MAC439 Laboratório de Bancos de Dados

Introdução a Bancos de Dados de Grafos Usando o Neo4J

20 de abril de 2018

Profa. Kelly Rosa Braghetto

Banco de Dados de Grafo

- **Grafo**: coleção de nós e arestas que os conectam
- Em um BD de grafo, os nós representam entidades de um domínio e as arestas representam os relacionamentos que existem entre as entidades
- Uma das formas mais populares de modelos de grafos é o chamado de **grafo de propriedades rotulado**
  - Simples e fácil de ser entendido
  - Pode ser usado na maioria dos domínios para os quais grafos são uma boa representação para os dados

Grafo de Propriedades Rotulado

- Características:
  - Contém nós e relacionamentos (arestas)
  - Nós contêm propriedades (pares do tipo chave-valor)
  - Nós podem ser rotulados com um ou mais rótulos
  - Relacionamentos têm nome e são direcionados; sempre possuem um nó de origem e um nó de destino
  - Relacionamentos também podem conter propriedades

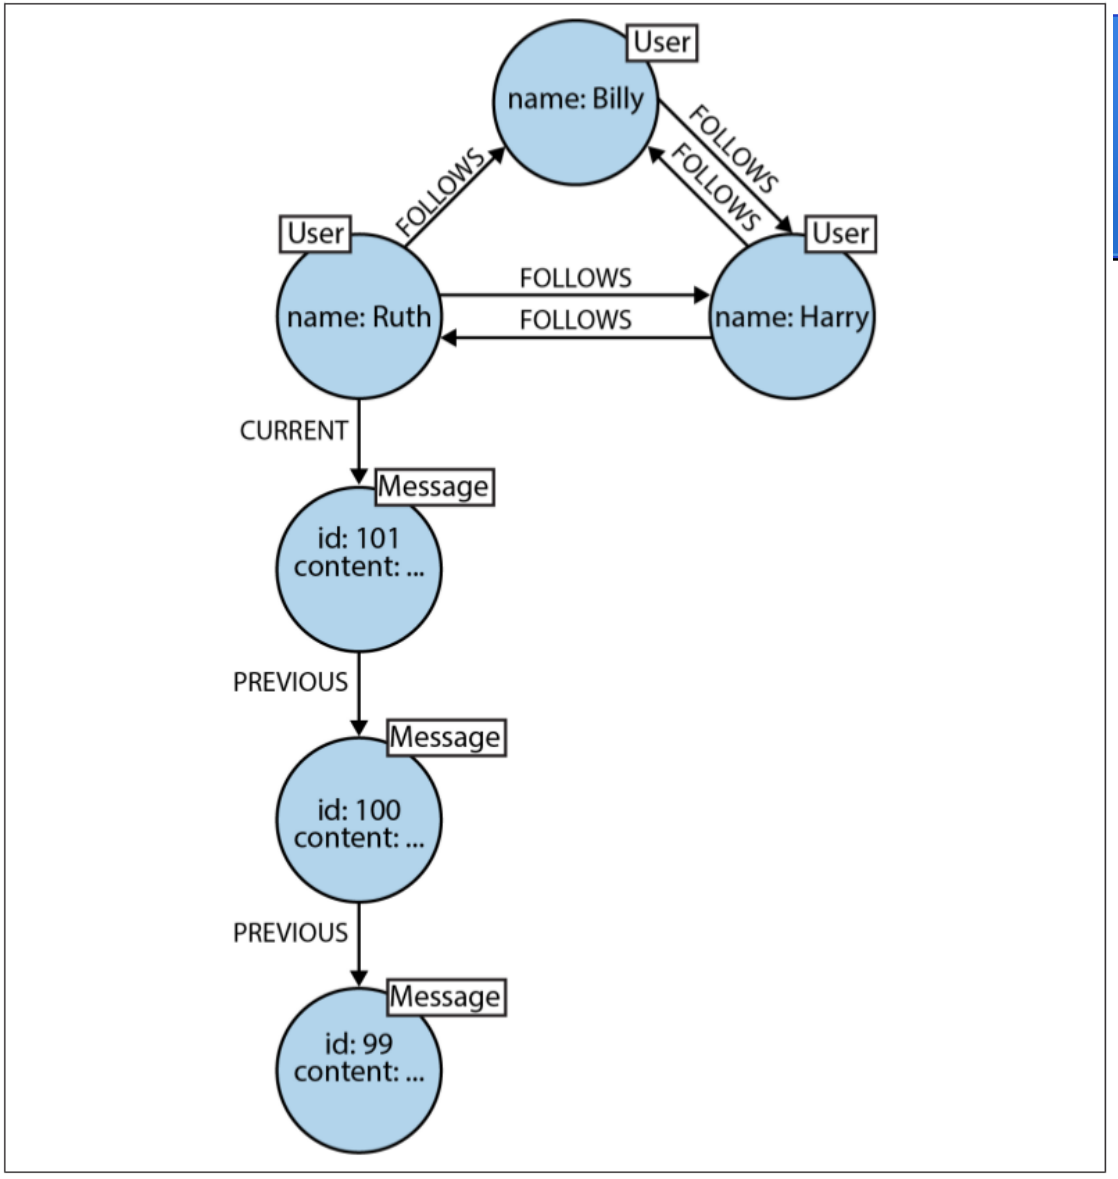

- Exemplo de grafo de propriedade rotulado de uma rede social

Sistema Gerenciador de Bancos de Dados de Grafos

- É um sistema de gerenciamento com suporte a operações de criação, leitura, alteração e remoção de dados, aplicadas a dados armazenados num modelo de grafo
- Esse tipo de sistema é geralmente desenvolvido para ser usado com sistemas transacionais (OLTP – online transaction processing)
  - Oferecem garantias transacionais (seguem o modelo ACID), mantendo consistência “forte“ dos dados
  - São otimizados para processar grandes volumes de transações tradicionais
