MongoDB – dokumentni nerelacijski SUPB

- dokumentno-usmerjen SUPB (JSON/BSON)
- lasten komunikacijski protokol
- konzola uporablja JavaScript sintakso
- podatkovna baza -> zbirke dokumentov (Collections) -> dokumenti (Documents)
- Porazdelitev in replikacija podatkov v oblikah master-slave ali delitev (sharding)
- sistem ne uporablja stikov podatkov (vendar so možni v uporabniškem programu)
- Osnovni (BSON) podatkovni tipi: null, boolean, 32/64-bit integer, double (64-bit FP), **decimal128** (128-bit BCD izpeljanke), string, datum/ura (timestamp)

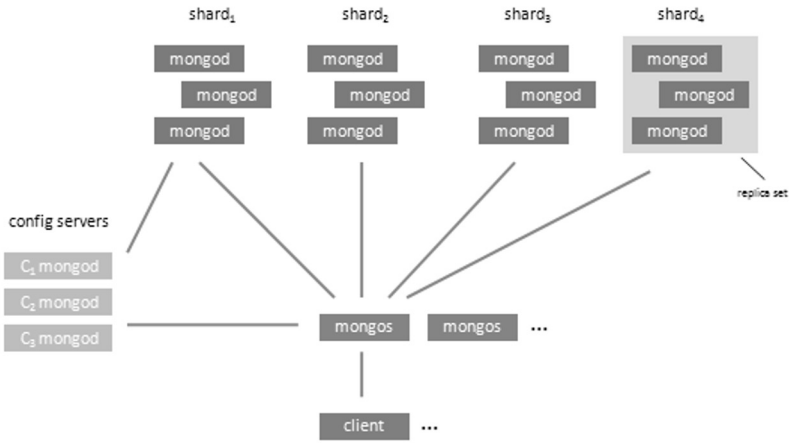

- polna postavitev sistema:
  - mongod - strežnik podatkov
  - mongos - usmerjevalnik k podmnožici podatkov
  - strežniki so lahko replicirani (redundantnost)
  - ločena konfiguracija od podatkov (konfiguracijski strežniki)

JSON in BSON dokumentna formata

- **JSON (JavaScript Object Notation)**
  - Semantično je dober približek za JSON Pythonov slovar (dict)
  - Tekstoven format, berljiv za ljudi, a potraten
  - Bolj ali manj standarden format za izmenjavo podatkov na spletu.
  - Podpira omejen nabor podatkovnih tipov (string, število, boolean, null, polje)
- **BSON (Binary JSON)**
  - Binaren format, optimiziran za shranjevanje in obdelavo.
  - Ni berljiv za ljudi.
  - Podpira več podatkovnih tipov kot JSON (npr. datum, binarni podatki).
  - Običajno mnogo hitrejši za obdelavo kot JSON.
  - Čeprav MongoDB interno uporablja BSON, še vedno lahko komunicira z uporabo JSON (samodejno pretvarja JSON↔BSON).

Namestitev

- http://www.mongodb.org/, prenos "community" različice (oktober 2024: 7.0.14 ali 8.0); platforma ali Docker vsebnik(i)
- mongod - strežniški program
  - pot do podatkov: argument --dbpath ali uporaba konfiguracijske datoteke in --config
  - strežnik posluša na vratih 27017
  - spletni administrativni strežnik posluša na vratih 28017
- mongosh - odjemalec (ukazna vrstica); compass – GUI okolje
- uporaba JSON in JavaScript sintakse (specifikacija dokumentov, poizvedb, skripte, ...)
- enostaven dostop od drugod, npr. Python - pymongo

```
> mongod --config mongodb.config
Mon Nov 05 16:20:46 [initandlisten] MongoDB starting : pid=8384 port=27017 dbpath=c:\mongodb\data 64-bit host=quaddrix
Mon Nov 05 16:20:46 [initandlisten] db version v2.2.0, pdfile version 4.5
Mon Nov 05 16:20:46 [initandlisten] git version: f5e83eae9cfbec7fb7a071321928f00d1b0c5207
Mon Nov 05 16:20:46 [initandlisten] build info: windows sys.getwindowsversion(major=6, minor=1, build=7601, platform=2,
service_pack='Service Pack 1') BOOST_LIB_VERSION=1_49
Mon Nov 05 16:20:46 [initandlisten] options: { config: "mongodb.config", dbpath: "c:\mongodb\data" }
Mon Nov 05 16:20:46 [initandlisten] journal dir=c:/mongodb/data/journal
Mon Nov 05 16:20:46 [initandlisten] recover : no journal files present, no recovery needed
Mon Nov 05 16:20:46 [initandlisten] waiting for connections on port 27017
Mon Nov 05 16:20:47 [websvr] admin web console waiting for connections on port 28017
```

Primerjava pojmov

SQL	MongoDB
database (podatkovna baza)	database (podatkovna baza)
table (tabela)	collection (zbirka)
row (vrstica)	dokument JSON
column (stolpec)	JSON field (polje v dokumentu JSON)
primary key (primarni ključ)	polje _id v dokumentu JSON
indeks	indeks
group by	agregacija

Primarni ključ dokumenta: _id

- Striktneje: ekvivalent primarnega ključa
- Imeti mora enolično določeno, nespremenljivo vrednost
- Lahko je poljubnega tipa (razen array)
- Lahko ga podamo pri kreiranju dokumenta
- Če ga ne podamo, ga MongoDB kreira avtomatsko v obliki ObjectId

- ObjectId:
  - 12-bytni BSON (binarni JSON) zapis

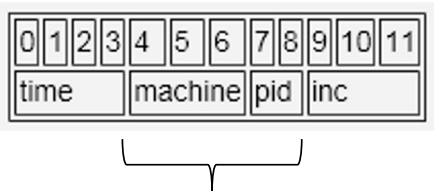

Prvi koraki

- `show dbs` // seznam baz podatkov
- `show collections` // seznam zbirk
- `use <podatkovna_baza>` // uporabi podano bazo
- `db` // referenca do aktivne baze

- `db.help()` // pomoč
- `db.stats()` // statistike
- `db.version()` // različica

- lena izvedba: **ustvarjanje baz in zbirk** je **implicitno** ob ustvarjanju dokumentov

