



SUNGARD

L'informatique qui
réinvente la finance

Mapping Objet Relationnel (ORM)

Partie 1 : Principes & Fonctionnement en lecture
SQL Généré
Optimisations


Arnaud NAUWYNCK
arnaud.nauwynck@gmail.com

- Introduction
 - Architecture, Outils ORM
 - API Language L4G <-> SGBDR
- Accès en Lecture
 - Fonctionnement
 - Relation 1-1, 1-N, Héritage
- Problèmes de performances
 - Optimisations Modèle, Index
 - Optimisations Mapping, Caches
 - Optimisations Oracle


Audience - Prérequis

- PAS un tutorial hibernate/JPA/EJB...
- Pré-requis: connaissances SGBD / persistence
- But: explications avancées
 - Problèmes de mapping Object vs Relationnel
 - SQL généré
 - Problèmes de Performances, Optimisations
 - Réduire distance Développeur / DBA


- Répartition des taches, outils ... OK
- Répartition des connaissances, compréhension ?



Architecture 3-Tiers



Couches: Applicatives, DAO, ORM, Jdbc



JDBC Sample Code

```
Connection conn = ...
```

```
PreparedStatement pstmt = null;
```

```
try {
```

```
    String sql = "select * from emp where id = ?";
```

```
    pstmt = conn.prepareStatement(sql) ;
```

```
    pstmt.setInt(1, id);
```

```
    ResultSet rs = pstmt.executeQuery();
```


```
    while(rs.hasNext()) { rs.next(); int val = rs.getInt(1); ... }
```

```
} finally { safeClose(pstmt); }
```

DAO BMP : CRUD

```
public class EmpDAO extends DAO {
```


- C Create** ... "insert into EMP (id, name) values(?,?)"
- R Read** ... "select * from EMP where id = ?"
... "select * from where ..."
- U Update** ... "update EMP set name=?, ...=? where id=?"
- D Delete** ... "delete EMP where id =?"



- Code simple ... mais Fastidieux
 - copier&coller *3 pour Select/Update/Create !
 - Code Query et Mapping imbriqués
- Performances
 - Avantages: 1 appel => SQL Explicit
 - Inconvénients: contrôle des appels
 - Framework nécessaire!
 - Cache pour 'Read'
 - XA pour 'Update'

- ... Solutions avec Introspection Java
- Historique:
 - Origine > 10 ans : Castor, JDO / EJB-CMP
 - Unification : JPA (EJB-3)
 - De-facto standards : Hibernate...
- Principe
 - Plus de SQL ... seulement code POJOs
 - Objets managés
 - Notion de Session (-> Connection + Cache + XA)

Vue d'ensemble API ORM, IN/OUT



Implémentation DAO avec JPA

```
public class EmpDAO extends DAO {
```

C

```
    Emp create(Emp p) {  
        return session.registerObject(p); }  
}
```

R

```
    Emp findById(EmpPK id) {  
        return (Emp) session.findById(...); }  
    List<Emp> findByXY(...) {  
        return (List<Emp>) session.executeQuery(...); }  
}
```



```
// update: simply call setter! ... emp.setA(..)
```

D

```
    void delete(Emp p{ session.unregisterObject(p); }  
}
```

- Expression
 - traduction en Orienté-Object (AST) de grammaire SQL “where clause”
- OQL / EJB-QL
 - ... similar to SQL with Objects
 - Exemple:
“select e from EMP e
where e.name = ? and e.dept.name = ?”
- Deprecated... “Query By Example”
- Direct SQL

API “where clause” : AST Expression

- API très low-level... exemple : Toplink

```
ReadAllQuery q = new ReadAllQuery(Emp.class);  
ExpressionBuilder b = q.getExpressionBuilder();  
Expression e = ...
```

```
Expression expr = b.get("f").get("g").equals(b.getParam("v1"));  
if (e != null) e = e.and(expr); else e = expr;  
b.addArgument("v1");  
Vector params = new Vector();  
params.add(new Integer(123));
```

- => encapsuler dans API applicative high-level
 - QueryHelper b = new QueryHelper(Emp.class);
b.andEq("f.g", 123);

Avantage ORM – Effets Cachés

- Manipulation Orientée Objet.... simple
 - Code = finder + getter/setter
 - Mapping externalisé (code != xml, annotation)
- ... MAIS
 - Code SQL = implicite, généré ... complexe
 - Effets non compris/prévus au dev
 - Getter => lazy loading, relation => jointure
 - Setter => pbs XA et caches hardus
- Rien de magique... comprendre => prévoir

