MongoDB

- ドキュメント指向NoSQLデータベースの一つ
- Mongoという名前は、英語で「**ばかでかい**」を意味する "humongous" に由来する
- JSONを拡張したBSONの形式でデータを格納する
- データの構造をあらかじめ定義しておく必要がない（**スキーマレス**）
- 任意の比較演算子での**結合問合せ**はない（$lookupを使った等号での結合のみ）

リレーショナルデータベースとの対応

リレーショナルデータベース	MongoDB
データベース	データベース
表	コレクション
行	ドキュメント
列	フィールド
タップル	オブジェクト
主キー	_id フィールド

JSONフォーマット

- **JavaScript Object Notationの略**
- **オブジェクト**（フィールド名と値のペアの集まり）でデータを表現する

（例）{empno: "E01", ename: "Smith"}

{フィールド名1: 値1, フィールド名2: 値2, …, フィールド名n: 値n}

- **オブジェクトの入れ子構造**（オブジェクトの値のところに新たなオブジェクトを書いたもの）を扱える
- オブジェクトの値として**配列（データの系列）**を扱うことができる

（例）{ goods: ["milk", "bread", "butter"] }

データの登録

db.コレクション名.insertOne(ドキュメント)

・1つのドキュメントをコレクションに登録する

・SQLの insert into 表 values タップル　に相当

（注意）SQLと違って**スキーマの定義が必要ない**（コレクションや中身のドキュメントは自動的に生成される）

db.コレクション名.insertMany(**[** ドキュメント1, ドキュメント2, …, ドキュメントn **]**)

・複数のドキュメントをコレクションに登録する（ドキュメントの系列を**配列**で表現）

データの登録例(1)

db.emp.insertOne({empno: "E01",

ename: "Smith", deptno: "D01", salary: 100})

（参考）SQLの insert into emp values ('E01', 'Smith', 'D01', 100) に相当

内部での表現（ _idは自動的に作成されるフィールド（RDBMSの主キーに対応））

{ "_id" : ObjectId("587ceffb3ae75d7ed54218de"), "empno" : "E01", "ename" : "Smith", "deptno" : "D01", "salary" : 100 }

実習で使うデータベース（一部）

```
db.emp.insertMany( [
 { empno: "E01", ename: "Smith", deptno: "D01",
salary: 100 },
 { empno: "E02", ename: "Morgan", deptno: "D01",
salary: 70 },
 { empno: "E03", ename: "Robert", deptno: "D01",
salary: 80 },
 { empno: "E04", ename: "Washington", deptno: "D02",
salary: 120 },
.....
] )
```

実習で使うデータベース(つづき)

```
db.dept.insertMany( [
 { deptno: "D01", dname: "Account", manager: "E01" },
 { deptno: "D02", dname: "Personnel", manager: "E04" },
 { deptno: "D03", dname: "Education", manager: "E07" },
 { deptno: "D91", dname: "Database", manager: "E91" }
] )
```

データベースの問合せ

db.コレクション名.find(検索条件, 出力フィールド指定)

- 検索条件と出力フィールド指定はオブジェクトの形式で表現する(どちらも省略可能で省略すると条件なしとなる)
- 検索条件の表現

{ フィールド名 : 値 } ← 値をそのまま書くと等号を指定したことになる(フィールド名 = 値)

{ フィールド名: {比較演算子: 値} } ← フィールドの値と比較演算子で比較($gt (>), $gte (>=), $lt (<), $lte (<=), $ne (≠)などがある)

{ {フィールド名1: 値1}, {フィールド名2: 値2} } ← 並べて書くとANDになる(フィールド名1=値1 and フィールド名2=値2)

検索条件

- { フィールド名 : 値 } ← 値をそのまま書くと等号を指定したことになる（フィールド名 = 値）
- { フィールド名: {比較演算子: 値} } ← フィールドの値と比較演算子で比較（$gt (>), $gte (>=), $lt (<), $lte (<=), $ne (≠)などがある）
- { フィールド名1: 値1, フィールド名2: 値2 } ← 並べて書くとANDになる（フィールド名1=値1 and フィールド名2=値2）
- { $or: [{フィールド名1: 値1}, {フィールド名2: 値2}] } ← 条件のORを指定するには$orの後に配列で表現する（フィールド名1=値1 or フィールド名2=値2）
- $orのところで$andと書いて条件のANDの指定も可能

検索条件の例

db.emp.find({ ename: "Smith"}) ← ename = "Smith" に相当

db.emp.find({ salary: {$gte: 100} }) ← salary >= 100に相当

db.emp.find({ deptno: "D01", salary: {$lt: 100} }) ← deptno="D01" **and** salary<100に相当

db.emp.find({ $or: [{deptno: "D03"}, {salary: {$gt: 120}}] } ← deptno="D03" or salary>120に相当

出力フィールド指定

{ フィールド名 : 数値 } 値が0なら指定したフィールドを出力しない、0以外なら出力する

例 { deptno: 0, dname: 1} dnameは出力するが、deptnoは出力しない（出力フィールド指定をつけると通常のフィールドは出力しなくなる）

（注意）**_idフィールドは明示的に0を指定しないと常に出力される**

実行例

```
db.dept.find( {}, { dname:1 } )
{ "_id" : ObjectId("5c07a660427bcba83dd6bb58"), "dname" : "Account" }
{ "_id" : ObjectId("5c07a660427bcba83dd6bb59"), "dname" : "Personnel" }
…
db.dept.find( {}, { _id:0, dname:1 } )
{ "dname" : "Account" }
{ "dname" : "Personnel" }
…
```