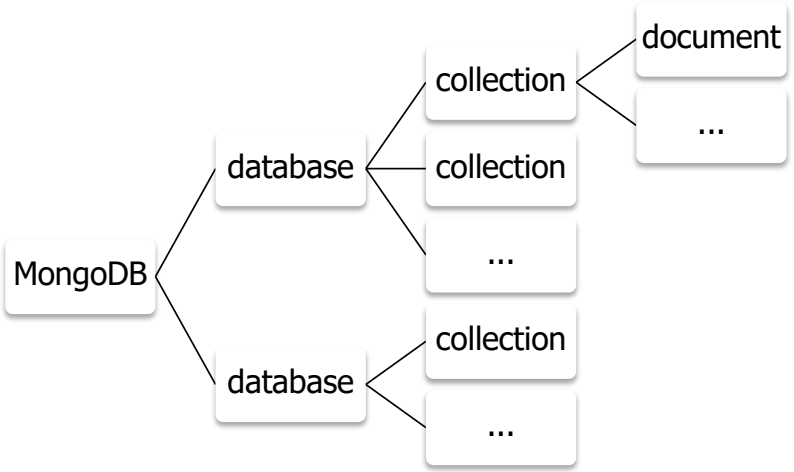

Delo z dokumenti

```
// ustvari ali uporabi bazo tup
use tup

// največja velikost dokumenta 16 MB (od 2018 dalje)
db.studenti.insertOne({ime: "janko", priimek: "novak"})
db.studenti.insertOne({ime: "peter", priimek: "klepec"})

db.studenti.deleteOne(kriterij)     // ali deleteMany
db.studenti.deleteOne({priimek:"klepec"})

db.studenti.drop()                  // brisanje cele zbirke (hitreje!)

db.studenti.findOne(kriterij)       // vrne prvi zadetek
db.studenti.find(kriterij)          // vrne kurzor na zadetke

// posodobi enega ali vse dokumente, ki ustrezajo kriteriju
db.studenti.updateOne(kriterij, novi_dokument) // ali updateMany
db.studenti.updateOne({priimek:"klepec"},{$set:{ime:"pavel", starost:25}})

// To je JavaScript sintaksa, pymongo sintaksa je malenkost drugačna.
```

Iskanje – primerjalni operatorji in modifikatorji

- `$eq/$ne, $in/$nin, $gt/$lt, $gte/$lte, $and/$or/$not/$nor`
- `db.x.find({visina: {$gt: 180}})` `// višina večja od 180`

- `db.x.find({prijatelji: {$ne: "Bojan"}})` `// prijatelj ni enak "Bojan"`
- `db.x.find({teza: {$in: [70, 75]}})` `// teža je v podani množici`
- `db.x.find({teza: {$nin: [70, 75]}})` `// teža ni v podani množici`
- `db.x.find({$or: [{teza: {$gt: 80}},`
  `{visina: {$gt: 180}}]})` `// disjunkcija`
- `db.x.find({teza: {$not : {$mod: [5,0]}}})` `// teža ni deljiva s 5`
- `db.x.find({prijatelji: {$all: ["Bojan", "Teo"]}})` `// vsebovanost podmnožice`
- `db.x.find({prijatelji: {$size: 3}})` `// velikost polja je 3`
- `db.x.find({}, {prijatelji: {$slice: [0,2]}})` `// izberi rezino (del) polja`
- `db.x.find({polje : {$exists : 1}})` `// izberi, če polje obstaja`

Posodabljanje (updateOne/updateMany)


```
db.x.updateOne({ime: "Eva"}, {nov dokument})                // zamenjaj cel dokument
db.x.updateOne({ime: "Eva"}, {$set : {mama : "Ana"}})       // nastavi element
db.x.updateOne({ime: "Eva"}, {$unset : {mama : 1}})         // odstrani element
db.x.updateOne({ime: "Eva"}, {$inc : {starost : 5}})        // inkrement elementa
db.x.updateOne({ime: "Eva"}, {$push : {prijatelji : "Janez"}}) // dodaj v polje
db.x.updateOne({ime: "Eva"}, {$addToSet : {loto : 42}})     // dodaj brez ponav.
db.x.updateOne({ime: "Eva"}, {$pop : {loto : 1}})           // odstrani s konca polja
db.x.updateOne({ime: "Eva"}, {$pop : {loto : -1}})          // odstrani z začetka polja
db.x.updateOne({ime: "Eva"}, {$pull : {loto : 15}})         // odstrani iz polja

db.x.updateOne( {ime: "Eva"}, {$inc : {starost : 5}}, {upsert:true}) // upsert ...
db.x.updateMany({ime: "Eva"}, {$inc : {starost : 5}}, {upsert:true}) // ... za vse zadetke
```

Gnezdeni dokumenti

- možno gnezdenje dokumentov in iskanje po gnezdenih seznamih (npr. knjige.avtorjev)

```
doc = {   ime : "Janko",
          priimek : "Novak",
          knjige : [
                    { avtorjev : 3, strani : 100},
                    { avtorjev : 5, strani : 50},
                    { avtorjev : 8, strani : 400}
                   ]
          }
```

- // iskanje z identično vsebino
  `db.primer.find({ime: {priimek: "Novak", prvo: "Janko"})`
- // iskanje po poljih
  `db.primer.find({"ime.prvo": "Janko", "ime.priimek": "Novak"})`
- // pogoji vezani na vsebino vsakega elementa
  `db.primer.findOne({knjige: {$elemMatch: {avtorjev : 3, strani : 50 }}})`
- // pozicijsko iskanje po prvi knjigi v seznamu
  `db.primer.findOne({"knjige.1.strani": 50})`
- // $ nadomesti pozicijo najdenega dokumenta
  `db.primer.findOne({"knjige.avtorjev" : 3, "knjige.strani": 50 }, {"knjige.$":1})`

Literatura

- Osnovna literatura
  https://docs.mongodb.org/manual

- kratki (referenčni) povzetki:
  https://www.10gen.com/reference

- MongoDB Fundamentals, Amit Phaltankar (2020)
  https://www.packtpub.com/en-us/product/mongodb-fundamentals-9781839210648

- Python data persistence: With SQL and NOSQL Databases
  https://bpbonline.com/products/python-data-persistence-sql-and-nosql-programming-book-ebook

Literatura

Queries and What They Match

`{a: 10}`	Docs where a is 10, or an array containing the value 10.
`{a: 10, b: "hello"}`	Docs where a is 10 and b is "hello."
`{a: {$gt: 10}}`	Docs where a is greater than 10. Also `$lt` (<), `$gte` (>=), `$lte` (<=), and `$ne` (!=).
`{a: {$in: [10, "hello"]}}`	Docs where a is either 10 or "hello."
`{a: {$all: [10, "hello"]}}`	Docs where a is an array containing both 10 and "hello".
`{"a.b":| 10}`	Docs where a is an embedded document with b equal to 10.
`{a: {$elemMatch: {b: 1, c: 2}}}`	Docs where a is an array containing a single item with both b equal to 1 and c equal to 2.
`{$or: [{a: 1}, {b: 2}]}`	Docs where a is 1 or b is 2.
`db.foo.find({a: /^m/})`	Docs where a begins with the letter "m".