Sémantique Relationnel vs Object

- Inexistant en SQL
 - Hiérarchie de classe (sub-class $\leftrightarrow$ class)
 - Ordered list, array...
- Purement SQL
 - Id technique, versioning, audits, trigger...
 - Query, Relation inverse
- Remarques : généricité ultime ...
 - Table Name-Value
 - Bien pour progiciels (plugins) ... calvaires DBA

- Relation code OO <--> SGBD Relationnel...
 “The Vietnam of Computer science”
- SQL non intégré dans code:
 - Non natif dans Java
 - Sémantique non orientée-objet
- Alternatives
 - Externalisation String ... OK si SQL static
 - extensions Java-SQL (précompilateur?...)
 - Oracle : PL-SQL = langage 3GL procédural + SQL
 - SGBD Orientés-Objets (ex: O2, Versant, Db4j)


- Introduction
 - Architecture, ORM
- Accès en Lecture
 - Fonctionnement
 - Relation 1-1
 - Relation 1-N
 - Relation Héritage
- Problèmes de Performances
 - Optimisations Modèle, Mapping, Oracle

Types de Champs Mappés

- Champs simples (ValueObject)
 - Type primitif : conversion SQL – Java
 - Type user-defined: ex Date, Struct, ...
- Relations
 - Relation 1->1 “**OneToOne**” = pointer
 - Relation 1->N “**OneToMany**” = Collection / Map
 - Relation N->M (“**ManyToMany**”)
=> décomposée en modèle normale : 1-N + N-1
 - Relation **Héritage**

Introspection, Reflection

- Reflection = descripteur (meta donnée)
- Introspection = invocation “de champ/method”
- Dualité:
 $\text{obj.setXX(val)} \Leftrightarrow \text{xxField.setValue(obj, value)}$
- Conséquences:
 - outils génériques, Serialisation, ...



Mapping Champs Simple

- read JDBC -> fill Obj Field

```
ResultSet rs =...  Object obj = ...
```

```
for(FieldMapping f : ...) {  
    switch(f.getMappingType()) {
```

```
    case SQL_INT:
```

```
        int val = rs.getInt(f.getSQLColIndex());
```

```
        f.setValue(obj, convert(val));
```


```
        break
```

```
    .... } /*switchType*/  ... } /*fieldMapping*/  ... } /*rs*/
```



Mapping Relation 1-1

- Relations loadées indirectement: **Proxy**
- load A
sql="select a.B_ID ... from A a where id=?"
- **lazy load A->B**
find B by id (in cache, then in db)
sql="select b.* ... from B b where id=?"



Proxy : Approche Explicite / AOP

- Approche **Intrusive** (code Explicite)


- Ex Toplink:

```
private ValueHolderInterface b = new ValueHolder();  
public B getB() { return (B) b.getValue(); }  
public void setB(B p) { b.setValue(p); }
```

- Approche Transparente : **AOP**


- Remplacement byte-code setter/getter

- Au Runtime (ClassLoader)
 - Ou Post-Compilation




IdentityMap : Cache by Id

- Principe:
 - 1 instance d'objet pour 1 type + 1 ID (+ 1 session)
“==” au lieu de “equals()”
- Conséquences:
 - FindById => always resolve in cache
 - Cache by Id = Solution optimale (Map)



Query No Cache + Resolve


- Pour TOUTES les Querys != findById
=> select in DB without cache
+ resolve result into cache !



- Hibernate : Cache de queries (pas Toplink)
 - Pbs: Invalidations sur updates / mémoire


Mapping Relation 1-N

- Load A :
sql = "select ... from A where id=?"
- Lazy load A->B :
find all B by parentA in db (no cache) !
sql = "select * from B where A_FK = ?"



Mapping Relation Héritage

- Discriminant
... = sous-type exact d'un objet
- Recherche A => retourne des A et des B!
un B “est un” A
- Pb ... plusieurs tables/jointures/queries!




Code SQL pour Héritage

- Step 1 : “select distinct(A.DISCR) from A where <expr>”
- Step 2.. N : query + jointures par type
 - “select * from A a, B b where a.ID=b.ID and <expr>”
 - “select * from A,B,C where ... <expr>”
 - etc
- Adieu Performances...
- Alternative possible
 - 1 select “ids, type”
 - + N findByIds : id in (?, ?, ? ...) cf next

- Introduction, ORM
- Accès en Lecture
 - Fonctionnement
 - Relation 1-1, 1-N, Héritage
- Problèmes de performances
 - Optimisations Indexes, Modèle de données,
 - Optimisations Mapping, Caches
 - Optimisations Oracle


Outils de Diagnostic Performance

- Nombreux Outils de Profiling... choisir cibles
- Meilleur rapport efficacité/coût: jdbc profiling



Rappel : B*-Tree Index

- Index = B*-Tree (B=Balanced) / hash / bitmap...
 - Recherche en $\log(N/K) \Rightarrow \sim 2-3$ logical Ios
 - Leaf doublement chaînées $\Rightarrow$ “index scan”



Index Eligible


- Query “where “F1=? And F2=? ... and Fn=?”
- Utilisation de k ($\leq N$) 1^{ères} colonnes de l'index
 - Index sur (F1,F2...Fn ...) => Eligible
 - Si Manque “Fi=?” => (reste de l') index inutilisable!!