- Aspectos importantes desse tipo de sistema
  - Modelo de armazenamento subjacente
  - Modelo de processamento de consultas

SGBD de Grafos – Modelo de de Armazenamento

- Alguns SGBDs de grafos têm **armazenamento nativo para grafos**, ou seja, um tipo de armazenamento que é projetado e otimizado para armazenar e gerenciar grafos
  - Benefícios: bom desempenho e escalabilidade
- Mas existem sistemas gerenciadores que seriam (= transformam) os grafos em outros formatos de dados, para que possam ser mantidos em outros sistemas, como em SGBDs relacionais, SGBDs orientados a objetos ou em outras sistemas de armazenamento de dados de propósito geral
  - Benefícios: usam *backends* maduros, cujas características em produção já são bastante conhecidas pelos desenvolvedores de software

SGBD de Grafos – Modelo de Processamento

- Diz-se que um SGBD faz **processamento de grafos nativo** se nele os nós conectados do grafo fisicamente apontam uns para outros no banco de dados, ou seja, as adjacências dos nós não são representadas por meio de chaves estrangeiras e índices (o que é conhecido como *index-free-adjacency*).
- Mas qualquer banco de dados que, sob a perspectiva de um usário, se comporta como um grafo (com operarações de inserção, remoção, consulta, etc.) geralmente é considerado um BD de grafo
- SGBDs com **processamento de grafos nativo** têm como benefício um bom desempenho em travessias (consultas que percorrem os nós por meio de seus relacionamentos)
  - Entretanto, a execução de consultas que não envolvem travessias fica mais difícil ou mais custosa em termos de consumo de memória