SQLとの比較(1)

SQL	MogoDB
select * from emp	db.emp.find()
select * from emp where **empno='E01'**	db.emp.find(**{empno: "E01"}**) *等号の比較は値をそのまま書く*
select **ename** from emp where empno='E01'	db.emp.find({empno: "E01"}, **{ename: 1}**) *第2引数は出力するフィールドの指定* *（値0は出力しない、0以外だと出力）*

SQLとの比較(2)

SQL	MogoDB
select * from emp where **salary >= 90 and** **salary <= 120**	db.emp.find({salary : {$gte: 90, $lte: 120}}) *比較演算子には$gt (>), $gte (>=), $lt (<), $lte (<=), $ne (≠)などがある*
select emp.*, **dept.*** from emp **join dept** **on emp.deptno =** **dept.deptno**	db.emp.**aggregate**([{ **$lookup**: {from:"**dept**", localField:"**deptno**", foreignField: "**deptno**", as: "emp_dept"} }]) *結合問合せに相当する*

集約パイプライン (aggregate pipeline)

- 複数の問合せ処理を組み合わせて実行する
- 個々の処理をステージと呼び、前段のステージの結果が後段のステージに渡される
- ステージは配列の要素として表現する

```
db.コレクション名.aggregate(
[ { ステージ1}, {ステージ2}, …, {ステージn} ]
)
```

集約パイプラインのステージ例

- $match　検索条件を満たすドキュメントを選択する（findの検索条件と同じ）
- $lookup 他のコレクションのドキュメントと結合する（SQLのjoinに相当する）
- $group 問合せの結果をグループ化する
- $project 出力のフィールドを指定する（findの出力フィールド指定と同じ）

$matchステージ

{ $match: { 検索条件 } }

検索条件を満たすドキュメントを選択する（findの検索条件と同じ）

```
db.emp.aggregate( [
 { $match: {ename: "Smith"} }
] )
```

結果

```
{ "_id" : ObjectId("5c07a660427bcba83dd6bb4b"), "empno" : "E01", "ename" : "Smith", "deptno" : "D01", "salary" : 100 }
```

$lookupステージ

他のコレクションのドキュメントと結合する（SQLのjoinに相当する）

```
{ $lookup: {
   from: "結合先のコレクション名",
   localField: "結合対象のフィールド名（結合元）",
   foreignField:"結合対象のフィールド名（結合先）",
   as: "結合で新たにできるフィールドの名前"
} }
```

$lookupの使用例

```
db.emp.aggregate([
  { $match: {ename: "Smith"} },
  { $lookup: { from:"dept", localField:"deptno",
    foreignField:"deptno", as: "emp_dept" } }
])
```

結果

```
{ "_id" : ObjectId("5c07a660427bcba83dd6bb4b"),
"empno" : "E01", "ename" : "Smith", "deptno" : "D01",
"salary" : 100, "emp_dept" : [ { "_id" :
ObjectId("5c07a660427bcba83dd6bb58"), "deptno" :
"D01", "dname" : "Account", "manager" : "E01" } ] }
```

$groupステージ

問合せの結果をグループ化する（SQLのgroup byに相当する）

{ $group: { _id: "$グループ化するフィールド名",
グループ化で作るフィールド名:
{ 集約演算子: 集約対象 } }}

（注意）全体で集約するときは_id: null とする

集約演算子には以下のようなものがある（一部）

$max（最大値）、$min（最小値）、$avg（平均）、
$sum（合計）、$push（フィールドの値を集約）

$groupの使用例(1)

```
db.emp.aggregate([
  {$group: { _id:"$deptno", count: {$sum: 1} } }
])
```

結果

```
{ "_id" : null, "count" : 1 }
{ "_id" : "D01", "count" : 4 }
{ "_id" : "D03", "count" : 3 }
{ "_id" : "D02", "count" : 2 }
{ "_id" : "D91", "count" : 3 }
```

```
db.emp.aggregate([{$group: { _id:null, count: {$sum: 1} }} ])
```

結果

```
{ "_id" : null, "count" : 13 }
```

$groupの使用例(2)

```
db.emp.aggregate([
  {$group: { _id: "$deptno",
             ename: { $push: "$ename" } } }
])
```

結果

```
{ "_id" : null, "ename" : [ "Roosevelt" ] }
{ "_id" : "D01", "ename" : [ "Smith", "Morgan", "Robert", "Taylor" ] }
{ "_id" : "D03", "ename" : [ "Satoh", "Takenaka", "Seno" ] }
{ "_id" : "D02", "ename" : [ "Washington", "Lincoln" ] }
{ "_id" : "D91", "ename" : [ "Suzuki", "Tanaka", "Matsuda" ] }
```

$projectステージ

{ $project: { 出力フィールドの指定 } }

出力のフィールドを指定する（findの出力フィールド指定と同じ）

```
db.emp.aggregate([
  {$match: {ename: "Smith"}},
  {$project: { _id:0, ename:1, salary:1 }}
])
```

結果

```
{ "ename" : "Smith", "salary" : 100 }
```

非正規形データへの対応

- 直積
  - **入れ子構造のオブジェクト**により表現可能

  （例）{name: "基礎工学部",
  address: **{street: "待兼山町1-3",**
  city: "豊中市", zip: "560-8531"}}
- 巾集合
  - **配列**により表現可能

