Databázové systémy

Spojení v relačním modelu a fyzická reprezentace dat

Petr Krajča

Katedra informatiky
Univerzita Palackého v Olomouci

Opakování: Operace s n-ticemi

Sjednocení (zřetězení)
Mějme n-tice $r \in \prod_{y \in R} D_y$ a $s \in \prod_{y \in S} D_y$ takové, že $r(y) = s(y)$ pro každý atribut $y \in R \cap S$. Zobrazení $r \cup s$ (zkráceně) rs nazveme sjednocení (zřetězení) n-tic r a s.

Projekce (zúžení)
Mějme n-tici $r \in \prod_{y \in R} D_y$, pak pro $S \subseteq R$ definujeme $r(S) \in \prod_{y \in S} D_y$ tak, že $(r(S))(y) = r(y)$ pro každý $y \in S$. Zobrazení $r(S)$ se nazývá projekce r na S.

Poznámky:

- sjednocení je komutativní ($sr = rs$), asociativní ($r(st) = (rs)t$), idempotentní ($rr = r$), neutrální vzhledem k $\emptyset$ ($r\emptyset = r$)
- sjednocení n-tic $r \cup s$ je množinově teoretické sjednocení zobrazení, odtud:

$$(rs)(y) = \begin{cases} r(y), & \text{pokud } y \in R \\ s(y), & \text{jinak.} \end{cases}$$

Přirozené (spojení)

Mějme relace $\mathcal{D}_1$ nad schématem $R \cup S$ a $\mathcal{D}_2$ nad schématem $S \cup T$ tak, že $R \cap T = \emptyset$. Relace $\mathcal{D}_1 \bowtie \mathcal{D}_2$ nad $R \cup S \cup T$ definovaná

$$\mathcal{D}_1 \bowtie \mathcal{D}_2 = \{rst \in \prod_{y \in R \cup S \cup T} D_y | rs \in \mathcal{D}_1, st \in \mathcal{D}_2 \text{ a } s \in \prod_{y \in S} D_y\}$$

se nazývá **(přirozené) spojení relací** $\mathcal{D}_1$ a $\mathcal{D}_2$.

Poznámky:

- S je množina společných atributů $\mathcal{D}_1$ a $\mathcal{D}_2$
- $\mathcal{D}_1 \bowtie \mathcal{D}_2$ obsahuje všechny atributy z obou tabulek
- interpretace: spojení relací $\mathcal{D}_1 \bowtie \mathcal{D}_2$ je relace obsahující spojení všech spojitelných n-tic a je to nejmenší relace této vlastnosti.

Příklady spojení

FOO	BAR	BAZ
444	ghi	103
555	def	102
555	ghi	103
666	abc	101

$\bowtie$

BAR	BAZ	QUX
abc	111	zzz
def	102	www
def	102	yyy
ghX	103	xxx
ghi	103	ttt
ghi	103	uuu
ghi	103	vvv

$=$

FOO	BAR	BAZ	QUX
555	def	102	www
555	def	102	yyy
444	ghi	103	vvv
555	ghi	103	vvv
444	ghi	103	ttt
555	ghi	103	ttt
444	ghi	103	uuu
555	ghi	103	uuu

FOO	BAR	BAZ
555	def	102
555	ghi	103
666	abc	101

$\bowtie$

BAR	BAZ	QUX
AAA	101	AAA
def	102	BBB
ghi	333	CCC

$=$

FOO	BAR	BAZ	QUX
555	def	102	BBB

FOO	BAR	BAZ
333	jkl	103
444	ghi	102
555	def	101
666	abc	101

$\bowtie$

BAZ
101
103

$=$

FOO	BAR	BAZ
333	jkl	103
555	def	101
666	abc	101

(Přirozené) Spojení v SQL

```
SELECT * FROM tab1 NATURAL JOIN tab2;

SELECT tab1.*, tab2.t_attr1, tab2.t_attr_2, tab2.t_attrn
       FROM tab1, tab2
       WHERE tab1.s_attr1 = tab2.s_attr1 AND
             tab1.s_attr2 = tab2.s_attr2 AND
             tab1.s_attrn = tab2.s_attrm
```

- `s_attrX` – atributy společné `tab1` i `tab2`
- `t_attrX` – atributy pouze z `tab2` `tab2`