The following queries cannot use indexes as of MongoDB v2.0. These query forms should normally be accompanied by at least one other query term which *does* use an index:

`{a: {$nin: [10, "hello"]}}`	Docs where a is anything but 10 or "hello."
`{a: {$mod: [10, 1]}}`	Docs where a mod 10 is 1.
`{a: {$size: 3}}`	Docs where a is an array with exactly 3 elements.
`{a: {$exists: true}}`	Docs containing an a field.
`{a: {$type: 2}}`	Docs where a is a string (see bsonspec.org for more types).
`{a: /foo.*bar/}`	Docs where a matches the regular expression "foo.*bar".
`{a: {$not: {$type: 2}}}`	Docs where a is not a string. `$not` negates any of the other query operators.

Literatura

SQL	MongoDB
SELECT * FROM users WHERE age <= 33	db.users.find({age: {$lte: 33})
SELECT * FROM users WHERE name LIKE '%Joe%'	db.users.find({name: /Joe/})
SELECT * FROM users WHERE name LIKE 'Joe%'	db.users.find({name: /^Joe/})
SELECT * FROM users WHERE age > 33 AND age < 40	db.users.find({age: {$gt: 33, $lt: 40}})
SELECT * FROM users ORDER BY name DESC	db.users.find().sort({name: -1})
SELECT * FROM users WHERE age = 32 AND name = 'Bob'	db.users.find({age: 32, name: "Bob"})
SELECT * FROM users LIMIT 10 SKIP 20	db.users.find().skip(20).limit(10)
SELECT * FROM users WHERE age = 33 OR name = 'Bob'	db.users.find({$or:[{age:33}, {name: "Bob"}]})
SELECT * FROM users LIMIT 1	db.users.findOne()
SELECT DISTINCT name FROM users	db.users.distinct("name")
SELECT COUNT(*) FROM users	db.users.count()
SELECT COUNT(*) FROM users WHERE AGE > 30	db.users.find({age: {$gt: 30}}).count()
SELECT COUNT(AGE) FROM users	db.users.find({age: {$exists: true}}).count()
CREATE INDEX ON users (name ASC)	db.users.ensureIndex({name: 1})
CREATE INDEX ON users (name ASC, age DESC)	db.users.ensureIndex({name: 1, age: -1})
EXPLAIN SELECT * FROM users WHERE age = 32	db.users.find({age: 32}).explain()
UPDATE users SET age = 33 WHERE name = 'Bob'	db.users.update({name: "Bob"}, {$set: {age: 33}}, false, true)
UPDATE users SET score = score + 2 WHERE name = 'Bob'	db.users.update({name: "Bob"}, {$inc: {score: 2}}, false, true)
DELETE FROM users WHERE name = 'Bob'	db.users.remove({name: "Bob"})

Kurzorji

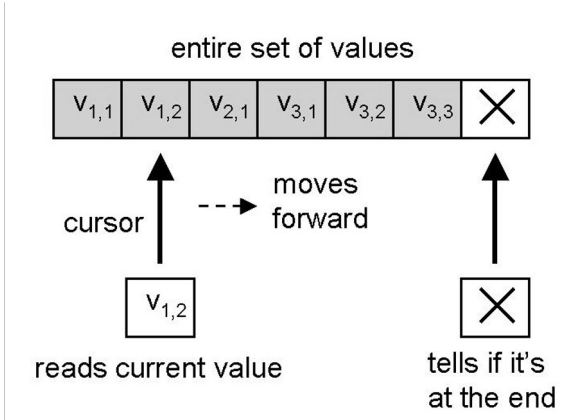

- kurzor - oblika iteratorja po podatkih v zbirki

- `var cur = db.evidenca.find()` // vrni kurzor
- `cur.forEach(function (x) {printjson(x); })` // iteracija po kurzorju

- `limit`, `skip`, `sort`
- `limit` in `skip` uporabna za ostranjevanje (pagination) v aplikacijah)

- `db.evidenca.find().limit(3)` // omeji na prve 3 zapise
- `db.evidenca.find().skip(3)` // preskoči 3 zapise
- `db.evidenca.find().sort({starost : 1})` // sortiranje naraščajoče
- `db.evidenca.find().sort({visina : -1})` // sortiranje padajoče

- `db.evidenca.countDocuments()` // štetje zadetkov
- `db.evidenca.countDocuments({visina: {$gt : 170}})` // štetje s pogojem
- `db.evidenca.distinct("visina")` // seznam različnih
- `db.evidenca.estimatedDocumentCount()` // "približno" štetje dokumentov iz metapodatkov

Indeksiranje

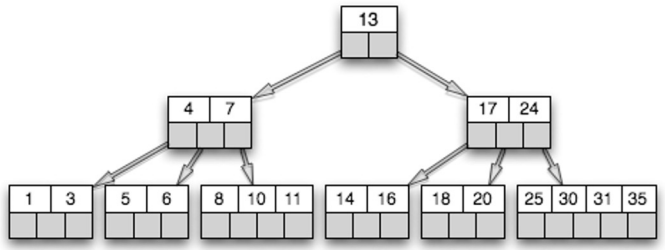

- omejitev: največ 64 indeksov na zbirko
- indeks na {a : 1, b : 1, c : 1, ..., z : 1} pohitri delovanje poizvedb {a: 1}, {a : 1, b: 1}, {a : 1, b : 1, c : 1, ...}, ...
- možno tudi indeksiranje gnezdenih dokumentov
- podatkovna struktura indeksov: B-drevesa (kot pri relacijskih PB)