Caracterização de Alguns SGBDs de Grafos

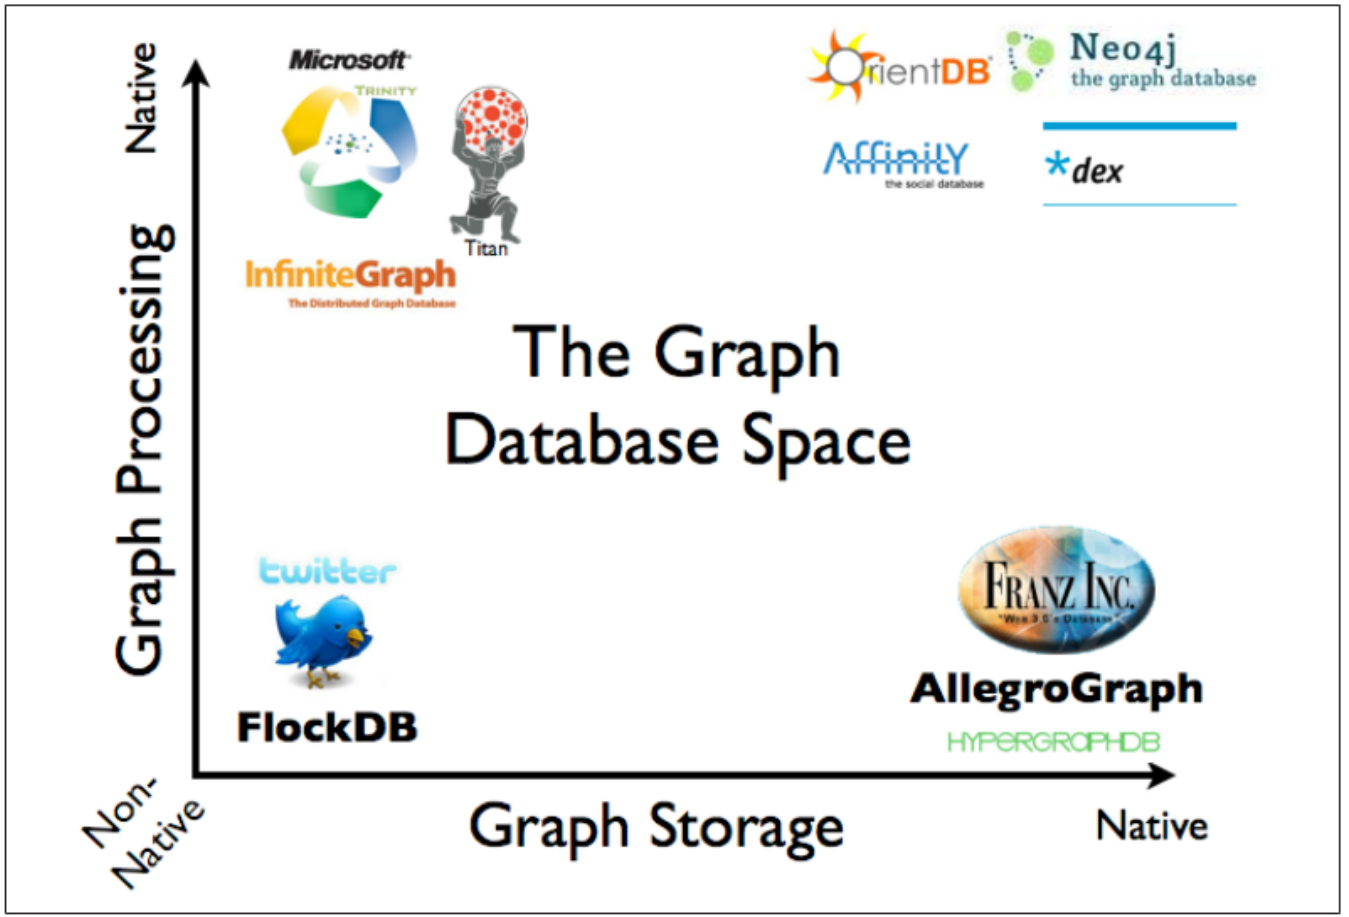

Ferramentas para Processamento de Grafos

- São ferramentas que possibilitam a execução de algoritmos sobre grafos de grande escala
- Esse tipo de software é projetado para realizar operações tais como:
  - Identificar padrões nos dados (agrupar)
  - Reponder questões do tipo: “Quantos relacionamentos em média um pessoa tem em uma rede social?“
- Diferentemente dos SGBDs de Grafos, essas ferramentas são otimizadas para varrer e processar grandes quantidades de dados em *batch* (como ocorre em ferramentas OLAP e de mineração de dados)
- A maioria dessas ferramentas não possui uma camada de armazenamento de dados, apenas processam dados que recebem de alguma fonte externa e devolvem os resultados para serem armazenados em algum outro lugar
- Exemplos:
  - Apache Giraph: http://giraph.apache.org/
  - Apache Spark GraphX: http://spark.apache.org/graphx/