  （例）{name:
  [“大阪太郎”, “大阪春子”, “大阪小太郎"] }

（参考）正規化の例（直積）
(normalization of Cartesian product)

住所録（正規化前）

氏名	住所
大阪太郎	560-8531大阪府豊中市待兼山町
神戸次郎	657-8501兵庫県神戸市灘区六甲台町

住所録（正規化後）

氏名	郵便番号	都道府県	市区	町村
大阪太郎	560-8531	大阪府	豊中市	待兼山町
神戸次郎	657-8501	兵庫県	神戸市灘区	六甲台町

dom（住所）=dom（郵便番号）×dom（都道府県）×dom（市区）×dom（町村）

直積データの例

データベースへの挿入（直積データをオブジェクトの中に埋め込める）

```
db.school.insertOne( {name: ”Engineering”,
  address: {street: "2-1 Yamadaoka",
  city: "Suita",   zip: "565-0871"} } )
db.school.insertOne( {name: "Science",
  address: {street: "1-1 Machikaneyama",
  city: "Toyonaka", zip: "560-0043"} } )
db.school.insertOne( {name: "Engineering Science",
  address: {street: "1-3 Machikaneyama",
  city: "Toyonaka", zip: "560-8531"} } )
```

直積データの問合せ例

問合せ（直積データ（オブジェクト）の中のフィールドを問合せで指定できる）

```
db.school.find({"address.city":"Toyonaka"},{"name":1})
```

結果

```
{ "_id" : ObjectId("587db012c2da811995c28b95"), "name" : "Science" }
{ "_id" : ObjectId("587db021c2da811995c28b96"), "name" : "Engineering Science" }
```

（参考）正規化の例（巾集合）
(normalization of power set)

世帯（正規化前）

世帯	家族
世帯1	{大阪太郎、大阪春子、大阪一太郎}
世帯2	{神戸次郎、神戸夏子、神戸小次郎}

$dom(家族)=2^{dom(構成員)}$

巾集合(power set)とは、ある集合のすべての部分集合からなる集合
例　ドメインD={1,2,3}とすると、Dの巾集合
2^D={{}, {1}, {2}, {3}, {1,2}, {2,3}, {1,3}, {1,2,3}}
となる

世帯（正規化後）

世帯	構成員
世帯1	大阪太郎
世帯1	大阪春子
世帯1	大阪一太郎
世帯2	神戸次郎
世帯2	神戸夏子
世帯2	神戸小次郎

巾集合データの例

データベースへの挿入（配列を使って集合を表現できる）

```
db.registration.insertOne( {subject:"OS",
    lecturer: ["Murata", "Matsuda"] } )
db.registration.insertOne( {subject:"Database",
    lecturer:"Matsuda"} )
```

巾集合データの問合せ例

問合せ

```
db.registration.find({lecturer:"Matsuda"},
    {subject:1})
```

結果

```
{ "_id" : ObjectId("587db73fc2da811995c28b97"),
"subject" : "OS" }
{ "_id" : ObjectId("587db750c2da811995c28b98"),
"subject" : "Database" }
```

MongoDBでのMapReduce処理(1)

- データベースのデータ

```
db.Orders.insertOne({"Name":"notebook",
  "Price":200, "Category":"material"}), …
db.Orders.insertOne{"Name":"bread",
  "Price":100, "Category":"food"}), …
```

- 結果

```
{"_id":"food",
 "value":{"Category":"food", "Count":2, "Amount":320} }
{"_id":"material",
 "value":{"Category":"material", "Count":3,"Amount":300}}
```

出典開発者が知っておくべき、ドキュメント・データベースの基礎
http://www.atmarkit.co.jp/ait/articles/1211/09/news056.html