- `db.x.createIndex({visina: 1})` // izdelava indeksa
- `db.x.createIndex({visina: 1}, {name : "indy"})` // poimenovanje indeksa
- `db.x.dropIndex({visina: 1})` // brisanje indeksa
- `db.x.createIndex({visina: 1}, {unique : true})` // unikatni indeks (za ključe)

- `db.x.find({starost : 33}).explain()` // poda statistiko poizvedbe

Geoprostorsko indeksiranje

- iskanje točk, ki so po lokaciji (koordinatah) sorodne izvorni točki

- vsak dokument vsebuje en par podatkov, ki predstavljajo lokacijo;

- koordinate so običajno na intervalu od -180 do 180 (ustreza zemljepisni dolžini/širini)

```
{ "gps" : [ 0, 100 ] }
{ "gps" : { "x" : -30, "y" : 30 } }
{ "gps" : { "latitude" : -180, "longitude" : 180 }}
```

- izgradnja indeksa

```
db.map.createIndex({"gps" : "2d"})
```

Geoprostorsko indeksiranje

- iskanje:
  - `db.map.find({"gps" : {$near : [40, -73]}})`
  - `db.map.find({"gps" : {$within : {$box : [[10, 20], [15, 30]]}}})`
  - `db.map.find({"gps" : {$within : {$center : [[12, 25], 5]}}})`
    - kot oblika možni tudi $center, $circle ali $poly

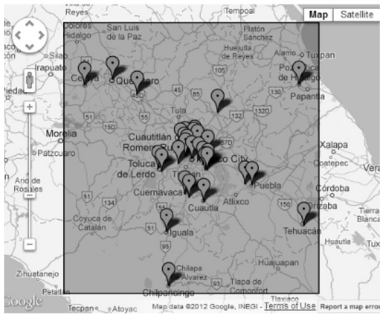

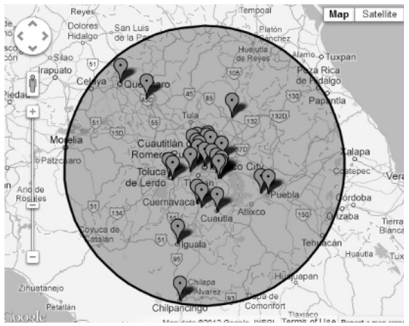

- možna kombinacija indeksov za optimicijo iskanja po različnih poljih
  - `db.places.ensureIndex( { location : "2d" , category : 1 } );`
  - `db.places.find( { location : { $near : [50,50] }, category : 'coffee' } );`

- tipi indeksov: 2d – ravninska geometrija, 2dsphere – sferična geometrija (WGS84, World Geodetic System, 1984; uporablja GPS)

Kompleksne poizvedbe

- operator $where
- pozor: počasna izvedba (pretvorba iz BSON v JavaScript, dela brez uporabe indeksov)

```
> db.primer.insert({jabolko: 1, banana : 6, breskev : 3})
> db.primer.insert({jabolko: 8, ananas : 4, lubenica : 4})

> db.primer.findOne({$where: function () {
... for (var prvi in this) {
...     for (var drugi in this) {
...         if (prvi != drugi && this[prvi] == this[drugi]) return true;
...     }
... }
... return false;
... }})

{
        "_id" : ObjectId("5098b267b6979a0c0c662391"),
        "jabolko" : 8,
        "ananas" : 4,
        "lubenica" : 4
}
```

PyMongo – MongoDB odjemalec

- Instalacija v Python:
  - conda install pymongo (distribucija Anaconda)
  - pip install pymongo
- Navodila: http://api.mongodb.org/python/current/tutorial.html

Uporaba iz Pythona (pymongo)

- Bistvene razlike do JS konzole
  - zapis funkcij s podčrtaji (find_one namesto findOne ipd.)
  - slovarji ali BSON namesto JSON

```
from pymongo import MongoClient

client = MongoClient('localhost', 27017)# privzeti parametri
db = client.sample_mflix               # baza sample_mflix
db.list_collection_names()             # seznam vseh zbirk

db.movies.insert({'title': 'The Terminator Test')     # dodajanje dokumenta

term = db.movies.find({'title': {'$regex'  : '.*terminator.*', '$options': 'i'} })

for movie in
db.movies.find({'title':{'$regex':'.*terminator.*','$options':'i'}},{'year':1,'title':1}):
    print(movie['title'], movie['year']) #  ... ali ...
    print(movie['title'], movie.get('year', '???'))
```

Iskanje, posodabljanje

```
query = {'title': {'$regex': '.*terminator.*', '$options': 'i'}}

# štetje zapisov - count
len(list(db.movies.find(query))) # 6
db.movies.count_documents(query) # 6

# omejitev števila zadetkov – limit
len(list(db.movies.find(query).limit(3))) # 3

# uporaba modifikatorjev, sortiranje
```

- for x in db.izpiti.find({"letnik": {"$gt": 1}}).sort("ime"): x

- # posodabljanje zapisov
- **db.izpiti.update({"letnik": 1},{"$inc": {"letnik" :1}}) # samo prvi**
- **db.izpiti.update({"letnik": 1},{"$inc": {"letnik" :1}}, multi=True) # vseh zadetkov**
- **db.izpiti.update({"letnik": 1},{"$inc": {"letnik" :1}}, upsert=True) # ustvari, če ne obstaja**

Indeksi: navadni in geoprostorski

- ```
  # indeksiranje
  db.izpiti.create_index([("letnik", ASCENDING), ("author", ASCENDING)])
  db.izpiti.drop_index([("letnik", ASCENDING), ("author", ASCENDING)])

  db.izpiti.find({...}).explain()["cursor"]             # statistike iskanja
  db.izpiti.find({...}).explain()["nscanned"]
  ```

- ```
  # geoprostorsko indeksiranje
  import bson
  loc = bson.SON()                                # ohranja vrstni red elementov
  loc["x"]=3
  loc["y"]=4
  dok = {"ime": "Metka", "loc": loc}
  db.prostor.insert(dok)

  db.prostor.create_index([("loc", GEO2D)])
  for doc in db.prostor.find({"loc": {"$near": [3, 6]}}).limit(3):
      print(doc)
  for doc in db.prostor.find({"loc": {"$within": {"$box": [[0,0],[3,4]]}}}):
      print(doc)
  ```