Ranking de Popularidade de Sistemas Gerenciadores de BDs de Grafos

Multi-model = Key-Value, Document Store, Graph DBMS

29 systems in ranking, March 2018

Rank Mar 2018	Rank Feb 2018	Rank Mar 2017	DBMS	Database Model	Score Mar 2018	Score Feb 2018	Score Mar 2017
1.	1.	1.	Neo4j	Graph DBMS	40.90	+1.08	+6.58
2.	2.	↑ 4.	Microsoft Azure Cosmos DB	Multi-model	16.76	+0.57	+12.81
3.	3.		Datastax Enterprise	Multi-model	8.00	+2.04	
4.	4.	↓ 2.	OrientDB	Multi-model	6.46	+0.52	+1.12
5.	5.	5.	ArangoDB	Multi-model	4.12	+0.65	+1.74
6.	6.	6.	Virtuoso	Multi-model	1.82	-0.01	-0.15
7.	7.	7.	Giraph	Graph DBMS	1.08	+0.06	+0.02
8.	8.		Amazon Neptune	Multi-model	0.70	-0.05	
9.	9.	↓ 8.	AllegroGraph	Multi-model	0.64	+0.00	+0.16
10.	10.	10.	Stardog	Multi-model	0.53	+0.01	+0.16
11.	↑ 13.	11.	Sqrrl	Multi-model	0.47	+0.05	+0.14
12.	12.	↓ 9.	GraphDB	Multi-model	0.45	+0.03	+0.05
13.	↓ 11.	↑ 17.	Graph Engine	Multi-model	0.43	-0.01	+0.33
14.	↑ 15.		JanusGraph	Graph DBMS	0.30	+0.09	
15.	↓ 14.	↑ 21.	Sparksee	Graph DBMS	0.23	-0.01	+0.17

http://db-engines.com/en/ranking/graph+dbms

Sobre o Neo4J

- SGBD para grafos criado em 2007, mantido pela Neo Technologies
- Software livre
- Usa como modelo grafos de propriedades rotulados
- Tem modelo de armazenamento e processamento nativos para grafos
- Usa uma linguagem de consulta chamada Cypher

A Linguagem Cypher

- Linguagem declarativa, como a SQL
  - Comandos definem o que deve ser recuperado, não como
- Muito legível e expressiva
- É usada para encontrar padrões nos relacionamentos de um grafo
- Tem comandos inspirados em outras linguagens de consulta conhecidas, como a SQL e a SPARQL
- Sua especificação é aberta
  - Foi desenvolvida como uma proposta de linguagem de consulta padrão para BDs de grafos

Instruções de Acesso ao Neo4J

- Para usar o servidor Neo4J instalado localmente nas máquinas do CEC, acesse:

  https://localhost:7474

- No prompt carregado, execute o seguinte comando para conexão:

  ```
  :server connect
  ```

- Para a primeira conexão, use como nome de usuário e senha o valor **neo4j**.

- No seu primeiro acesso, será solicitado que você cadastre uma nova senha para o usuário **neo4j**. Use como nova senha **mac439**.

  (isso é importante porque, caso mudem de computador nas próximas aulas, saberão a senha de acesso ao neo4j da nova máquina)

BD de Exemplo para a aula

- Para criar o banco de dados que será usado nos exemplos desta aula
  - Abra o arquivo “criacao_bd_filmes.txt“ (disponível no Paca)
  - Copie o conteúdo
  - Cole no prompt do cliente web de conexão com o Neo4J
  - Aberte o botão para executar os comandos colados

BD de Exemplo para a aula

- A imagem mostra parte do BD criado
- O BD contém dados sobre filmes, atores e diretores
- Na interface web, é possível interagir com os nós, consultar suas propriedades, etc.