（参考）MapReduceの実装

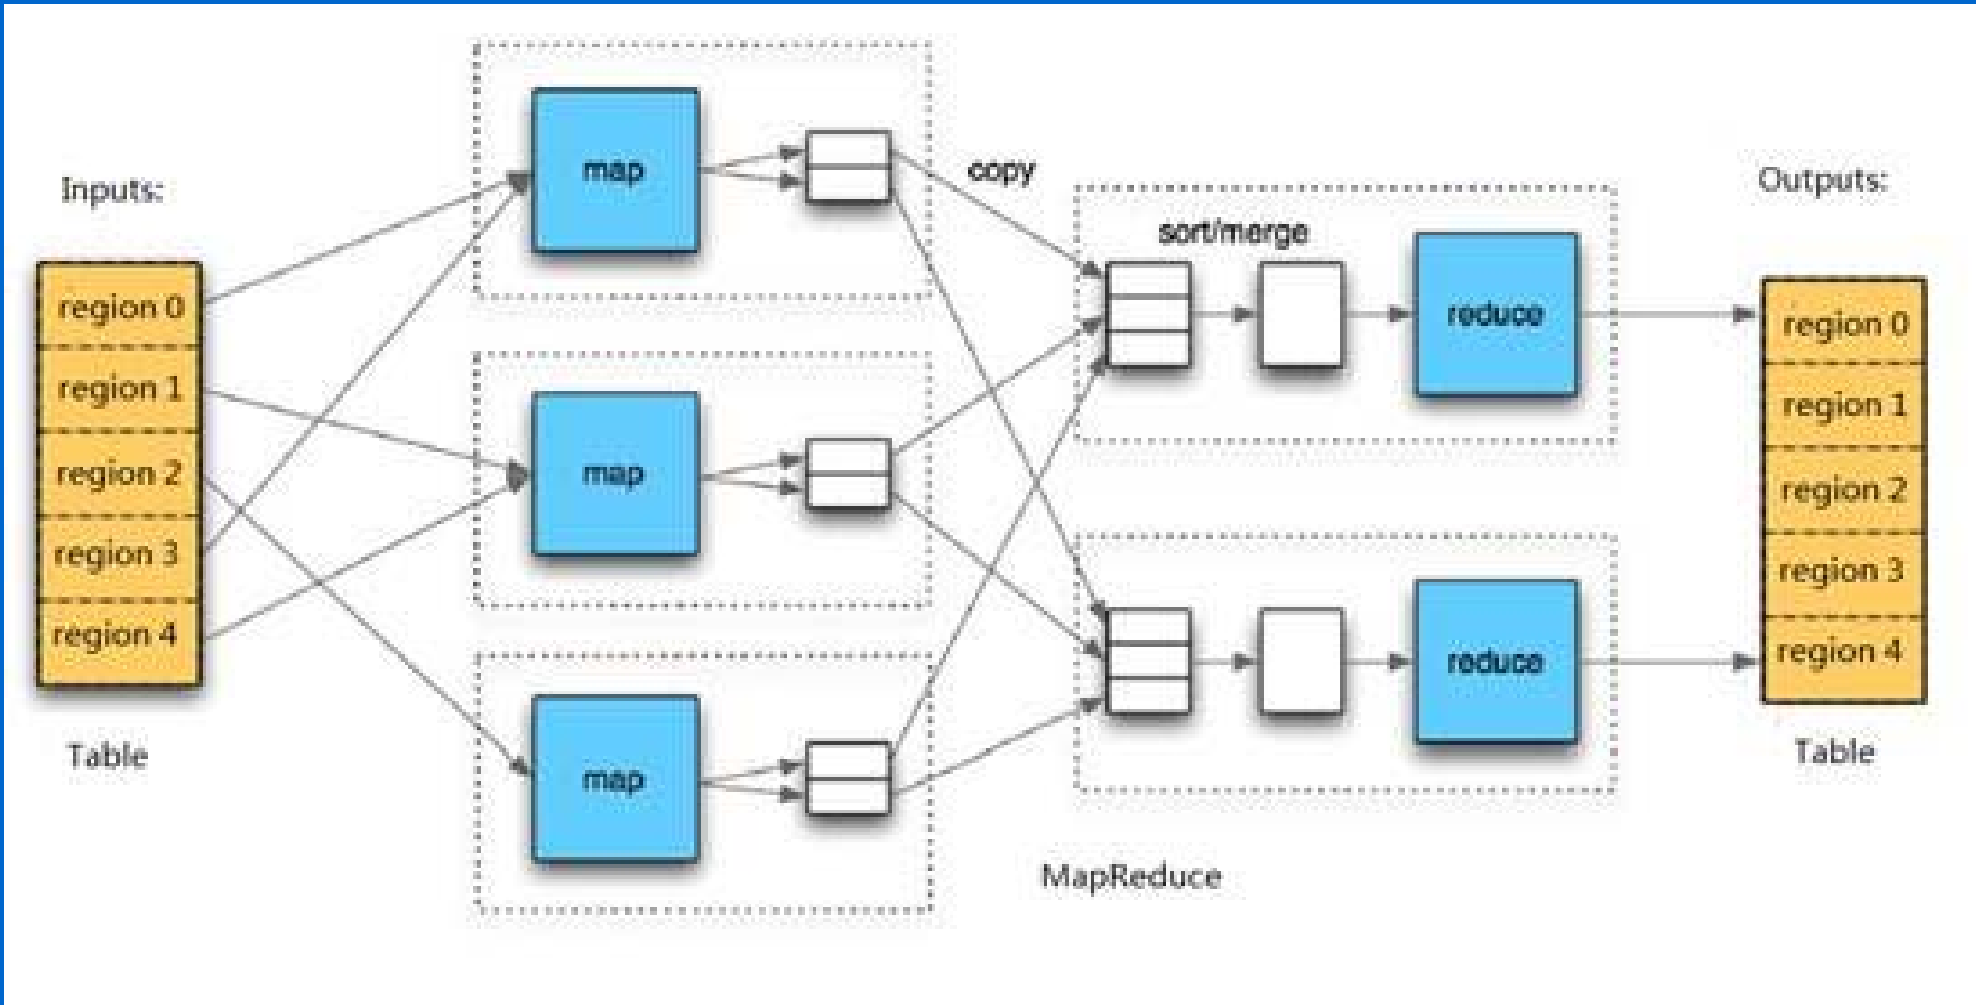

出典　"Turn" Introduction to HBase Technology,
URL: http://www.programering.com/a/MjNwQjNwATQ.html

MongoDBでのMapReduce処理(2)

mapの関数とreduceの関数をユーザが定義して処理する

```
function mapf() {
 emit(this.Category,
 {Category:this.Category, Count:1, Amount:this.Price})
}
function reducef(key, values) {
 var result = {Category:key, Count:0, Amount:0};
 values.forEach(function(v) {
   result.Count += v.Count;
   result.Amount  += v.Amount; });
 return result; }
```

MongoDBでのMapReduce処理(3)