Primer (jadralci)

```
# Jadralci
db.jadralec.insert_one( {"jid": 22, "ime" : "Darko", "rating": 10, "starost":45} )
# Čolni
db.coln.insert(…)   # ← ???
# Rezervacije
db.rezervacija.insert_one( {"jid": 22, "cid" : 101, "dan": "2006-10-10" } )
db.rezervacija.insert_one( {"jid": 22, "cid" : 102, "dan": "2006-10-10" } )
db.rezervacija.insert_one( {"jid": 22, "cid" : 103, "dan": "2006-10-8" } )
db.rezervacija.insert_one( {"jid": 22, "cid" : 104, "dan": "2006-10-7" } )

# Indeksi
db.jadralec.create_index("jid")
db.coln.create_index("cid")
db.rezervacija.create_index( [("jid", pymongo.DESCENDING), ("cid", pymongo.ASCENDING), "dan"] )
```

```
# STIK: Poišči vse Darkove rezervacije
darko = db.jadralec.find_one({"ime" : "Darko"})
rez =  db.rezervacija.find( {"jid" : darko["jid"]} )
for r in rez:
    print(r)
```

Jadralci v duhu MongoDB

Jadralec -(1,1)----(0,n)- Rezervacija

```
db.jadralec.update_one( {"jid": 22}, {"$set"  : {"rezervacija" : []} })
db.jadralec.update_one( {"jid": 22}, {"$push" : {"rezervacija" : {"cid" : 101, "dan": "2006-10-10"} }} )
db.jadralec.update_one( {"jid": 22}, {"$push" : {"rezervacija" : {"cid" : 101, "dan": "2006-10-10"} }} )
db.jadralec.update_one( {"jid": 22}, {"$push" : {"rezervacija" : {"cid" : 103, "dan": "2006-10-8" } }} )
db.jadralec.update_one( {"jid": 22}, {"$push" : {"rezervacija" : {"cid" : 104, "dan": "2006-10-7" } }} )
db.jadralec.find_one({'jid':22})
```

```
{'_id': ObjectId('670bcd3e863257cfab8c6530'),
 'jid': 22,
 'ime': 'Darko',
 'rating': 10,
 'starost': 45,
 'rezervacija': [{'cid': 101, 'dan': '2006-10-10'}, {'cid': 101, 'dan': '2006-10-10'},
                 {'cid': 103, 'dan': '2006-10-8'},  {'cid': 104, 'dan': '2006-10-7'}]
}
```

MapReduce

- postopek omogoča preprosto paralelizacijo programov (poizvedb) v velikih podatkovnih bazah preko velikega števila računalnikov/jeder/procesorjev
- splošen koncept, popularizirala Google in Apache Hadoop
- podobna ideja kot pri funkcijskem programiranju (map-fold)
- enostavna in učinkovita paralelizacija asociativnih *idempotentnih* funkcij
- velik **pretok** podatkov vendar previsoka **latenca** za izvajanje v realnem času

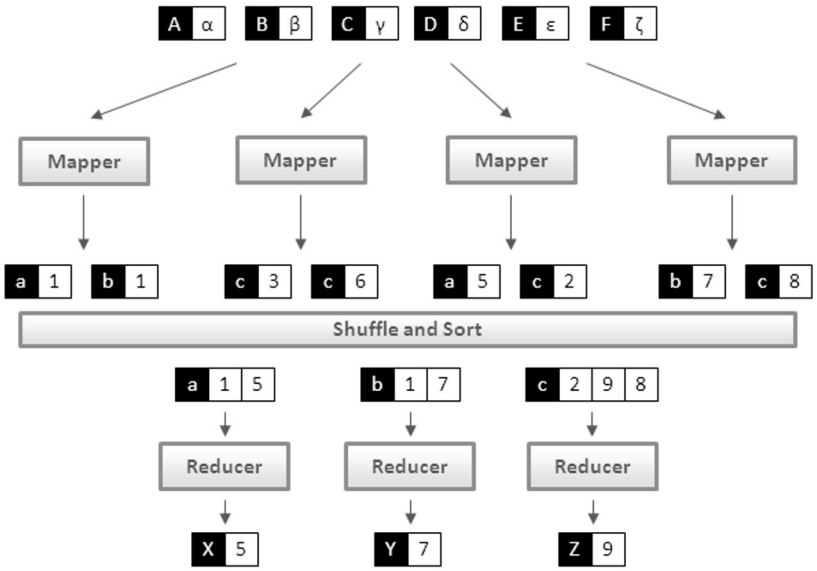

MongoDB MapReduce

- **map**: preslika vhodne dokumente v drugačno predstavitev (in/ali ključ) in jo/ju posreduje naprej s stavkom **emit**
- **reduce**: za vsak ključ prejme polje vrednosti od funkcije map in izračuna končni rezultat