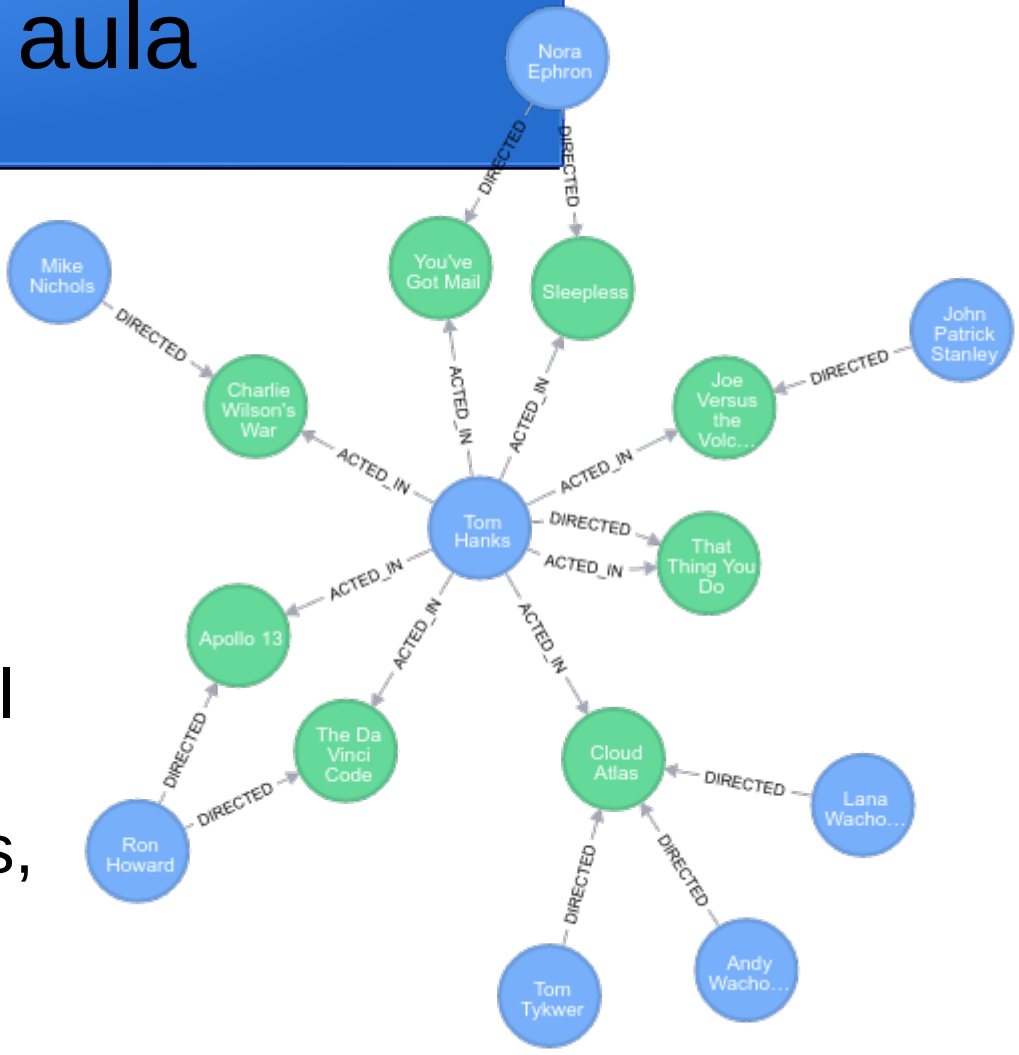

Cypher – Nós

- **São denotados por um par de parênteses**
- Exemplo: um nó com nome de variável `matrix`, rótulo `Movie` e duas propriedades (`title` e `released`)

```
(matrix:Movie {title: "The Matrix",  released: 1999})
```

- A variável de nó pode ser usada em outros lugares dentro do mesmo comando em que foi definida
- O rótulo funciona como a definição de um tipo ou papel para o nó
  - Possibilita agrupar os nós
  - Bastante usado como filtro nas consultas
- Um nó pode ter mais de um rótulo
- Com exceção dos parênteses, todos os demais elementos de definição de nó mostrados acima são opcionais

Cypher – Outros Exemplos de Nós

```
()
(matrix)
(:Movie)
(matrix:Movie)
(matrix:Movie {title: "The Matrix"})
(matrix:Movie {title: "The Matrix", released: 1999})
(matrix:Movie:Promoted)
```

Cypher – Busca por Nós

- Consultas/buscas são realizadas por meio da função MATCH
- A consulta a seguir devolve todos os nós de filme (ou seja, os nós que têm `Movie` como rótulo)

```
MATCH (movie:Movie)
RETURN movie
```

Cypher – Busca por Nós

- A consulta a seguir devolve todos os nós de filme que têm a propriedade title = "The Matrix"

```
MATCH (filme:Movie {title:"The Matrix"})
RETURN filme
```