- 実行

```
db.Orders.mapReduce(mapf, reducef,
  {out: {replace:"testcol"}} )
```

- 実際に分散サーバ環境で実行するには、次に説明するshardingを利用する

MongoDBの分散環境での実行（sharding）

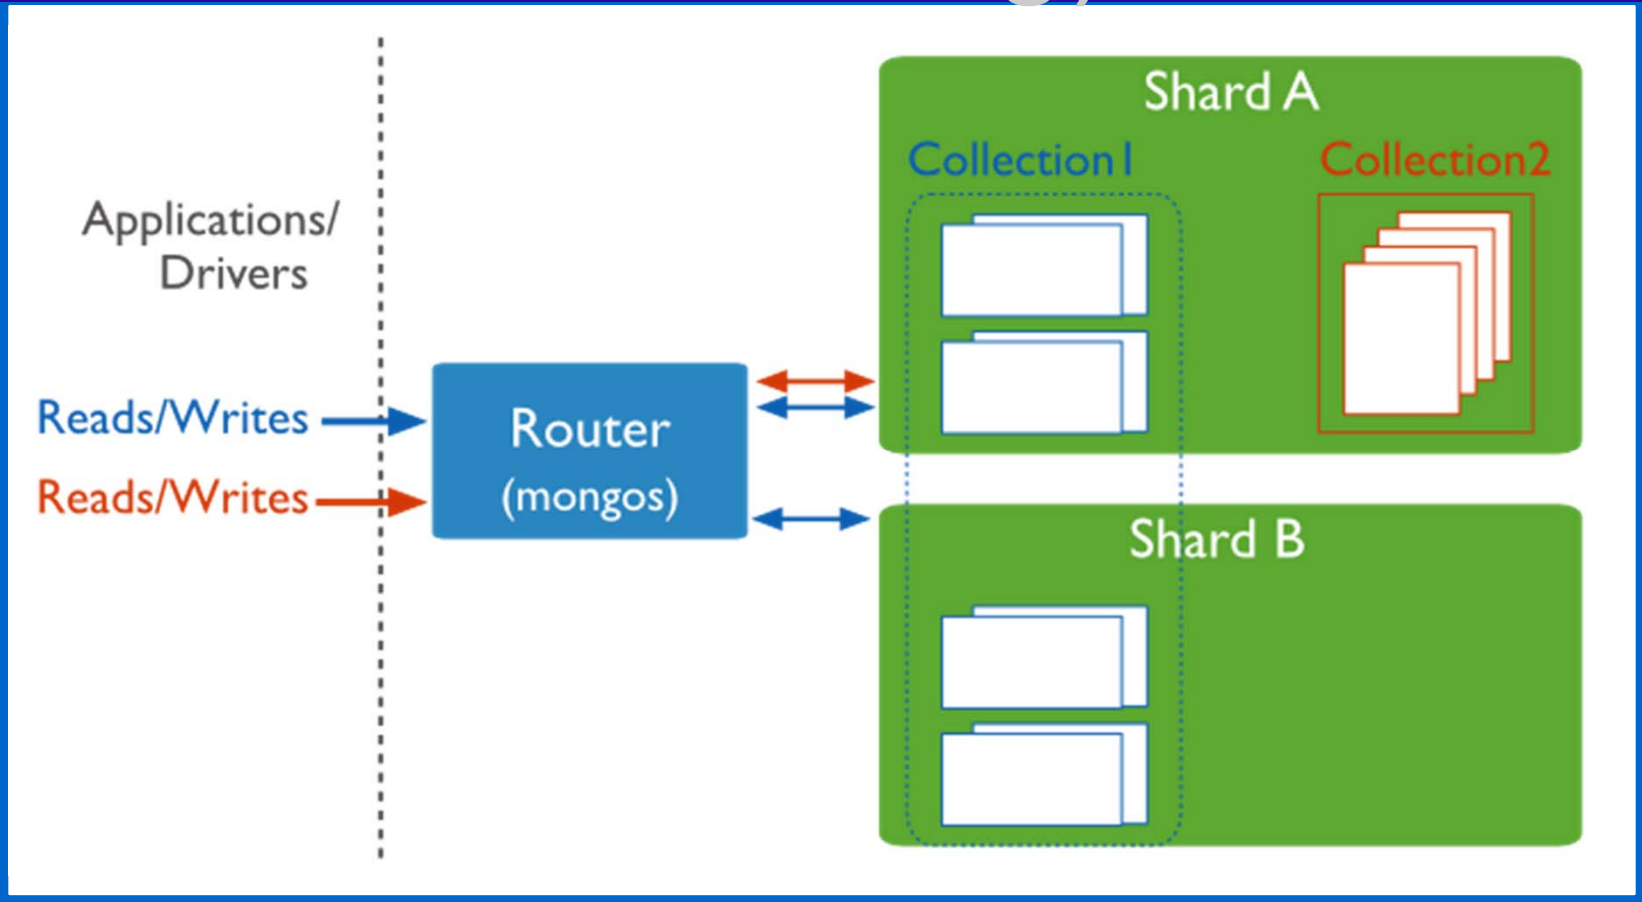

クライアントからの処理要求をルータサーバで振り分けて複数のデータベースサーバに割り付ける

出典 MongoDB Documentation https://docs.mongodb.com/

Neo4j

- グラフ型のNoSQLデータベース
- データベースのデータを、**節点(node)**と**辺(relationships)**からなる**グラフで表現**、節点と辺には**属性(property)**を付与できる
- CypherというSQLに似たデータ操作言語を備える
- 問合せでは**グラフを探索**（複数の節点や辺にまたがる結合問合せを表現可能）
- ACID特性を持つトランザクション（ただしC（整合性）は複数サーバで使うときは**結果整合性**）
- 大規模なグラフデータを高速に検索可能（10億ノードのグラフを数分で検索、MapReudeではなく独自の複数サーバ分散技術(causal clustering)を利用）