Select * from A where ...

where F1=? ==> index1 only

where F1=? And F2=?
==> index1 or index2


where F4=? ==> no index



Couverture d'Index


- “select $F_{n+1}, \dots F_p$ where $F_1..F_n$ ”
 - Colonnes utilisées en “lecture” au lieu de “recherche”
 - Ordre indexé indifférent
 - Bonne idée: rajouter “ID” en dernier

Select F2 from A where F1=?
== > index 1 ... avec couverture d'index
(no table access A)




Pb de Performance avec Heritage

- $lsB = \text{findBy}(A_F1, B_F2)$
- sql: “select * from A a, B b
where a.ID = b.ID
and a.F1 = ? and b.F2 = ?”
- Pb: sous-indexation séparée de 2 tables = HashJoin




Dénormalisation Mapping

- 2 Class $\leftrightarrow$ 1 seule table + columns nullables



Pb Similaire avec Relation OneToMany


- `lsC = findBy(A_F1, C_F3)`
- Sql: “select * from A a, C c
where c.A_FK = a.ID
and a.F1 = ? and c.F3 = ?”
- Pb: sous-indexation séparée de 2 tables



Denormalisation: Copy Trigger


- Trigger to copy A.F1 -> C.COPYAF1, then index
 - on update A.F1 / on Insert C / on Update C.A_FK
- Pb: changer query,
utiliser C.COPYAF1 au lieu de =A.F1

solution avancée
Materialized Views
+ Query Rewrite



Problème Applicatif : “N+1” Queries

- lsA = findBy(...); // 1 Query
for (A a : aLs) {
 b = process(a); // N Queries! 1 per A
 ... c = process(b);
}



1 x “select * from A a where ...”



N x “select * from B where ...”



NxP x “select * from C where ...”

Problème des “N+1” Querys

- Extrêmement fréquent, voir Omni-présent !
- Complexité linéaire
... quadratique si 2 pbs “N+1” en cascade !
- 1 Traitement $\Rightarrow$ N querys $\Rightarrow$ Timeout
 - query = appel réseau + parse + execute + fetch
 - 15 ms min (~70 ms avg)
- Stats en Prod
 - ~10M de selects par jours = 100 querys / seconde

Solutions au Problème “N+1”

- Refactorer Modèle : Query->Relation
 - => Relations loadées (lazily) 1 seule fois
... puis rattachées au cache
- Mapper les relations OneToOne
 - Ne pas mapper des “int” mais des pointeurs!
- Caches + preload (hot data)
- Batch Reading / Join (?)
- Machine 4/8 CPUS... use it (don't save it!)

Solution au “N+1” : Cache By Id


- `lsA = findBy(...); // 1 Query`

```
// preload corresponding B at startup/on demand  
// “select * from B where ...”  
// => put in cache: cacheB.put(bId, b)
```

```
for (A : aLs) {  
    B b = a.getB();  
    // = lazy load B by id = hit cache, in memory...  
    // = cacheB.get(bId)  
}
```


Relation 1-1 de Référentiel

- Relations 1-1 très nombreuses
 - Partie “référentiel”
 - Schéma en “Etoile”, typique des Datawarehouses
- Exemple



Cache Applicatif – By Code $\neq$ By Id


- 2 exemples typiques:
 - Table “User” $\Rightarrow$ findByName
 - Table translation “CodeExtern”
 $\Rightarrow$ findExtBySysCode / findCodeBySysExt
- Solution Cache Applicatif: “Name->Id”



- FAUSSE Bonne Idée :
“Rajouter une jointure pour éviter une query ?”
- Problèmes: parfois pire que mieux
 - execution (repeat “where clause”)
 - volume de données (repeat “data”) / resolve cache!
- Où ?
 - Jamais pour données de référentiel
 - Exclusivement pour agrégations fortes
 - Ex: load Curve(s) => load Child Points


Explication Batch Reading

- “Proxy” remplacé par “QueryBatchProxy”
 - Remember parent query + group children
 - Lazy-load 1 child = load All Children
= exec { repeat parent query + join }



Fonctionnement QueryBatchProxy

- `lsA = findBy(...); // "select * from A where ..."`
`lsA[0].getB(); // use one b ... load all B`
`// "select B.* from A a, B b where ... and a.ID=b.A_FK"`
- Queries répétées N fois avec $1 + 2 + \dots + N$ jointures
- Cascader BatchReading + Héritage = désastre !!
- ex:



=> 3 requêtes SQL :

1: select * from A ...

