le mode du langage étant déclaratif, le mode de parcours est totalement délégué**
 - Il n'y a pas à s'en préoccuper
- ⦿ **Dans un langage impératif, il y a possibilité de spécifier le mode de parcours du graphe**
 - Trouvé en Java
 - `TraversalDescription traversalDescription = graphDb.traversalDescription().depthFirst()`
 - Pas en Python ...
 - Il faudra compter sur l'harmonisation des API

Manips en cours ...




Objectifs et outils

🎯 Poursuite de l'exemple

- Les amis font connaissance ;-)
- Utilisation de Cypher (interface Neo4J ou Jupyter)
- Programmation en Python via Jupyter

La sécurité



La sécurité

- ⦿ La sécurité est assez peu intégrée dans Neo4J (comme dans MongoDB)
- ⦿ Neo4J est basé sur des API REST et tout le problème consiste donc à sécuriser ces API (accès HTTP)
 - Py2neo permet est basé sur les API REST et en cache la complexité au développeur
- ⦿ Il est possible de définir nativement des comptes et des mots de passe mais des accès restent basiques (granularité des accès)
- ⦿ Cette option peut paraître « osée » dans le contexte sécurité actuel
 - Mais performances et sécurité font rarement bon ménage ...
- ⦿ Il faut donc sécuriser les accès via des moyens externes à Neo4J

Première étape : les sauvegardes

🕒 Méthode 1: copie des fichiers de la base

- `cp -R data/graph.db data/backup`

🕒 Méthode 2: utiliser la commande de sauvegarde

- <http://neo4j.com/docs/stable/backup-embedded-and-server.html>
- `mkdir /.../backup/neo4j-backup`
- `neo4j-backup -host 192.168.56.1 -to /.../backup/neo4j-backup`

🕒 Méthode 3: utiliser la commande Cypher Dump

- `neo4j-shell -c 'dump MATCH (n) OPTIONAL MATCH (n)-[r]-() RETURN r,n' > export.cql`
- Pour réimporter le graphe (après avoir détruit ce qui existait auparavant): `neo4j-shell -file export.cql`

🕒 Peu de méthodes natives éprouvées ...

La sécurité : les accès


🕒 Les moyens de sécurisation de base

- Sécuriser l'accès à Neo4J revient à sécuriser des API REST
- Utilisation de proxy (HA-Proxy par exemple) : <http://www.haproxy.org/>
- Utilisation de SSL/TLS
- Restreindre si possible l'accès à un domaine voire à un sous ensemble défini d'applications clientes
- Positionner Neo4J dans un réseau dédié
- Tracer, logger, consigner, filtrer, exploiter,


Architecture



Rappel : Embedded vs Server




Architecture classique



BD et traitements dans la même JVM


Mise en œuvre haute-disponibilité




Mise en œuvre haute-disponibilité

- ⦿ Cette configuration nécessite la version Enterprise
- ⦿ La mise en œuvre n'est pas très complexe mais nécessite de la ressource
 - Intel Core I7 recommandé
 - Filesystem Ext4
 - 8 à 12 Go de RAM minimum (par nœud)
 - OpenJDK 8 recommandé
- ⦿ Voici l'URL de référence : <http://neo4j.com/blog/graphs-to-production-at-scale/>
 - Contient même la configuration de Ha-Proxy


La haute-disponibilité et la lecture/écriture




La haute-disponibilité et la lecture/écriture



La haute-disponibilité : répartition d'un graphe



Exemple de mise en œuvre complète



Des questions ?



Résumé des concepts