リレーショナルデータベースとの比較

emp

empno (P)	ename	deptno (R)	salary	roomno (R)
E01	Smith	D01	100	R01
E02	Morgan	D01	70	R02

dept

deptno (P)	dname	manager (R)
D01	Account	E01

room

roomno (P)	rname	deptno (R)
R01	Account Room 1	D01
R02	Account Room 2	D01

（注） (P)は主キー、(R)は外部キーを表す

Neo4jでのデータベース

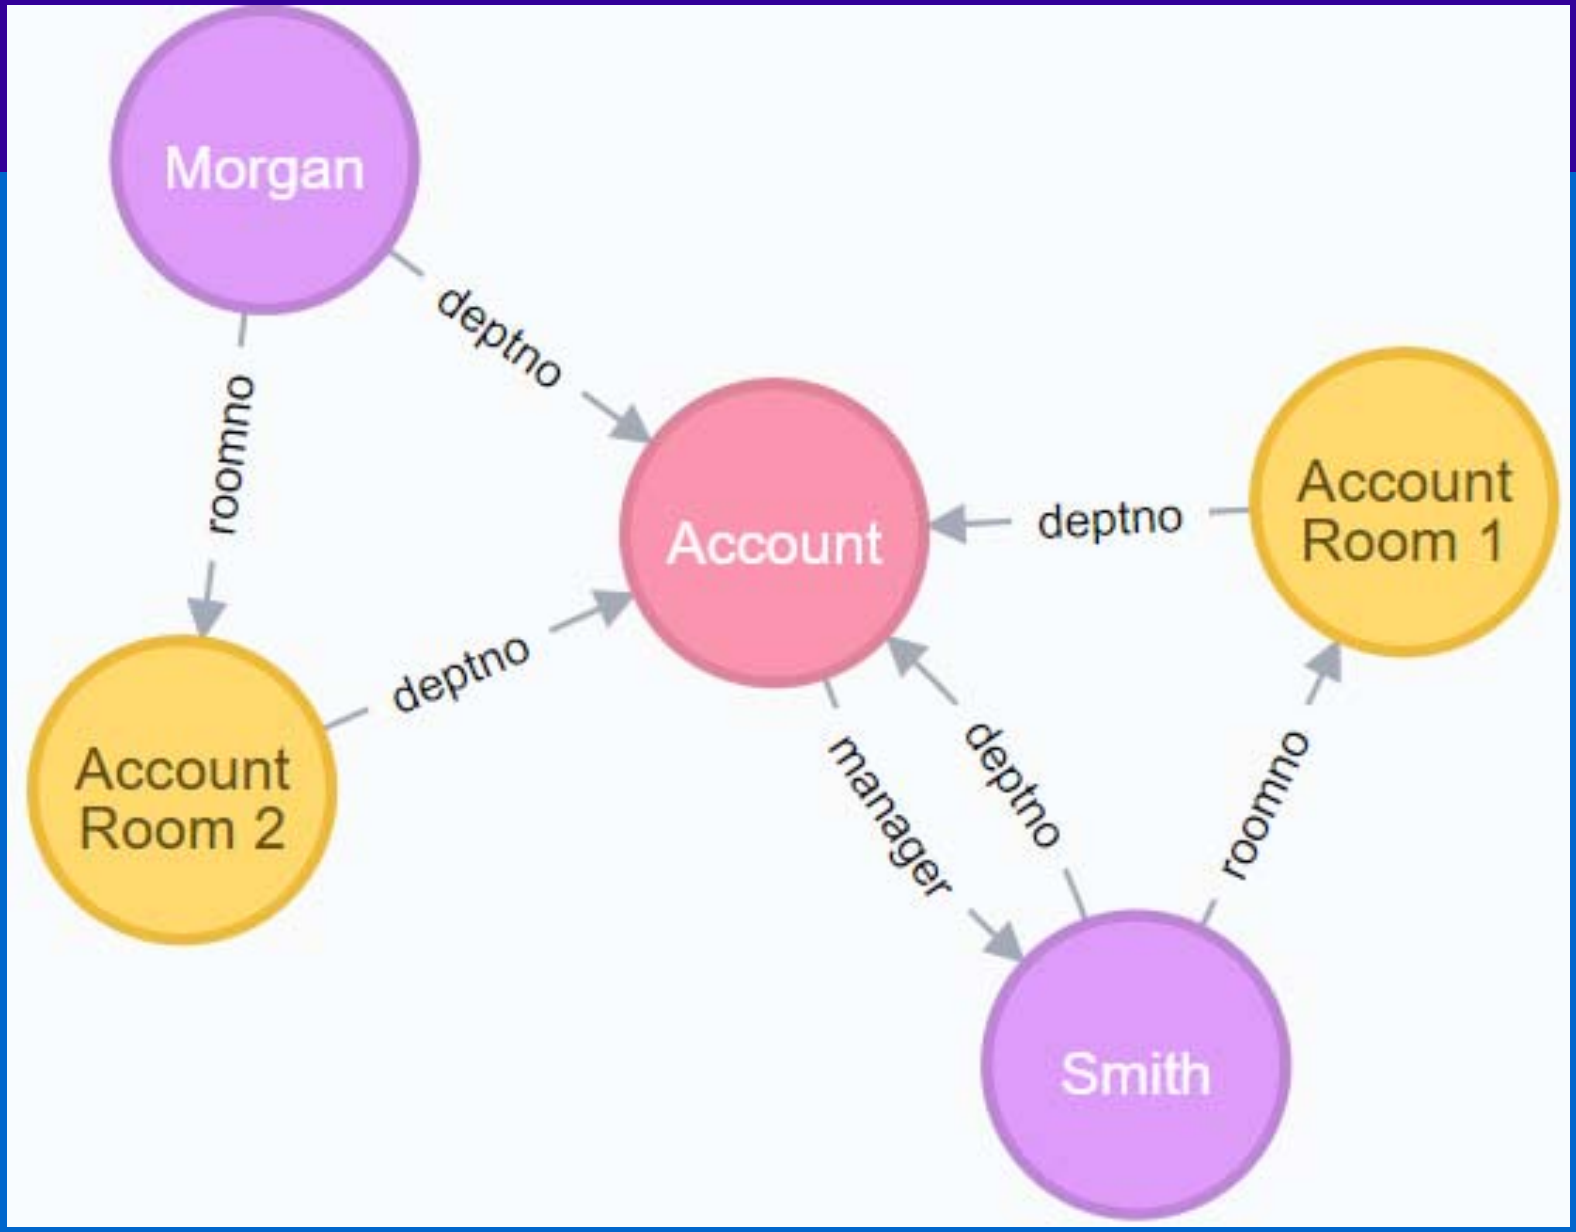

（注） タップルを節点(node)、外部キーを辺(relationship)で表現する

Neo4jでのデータ登録例

- **CREATE**文によりデータを登録する
- 節点データの登録

  CREATE (変数:ラベル {属性リスト})
- 辺データの登録

  CREATE (変数1)-[:ラベル]->(変数2)

（例）（注）E01, E02, D01, R01, R02はIDではなく登録時にのみ有効な一時的な変数

```
CREATE (E01:emp {ename: 'Smith', salary: 100}),
       (D01:dept {dname: 'Account'}),
       (R01:room {rname: 'Account Room 1'}),
       (E01)-[:deptno]->(D01), (E01)-[:roomno]->(R01),
       (D01)-[:manager]->(E01), (R01)-[:deptno]->(D01)
CREATE (E02:emp {ename: 'Morgan', salary: 70}),
       (R02:room {rname: 'Account Room 2'}),
       (E02)-[:deptno]->(D01), (E02)-[:roomno]->(R02),
       (R02)-[:deptno]->(D01)
```

Neo4jでの問合せ

- **MATCH**文により問合せを記述する
- 節点に対する問合せ

MATCH (変数:ラベル) WHERE 検索条件 RETURN 検索対象

- 辺に対する問合せ（SQLの結合問合せに相当する）

MATCH (変数1:ラベル1)-[:ラベル3]->(変数2:ラベル2)
WHERE 検索条件 RETURN 検索対象

（例）

```
MATCH (e:emp) WHERE e.salary>=100
  RETURN e.ename