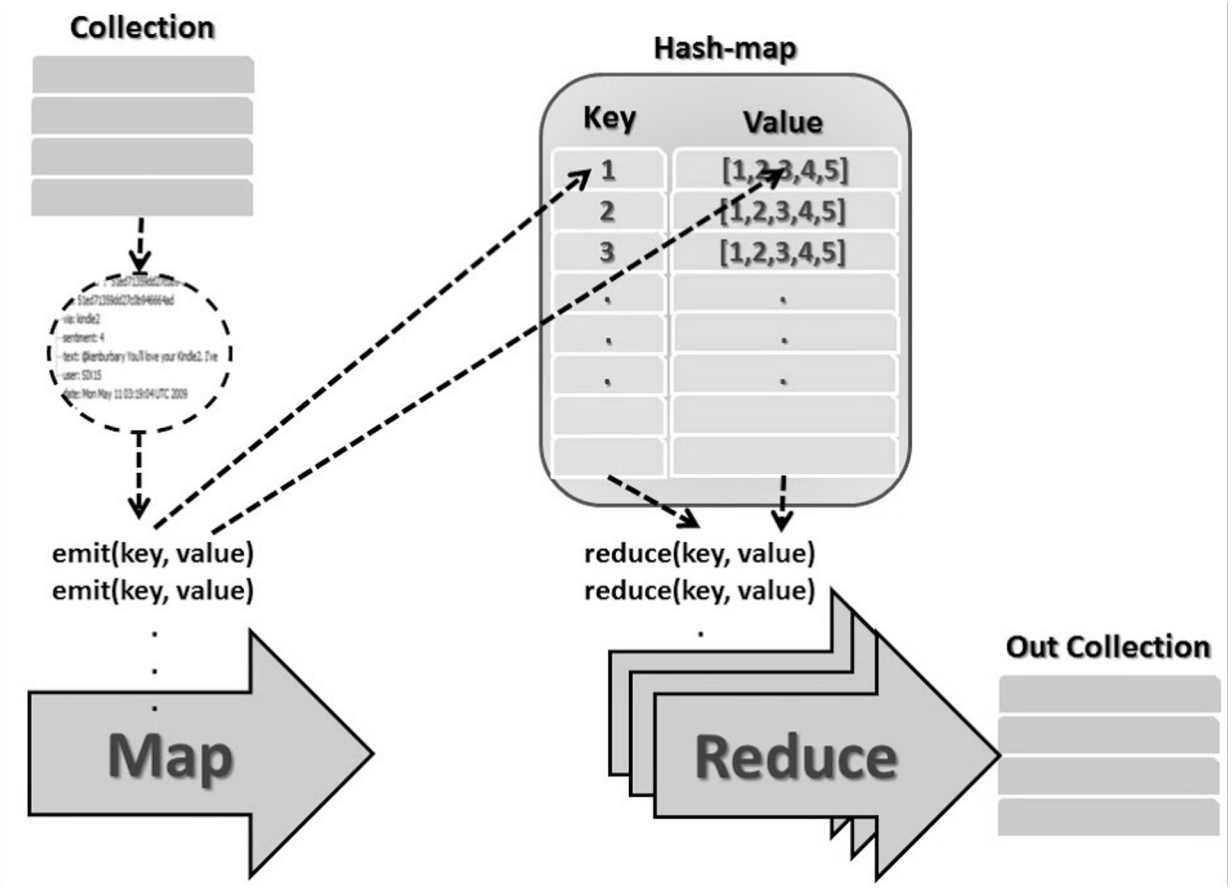

MapReduce

- Podana je študentska evidenca opravljenih izpitov:
- `> db.izpiti.find({},{_id:0})  # Projekcija, izpis brez _id`

```
{ "ime" : "Luka", "letnik" : 1, "izpitov" : 4 }
{ "ime" : "Vili", "letnik" : 1, "izpitov" : 6 }
{ "ime" : "Jaka", "letnik" : 1, "izpitov" : 2 }
{ "ime" : "Taja", "letnik" : 2, "izpitov" : 2 }
{ "ime" : "Dino", "letnik" : 2, "izpitov" : 4 }
{ "ime" : "Igor", "letnik" : 3, "izpitov" : 2 }
{ "ime" : "Nina", "letnik" : 3, "izpitov" : 3 }
{ "ime" : "Dani", "letnik" : 3, "izpitov" : 6 }
{ "ime" : "Pika", "letnik" : 3, "izpitov" : 5 }
{ "ime" : "Dasa", "letnik" : 3, "izpitov" : 5 }
```

- Zanima nas:
  1. Kakšno je skupno število izpitov, ki so jih opravili vsi študenti v letnikih?
  2. Kakšno je povprečno število izpitov, ki so jih opravili vsi študenti v letnikih?

MapReduce: primer 1

- Kakšno je skupno število izpitov, ki so jih opravili vsi študenti v letnikih?

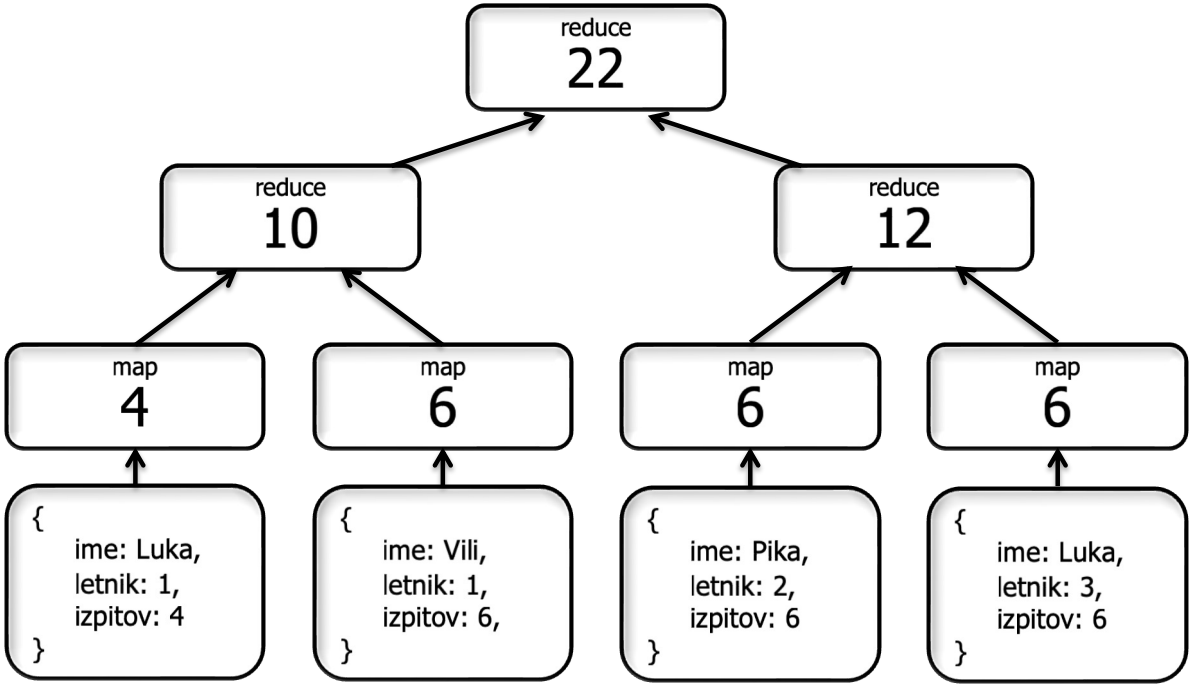

- reduce mora biti **asociativen**, vrstni red izvedbe je neopredeljen!!!
- reduce mora vrniti podatek istega tipa kot je tip rezultata funkcije emit

MapReduce: primer 1

```
var mapper = function() {
     emit(null, this.izpitov)
}

var reducer = function(key, values) {
     var sum = 0;
     values.forEach(function(x) {
          sum += x;
     })
     return sum;
}

> db.izpiti.mapReduce(mapper, reducer, {out: "rezultati"})
{
        "result" : "rezultati",
        "timeMillis" : 97,
        "counts" : {
                "input" : 10,
                "emit" : 10,
                "reduce" : 1,
                "output" : 1
        },
        "ok" : 1,
}

> db.rezultati.find()
{ "_id" : null, "value" : 39 }
> db.rezultati.findOne().value
39
```

naziv zbirke, v kateri se bo shranil rezultat

izpis rezultata

MapReduce: primer 2

- Kakšno je povprečno število izpitov, ki so jih opravili vsi študenti v letnikih?