- Embora o uso deles na especificação de uma consulta não seja obrigatório, o Cypher usa os rótulos na otimização das consultas, portanto o uso deles é fundamental para garantir um bom desempenho nas operações sobre o grafo

Cypher – Busca por Relacionamentos

- Formato geral:

```
MATCH (node1:Label1)-[rel:REL_TYPE]->(node2:Label2)
RETURN node1, node2
```

- Exemplo: Devolva todos os atores do filme *The Matrix*

```
MATCH (matrix:Movie {title:"The Matrix"}) <-[:ACTED_IN]-
(actor:Person)
RETURN matrix, actor
```

Cypher – Busca por Relacionamentos

- Outro exemplo: Devolva todos os personagens dos filmes no BD

```
MATCH (actor:Person)-[rel:ACTED_IN]->(movie:Movie)
RETURN rel.roles
```

Obs.: os personagens aparecem na propriedade `roles` dos relacionamentos com rótulo `ACTED_IN`.

Cypher – Busca por Padrões

- Combinando buscas por nós com buscas por relacionamentos, é possível especificar buscas por padrões
- Exemplo de padrão simples: verifique se o `Keanu Reeves` fez o personagem `Neo` no filme `The Matrix`

```
MATCH (matrix:Movie {title:"The Matrix"} )
       <-[role:ACTED_IN {roles:["Neo"]}]-
      (keanu:Person {name:"Keanu Reeves"})
RETURN matrix, role, keanu
```

Cypher – Busca por padrões

- Busca os filmes nos quais o `Keanu Reeves` atuou fazendo um personagem chamado `Neo`:

```
MATCH (keanu:Person)-[r:ACTED_IN]->(movie)
WHERE keanu.name="Keanu Reeves"
AND "Neo" IN r.roles
RETURN movie.title
```

Cypher – Buscas

- Para devolver todos os nós que possuem relacionamentos com outros nós:

```
MATCH (n)-->(m)
RETURN n, m;
```

- O resultado de uma busca pode ser armazenado em uma variável:

```
MATCH cast = (:Person)-[:ACTED_IN]->(:Movie)
RETURN cast
```

Cypher – Criação de Nós

- Exemplo: criação de um novo nó de pessoa

```
CREATE (me:Person {name: "Kelly R B"})
RETURN me
```

- Consulta para verificar se o nó criado está no grafo

```
MATCH (me:Person {name:"Kelly R B"})
RETURN me.name
```

ou

```
MATCH (me:Person)
WHERE me.name="Kelly R B"
RETURN me.name
```

Cypher – Criação de Relacionamentos

- Primeiro, vamos criar um novo filme:

```
CREATE (movie:Movie {title: "Mystic River",
released:1993})
```

- Agora, vamos incluir no BD o fato do `Kevin Bacon` ter atuado como `Sean` em `Mystic River`:

```
MATCH (kevin:Person) WHERE kevin.name = "Kevin Bacon"
MATCH (mystic:Movie) WHERE mystic.title = "Mystic River"
CREATE (kevin)-[r:ACTED_IN {roles:["Sean"]}]->(mystic)
RETURN mystic, r, kevin
```

Cypher – Criação de Relacionamentos

- Vamos incluir mais um novo relacionamento: uma avaliação para o filme `Mystic River`

```
MATCH (me:Person), (movie:Movie)
WHERE me.name="Kelly R B"
      AND movie.title="Mystic River"
CREATE (me)-[r:REVIEWED{rating:80,
        summary:"tragic character movie"}]->(movie)
RETURN me, r, movie
```

Cypher – Criação de Relacionamentos

- O comando abaixo tem resultado igual ao do slide anterior:

```
MATCH (me:Person {name:"Kelly R B"}),
      (movie:Movie {title:"Mystic River"})
CREATE (me)-[r:REVIEWED {rating:80,
   summary:"tragic character movie"}]->(movie)
RETURN me, r, movie
```

Cypher – Merge de Relacionamentos

- Se executamos um comando de criação de relacionamentos mais de uma vez, mais de uma aresta é criada entre o mesmo par de nós
- Para evitar esse problema, podemos usar o comando MERGE no lugar do CREATE. O MERGE tem semântica *get-or-create*, ou seja, primeiro ele busca pela aresta. Se a encontrar no grafo, devolve-a como resposta. Senão, ele cria a aresta.
- Exemplo:

```
MATCH (me:Person {name:"Kelly R B"}),
      (movie:Movie {title:"Mystic River"})
MERGE (me)-[r:REVIEWED {rating:80,
   summary:"tragic character movie"}]->(movie)
RETURN me, r, movie
```