MATCH (e:emp)-[:deptno]->(d:dept)
  WHERE e.ename='Smith' RETURN d.dname
MATCH (e:emp)-[:deptno]->(d:dept)
  WHERE d.dname='Account' RETURN e.ename
```

（注）属性の条件を属性リストを使って書くことも可能

```
MATCH (e:emp {ename: 'Smith'} )-[:deptno]->(d:dept)
  RETURN d.dname
```

グラフ探索の例(1)

- 経路を求める

```
MATCH p=((e1:emp)-[*]->(e2:emp))
WHERE e1.ename='Morgan' AND e2.ename='Smith'
RETURN p
```

（別の記法:MATCH文の属性条件を属性リストで表記）

```
MATCH p=((e1:emp {ename: 'Morgan'} )-[*]->
            (e2:emp {ename: 'Smith'} )) RETURN p
```

（結果）複数の経路が表示される

[{"salary":70,"ename":"Morgan"},{},{"rname":"Account Room 2"},{"rname":"Account Room 2"}, {}, {"dname":"Account"}, {"dname":"Account"},{},{"salary":100,"ename":"Smith"}]

[{"salary":70,"ename":"Morgan"},{},{"dname":"Account"}, {"dname":"Account"},{},{"salary":100,"ename":"Smith"}]

グラフ探索の例(2)

- 最短経路を求める

```
MATCH p=shortestPath((e1:emp)-[*]->(e2:emp))
WHERE e1.ename='Morgan' AND e2.ename='Smith'
RETURN p
```

（別の記法:MATCH文の属性条件を属性リストで表記）

```
MATCH p=shortestPath((e1:emp {ename: 'Morgan'})
                -[*]->(e2:emp {ename: 'Smith'})) RETURN p
```

（結果）最短経路のみが表示される

[{"salary":70,"ename":"Morgan"},{},{"dname":"Account"},
{"dname":"Account"},{},{"salary":100,"ename":"Smith"}]