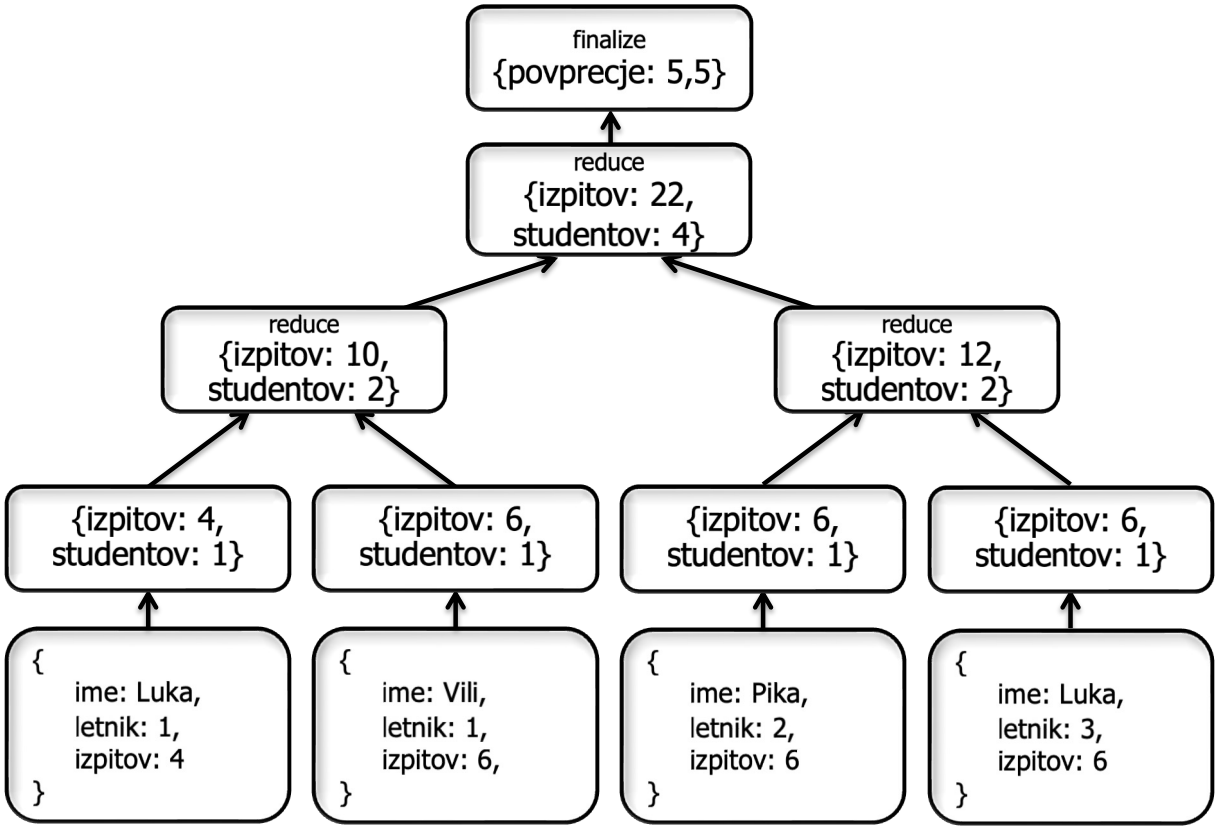

MapReduce: primer 2

Kakšno je povprečno število izpitov, ki so jih opravili vsi študenti v letnikih?

```
var mapper = function() {
     emit(null, {studentov: 1, izpitov: this.izpitov})
}

var reducer = function(key, values) {
     var sum = {studentov: 0, izpitov: 0}
     values.forEach(function(x) {
          sum.studentov += x.studentov;
          sum.izpitov += x.izpitov
     })
     return sum;
}

> db.izpiti.mapReduce(mapper, reducer, {out: "rezultati"})
> db.rezultati.find()
{ "_id" : null, "value" : { "studentov" : 10, "izpitov" : 39 } }

> var finalizer = function(key, value) {
     var povprecje = value.izpitov/value.studentov;
     delete value.izpitov;
     delete value.studentov;
     value.povprecje = povprecje;
     return value;
}

> db.izpiti.mapReduce(mapper, reducer,
       {out: "rezultati", finalize: finalizer})
> db.rezultati.find()
{ "_id" : null, "value" : { "povprecje" : 3.9 } }
```

funkcija za finalizacijo rezultata, ki se izvede

dodatni parameter za uporabo finalizatorja

MapReduce in agregacijske funkcije

- MapReduce je v novejših verzijah označen kot zastarel (deprecated)
- Velika večina MapReduce opravil v MongoDB je agregacijskih!
- Spomnimo se:

  SELECT MIN/MAX/SUM/AVG/…

  …

  GROUP BY …

  HAVING …
- Agregacijske funkcije in cevovodi nadomeščajo in poenostavljajo MapReduce, pa še hitreje delujejo

Agregacijske funkcije in cevovodi

- Preproste: count, distinct, …
- Agregacije so vsaj tako močne kot v SQL
- Agregacijo je smiselno organizirati v stopnje, ki jih potem poljubno sestavljamo v cevovode
-
- Agregacije so implementirane v C/C++ (mnogo hitrejše kot Java Script) in se avtomatsko horizontalno skalirajo