Cypher – Adição de novas propriedades

- O operador **set** pode ser usado para incluir propriedades
- Exemplo: adiciona uma *tagline* ao filme `Mystic River`

```
MATCH (movie:Movie)
WHERE movie.title = "Mystic River"
SET movie.tagline = "We bury our sins here, Dave. We wash them clean."
RETURN movie.title AS title,
       movie.tagline AS tagline
```

Cypher – Modificação de propriedades

- O operador **set** também pode ser usado para mudar o valor de propriedades que já existem
- Exemplo: muda o nome do papel do `Kevin Bacon` em `Mystic River` para `Sean Devine`:

```
MATCH (kevin)-[r:ACTED_IN]->(mystic)
WHERE kevin.name = "Kevin Bacon"
      AND mystic.title = "Mystic River"
SET r.roles = ["Sean Devine"]
RETURN mystic, r, kevin
```

Cypher – Remoção de Nós

- O comando a seguir remove o nó da `Kelly R B` e todos os seus relacionamentos (caso ele tenha algum)

```
MATCH (me:Person {name:"Kelly R B"})
OPTIONAL MATCH (me)-[r]-()
DELETE me,r
```

Cypher – Remoção de Nós

- Como a operação de remover um nó juntamente com seus relacionamentos é bastante comum, foi incluída no Cypher uma variação do `DELETE`, o `DETACH DELETE`, que faz a remoção completa:

```
MATCH (me:Person {name:"Kelly R B"})
DETACH DELETE me
```

Cypher – Ordenação dos resultados

- Mostra os anos de nascimento de todas as pessoas em ordem decrescente

```
MATCH (person:Person)
RETURN person.name, person.born
ORDER BY person.born DESC
```

Cypher – Limit e Skip

- A consulta abaixo devolve a “segunda página“ (cada página com 10 atores) dos dados de atores:

```
MATCH (actor:Person)-[:ACTED_IN]->(movie:Movie)
RETURN actor.name AS Actor,
       movie.title AS Movie
SKIP 10 LIMIT 10;
```

Cypher – Eliminando repetições

- Usa-se o operador DISTINCT para eleminar repetições na resposta de uma consulta.
- Exemplo: Mostra os 5 atores mais velhos.

```
MATCH (actor:Person)-[:ACTED_IN]->()
RETURN DISTINCT actor
ORDER BY actor.born
LIMIT 5
```

Cypher – Buscas mais avançadas

- Encontra os nomes dos atores que atuaram em filmes em que o `Tom Hanks` atuou e que são mais velhos que o `Tom Hanks`:

```
MATCH (tom:Person)
            -[:ACTED_IN]->()<-[:ACTED_IN]-
      (actor:Person)
WHERE tom.name="Tom Hanks"
AND actor.born < tom.born
RETURN distinct actor.name AS Name
```

Cypher – Buscas mais avançadas

- Encontra os nomes e a diferença de idade dos atores que atuaram em filmes em que o `Tom Hanks` atuou e que são mais velhos que o `Tom Hanks`:

```
MATCH (tom:Person {name:"Tom Hanks"})
      -[:ACTED_IN]->(movie:Movie),
      (movie)<-[:ACTED_IN]-(actor:Person)
WHERE actor.born < tom.born
RETURN DISTINCT actor.name AS Name,
      (tom.born - actor.born) AS diff
```

Cypher – Buscas mais avançadas

- Encontra os nomes dos atores que são também diretores e que atuaram em filmes em que o `Gene Hackman` atuou:

```
MATCH (gene:Person)
        -[:ACTED_IN]->()<-[:ACTED_IN]-
      (other:Person)
WHERE gene.name="Gene Hackman"
AND exists( (other)-[:DIRECTED]->() )
RETURN DISTINCT other
```