2: select A,B ...

3: select A,B,C ...

- Introduction, ORM
- Accès en Lecture
 - Fonctionnement
 - Relation 1-1, 1-N, Héritage
- Problèmes de performances
 - Optimisations Indexes, Modèle de données
 - Optimisations Mapping, Caches
 - Optimisations Oracle

Find By Ids Multiple

“select * from A where ID in (... , ... , ...)”

- Besoin fréquent: pour “N+1”, héritage...
- Problèmes
 - pas de bind variables, hard parse
- Solution Oracle:

“select * from A where ID in (select id from table(cast ? As T))”

OracleArray = ...

pstmt.setObject(1, oracleArray);

Reports: *FIRST_ROWS* / *Rownum*

- Ecrans de recherche
 - Critères facultatifs... => rapide / full table scan
- Solution 1 : Query Timeout
- Solution 2 : “select /*+FIRST_ROWS*/ ...”
- Solution 3 : “where ... rownum < 500”
 - execute query != consume resultset.next()
... cf pb Toplink
 - Solution 3bis: Use rownum paging [first,last]
“select .. from (select rowum r, .. from ... where rownum < last)
where r > first”

Query Reports... Combining Solutions

- Trop de jointures ?
 - a) Select Object + Héritage ... jointures
 - b) Select “a.name” (référentiel?)... jointure
 - c) Critère “a.b.c.d = ?” ... jointures
- Pour a) : “select ID from....” + findByIds
- Pour b) : “select a.id” + cache applicatif
- Pour c) : split queries... c.d=? / a.b in (...)

BindVariable, Soft/Hard Parse

- Utiliser **PreparedStatement** + **Bind Variables**
- 1ère exécution = **Hard-Parse**
 - CPU pour Parser + optimizer Plan
 - Stocké dans V\$SQLAREA
- Re-exécution = **Soft-Parse**
 - Lookup (par text sql) + check + execute
- Sans BindVariable... performance impossible
 - Spin-locks (=CPU + lock), Cache miss / Mémoire

Hard Parse – Soft Parse : JDBC

- Mauvais Exemple:

```
for (int i = 0; i < 1000; i++) {  
    conn.executeQuery("select * from A where id=" + i);  
}
```

- Correct, 2x plus rapide:

```
String sql = "select * from A where id = ?";  
for (int i = 0; i < 1000; i++) {  
    stmt = conn.prepareStatement(sql);  
    stmt.setInt(1, i);  
    stmt.executeQuery();  
    stmt.close();  
}
```

- **Softer-Soft-Parse**

- Reuse PreparedStatement, no close
=> skip lookup, check
=> only execute + fetch

- => 2x2 fois plus rapide:

```
stmt = conn.prepareStatement("select * from A where id = ?");  
for (int i = 0; i < 1000; i++) {  
    pstmt.setInt(1, i);  
    pstmt.executeQuery();  
}  
pstmt.close(); // repool in LRU pstmt cache
```

Tuning Soft(er) Parse

- Si code sans PreparedStmt... Work Around System
 - “alter system set CURSOR_SHARING similar”
 - ... pb induit: pseudo variables pour constantes!
=> plan d'exécution moins précis
- Config Serveur Applicatif
 - Pool JDBC > LRU cache Statement Size = ...
- Dans PL-SQL => implicit !!! open+cache cursors...

- Mapping Objet-Relationnels
 - Outils matures, fiables et performants
 - Standards
- Sémantique Objet vs Base Relationnel
 - Diff (in)évitable ... pb performance
- Principes universels
 - à connaître et maîtriser
 - Pourtant... méconnaissance développeur / DBA

Conclusion... A Suivre

- 1ere partie = accès en lecture, SQL généré, perf
- ... cf 2eme partie = accès en écriture

Plan

- Aspects Transactionnels : JTA, XAResource
- Fonctionnement ORM - XA
- Lock Optimiste, Versionning
- Pattern Read-Mostly (cache niveau 1 / 2)
- Oracle : Undo/Redo, isolation no-read-lock

Questions

Questions ??

arnaud.nauwynck@gmail.com