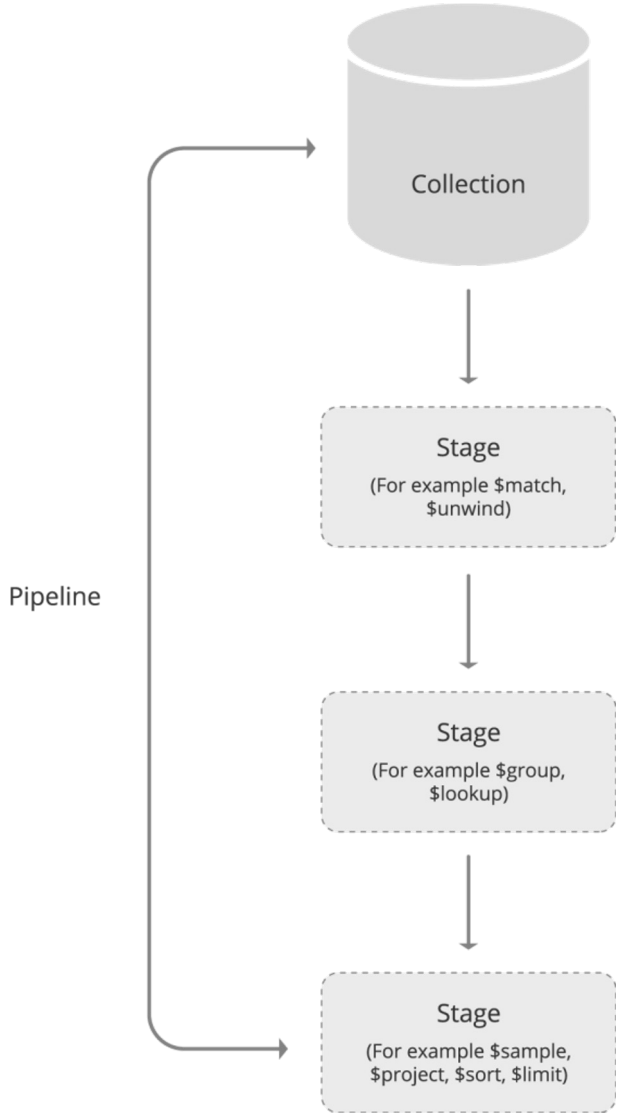

Agregacijske funkcije in cevovodi

- Primer: ločevanje operacij v $match in $group stopnjah

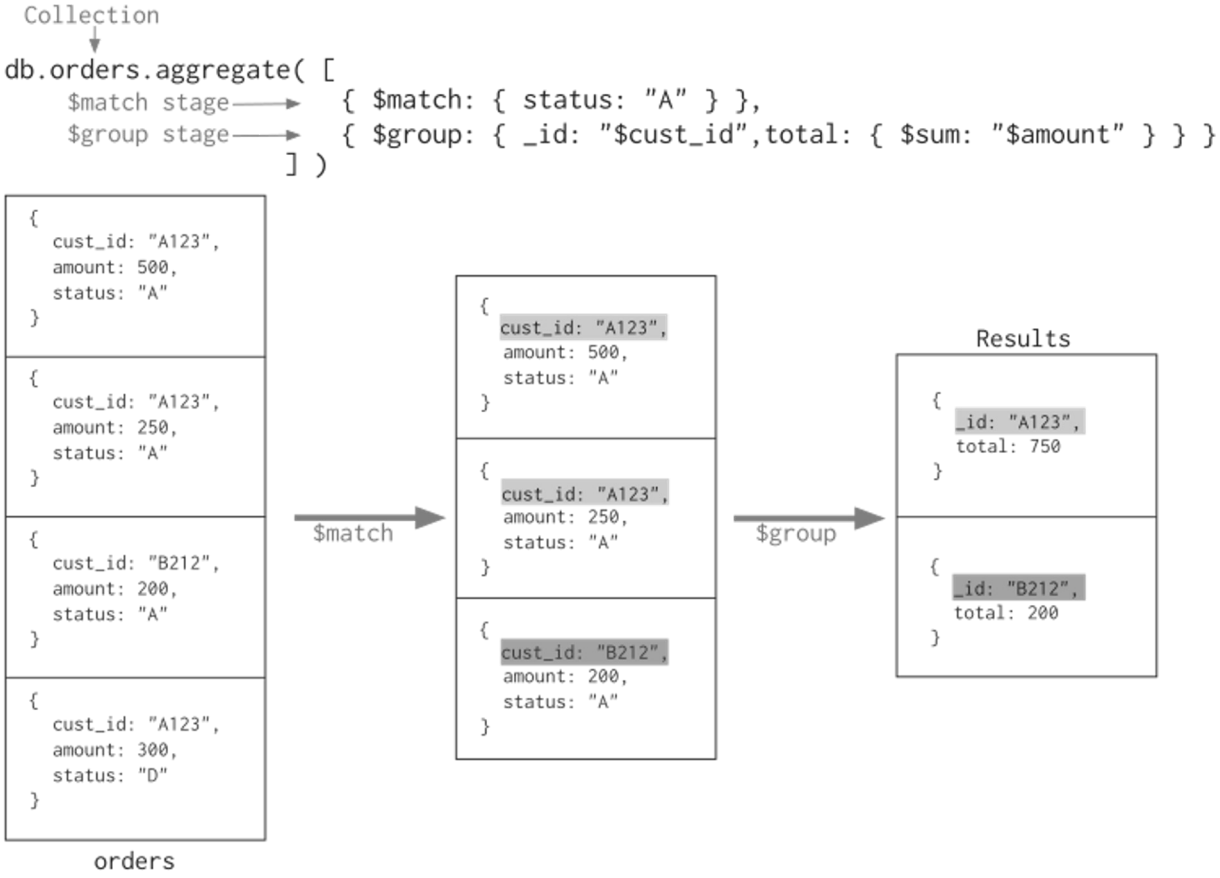

Vsota po strankah (vsaki posebej) s statusom "A"

MongoDB - zaključek

- Enostavno razumljiv podatkovni model
- Bogat nabor operacij
- Preprosto horizontalno skaliranje (ob vzpostavitvi sistema, uporabnik tega pretežno ne vidi)
- Preprosto porazdeljeno procesiranje (agregacije)
- Od verzije 4 dalje podpora ACID transakcijam (na zahtevo, znotraj namenskih sej - session), vendar z omejitvami:
  - Počasnejše procesiranje (zaklepanje virov)
  - Časovna omejitev (privzeto 60 s)
  - Omejitev obsega (maksimalno 16 MB sprememb v transakciji)