Cypher – Buscas mais avançadas

- Encontra os nomes dos atores que atuaram em filmes em que o `Gene Hackman` atuou, mas não quando o `Robin Williams` estava no filme:

```
MATCH (gene:Person {name:"Gene Hackman"})
            -[:ACTED_IN]->(movie:Movie),
      (other:Person)
            -[:ACTED_IN]->(movie),
      (robin:Person {name:"Robin Williams"})
WHERE NOT exists( (robin)-[:ACTED_IN]->(movie) )
RETURN DISTINCT other
```

Cypher – Busca por Padrões com caminhos de tamanho variável

- Devolve todos os pares de nós que estão conectados, mesmo que seja por meio de relacionamentos indiretos de qualquer distância:

```
MATCH (node1)-[*]-(node2)
RETURN node1, node2
```

Cypher – Busca por Padrões com caminhos de tamanho variável

Variações

- Encontra pares de nós que estão relacionados por meio de um caminho de tamanho **`4`**:

```
MATCH (a)-[*4]->(b)
```

- Encontra pares de nós que estão relacionados por meio de um caminho de tamanho **`entre 1 e 4`**:

```
MATCH (a)-[*1..4]->(b)
```

- Encontra pares de nós que estão relacionados (mesmo que indiretamente) por meio de relacionamentos do tipo `LIKE`

```
MATCH (a)-[:LIKE *]->(b)
```

- Encontra pares de nós que estão relacionados por meio de relacionamentos do tipo `LIKE` em segundo grau **ou** relacionamentos diretos do tipo `KNOWS` em primeiro grau

```
MATCH (a)-[:LIKE *2 |:KNOWS]->(b)
```

Cypher – Extraindo dados de caminhos

- Exibe somente os nós dos caminhos (subgrafos) devolvidos na consulta (MATCH):

```
MATCH p =(actor:Person)
          -[:ACTED_IN]→(movie:Movie)<-[:DIRECTED]-
         (director:Person)
RETURN nodes(p);
```

- Além da função nodes(p), temos também:
  - `length(p)` – devolve o tamanho do caminho
  - `rels(p)` – devolve apenas os relacionamentos

Cypher – Agrupamento/Agregação

- Funções de agregação:
  - **count(x)**: conta o número de ocorrências
  - **min(x):** obtém o menor valor
  - **max(x):** obtém o maior valor
  - **avg(x):** obtém a média de valores numéricos
  - **sum(x):** soma valores
  - **collect(x):** coloca todos os valores em uma collection

Cypher – Agrupamento/Agregação

- Mostra todos os títulos dos filmes dos quais um ator participou

```
MATCH (person:Person)
      -[:ACTED_IN]->(movie:Movie)
RETURN person.name, collect(movie.title);
```

- Mostra o nome de todos os diretores com os quais um ator trabalhou

```
MATCH (person:Person)-[:ACTED_IN]->
      (movie:Movie)<-[:DIRECTED]-
      (director:Person)
RETURN person.name,
       collect(DISTINCT director.name) as directors;
```

Cypher – Agrupamento/Agregação

- Devolve o número de filmes em que um ator trabalhou junto com um mesmo diretor:

```
MATCH (actor:Person)
      -[:ACTED_IN]->(movie:Movie)<-[:DIRECTED]-
      (director:Person)
RETURN actor.name, director.name, count(movie);
```

- Devolve os 10 atores que mais atuaram em filmes

```
MATCH (person:Person)-[:ACTED_IN]->(movie:Movie)
RETURN person.name, count(movie)
ORDER BY count(movie) DESC
LIMIT 10;
```

Referências Sobre o Neo4J

- Documentação do Neo4J
  - https://neo4j.com/developer/
- “Treinamentos“ oficiais:
  - https://neo4j.com/graphacademy/
  - Material da aula veio do tutorial a seguir:
    https://neo4j.com/graphacademy/online-training/introduction-graph-databases/
- Livros (disponíveis para download gratuito!) :
  - **“Graph Databases - The Definitive Book on Graph Databases“**
    http://graphdatabases.com/
  - **“The Definitive Guide to Graph Databases – for the RDBMS developers“**
    https://neo4j.com/resources/rdbms-developer-graph-white-paper/
    Obs.: compara BDs de grafos com BDs relacionais

Referências sobre a Cypher

- Documentação
  - https://neo4j.com/developer/cypher/
- Manual
  - https://neo4j.com/docs/developer-manual/current/cypher/
- Cartão de referência
  - http://neo4j.com/docs/cypher-refcard/current/