Neo4jの複数サーバでの利用例

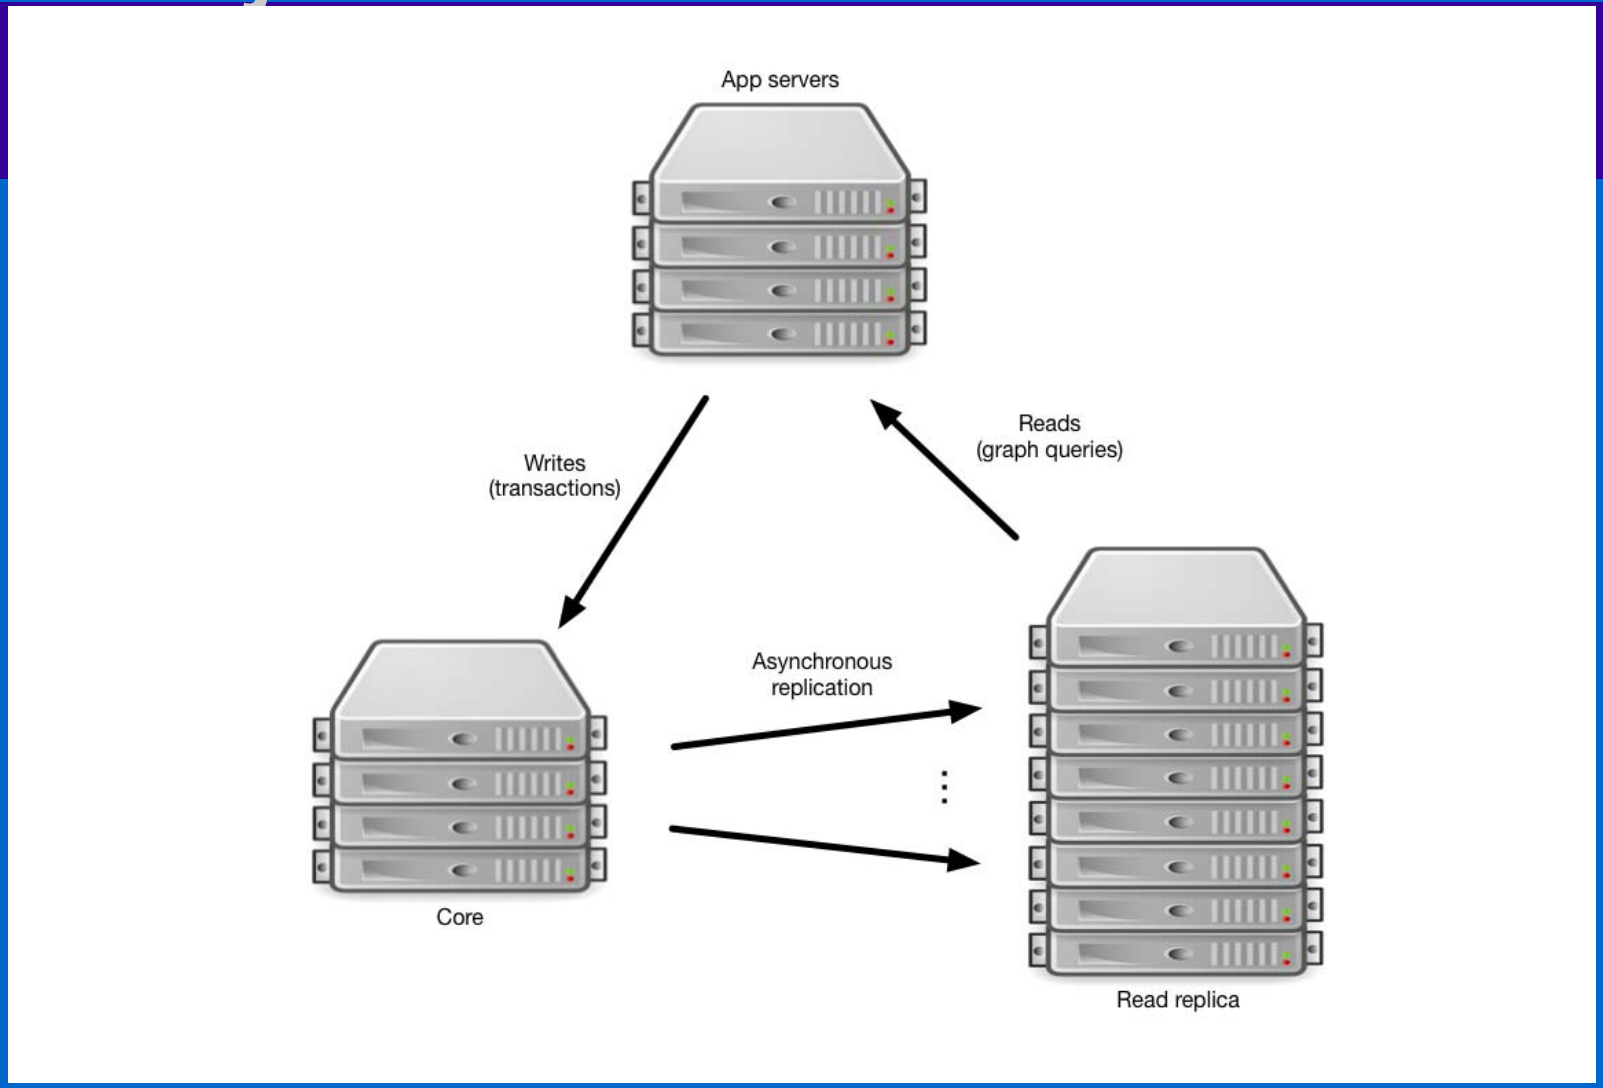

複数のクライアント(App servers)からのアクセスは、更新を単一のサーバ(core)に、問合せをデータベースの複製サーバ(Read replica)に分けることで性能を向上
複数の更新が独立に生じると、クライアントごとに読む複製の値が一時的に異なることが起こり得るが、十分長い時間に更新がなければ同じ値になる(結果整合性)