(Přirozené) Spojení: Příklad

```
SELECT tab1.*, tab2.qux FROM tab1 NATURAL JOIN tab2;
SELECT tab1.*, tab2.qux FROM tab1, tab2
   WHERE tab1.bar = tab2.bar AND
         tab1.baz = tab2.baz
```

tab1

foo	bar	baz
444	ghi	103
555	def	102
555	ghi	103
666	abc	101

tab2

bar	baz	qux
abc	111	zzz
def	102	www
def	102	yyy
ghX	103	xxx
ghi	103	ttt
ghi	103	uuu
ghi	103	vvv

foo	bar	baz	qux
555	def	102	www
555	def	102	yyy
444	ghi	103	vvv
555	ghi	103	vvv
444	ghi	103	ttt
555	ghi	103	ttt
444	ghi	103	uuu
555	ghi	103	uuu

Spojení: vlastnosti

Pro libovolné relace $\mathcal{D}, \mathcal{D}_1, \mathcal{D}_2, \mathcal{D}_3$ platí:

- $\mathcal{D} \bowtie \mathcal{D} = \mathcal{D}$
- $\mathcal{D}_1 \bowtie \mathcal{D}_2 = \mathcal{D}_2 \bowtie \mathcal{D}_1$
- $\mathcal{D}_1 \bowtie (\mathcal{D}_2 \bowtie \mathcal{D}_3) = (\mathcal{D}_1 \bowtie \mathcal{D}_2) \bowtie \mathcal{D}_3$
- $\mathcal{D} \bowtie \mathcal{D}_\top = \mathcal{D}$, kde $\mathcal{D}_\top$ je relace nad schématem $\emptyset$ obsahující právě jednu n-tici
- $\mathcal{D} \bowtie \emptyset_S = \emptyset_{R \cup S}$ pro $\mathcal{D}$ na R a pro libovolné S.

Nechť $\mathcal{D}_1, \mathcal{D}_2$ jsou relace nad stejným schématem, pak platí

- $\mathcal{D}_1 \bowtie \mathcal{D}_2 = \mathcal{D}_1 \cap \mathcal{D}_2$.

Pokud je $\mathcal{D}$ relace na schématu $R, y \in R$ a $d \in D_y$, pak platí

- $\sigma_{y=d}(\mathcal{D}) = \mathcal{D} \bowtie \{\{\langle y, d \rangle\}\}$.

Kartézský součin

Mějme relace $\mathcal{D}_1$ a $\mathcal{D}_2$ na schématech R a T takových, že $R \cap T = \emptyset$. Pak $\mathcal{D}_1 \bowtie \mathcal{D}_2$ se nazývá **kartézský součin** relací $\mathcal{D}_1$ a $\mathcal{D}_2$.

Poznámky:

- speciální případ přirozeného spojení pro $S = \emptyset$
- každá n-tice je spojitelná
- $|\mathcal{D}_1 \bowtie \mathcal{D}_2| = |\mathcal{D}_1| \cdot |\mathcal{D}_2|$ (obecně platí pouze $\leq$)

Pozor!!!

1. **(naivní) kartézský součin** množin (v daném pořadí), tj. $A \times B$
2. **obecný kartézský součin** (indexovaného systému množin), tj. $\prod_{i \in I} A_i$
3. **kartézský součin relací nad relačními schématy**, tj. $\mathcal{D}_1 \bowtie \mathcal{D}_2$

SQL

```
SELECT tabulka1.*, tabulka2.* FROM tabulka1, tabulka2;
SELECT tabulka1.*, tabulka2.* FROM tabulka1 CROSS JOIN tabulka2;
```

θ-spojení

Motivace: chceme spojovat data ze dvou tabulek tak, aby kritérium spojitelnosti nebylo dáno pouze rovností, ale obecnou podmínkou vztahující se na hodnoty n-tic z obou tabulek

Mějme relace $\mathcal{D}_1$ a $\mathcal{D}_2$ na schématech R a T takových, že $R \cap T = \emptyset$ a nechť θ je skalární výraz typu ,,pravdivostní hodnota", který může obsahovat jména atributů z $R \cup T$, pak relaci

$$\mathcal{D}_1 \bowtie_\theta \mathcal{D}_2 = \sigma_\theta(\mathcal{D}_1 \bowtie \mathcal{D}_2)$$

nazýváme θ-**spojení** $\mathcal{D}_1$ **a** $\mathcal{D}_2$ **splňující** θ

Poznámka:

- z definice σ_θ a $\mathcal{D}_1 \bowtie \mathcal{D}_2$ plyne:
  $\mathcal{D}_1 \bowtie_\theta \mathcal{D}_2 = \{rt | r \in \mathcal{D}_1 \text{ a } t \in \mathcal{D}_2$ tak, že rt splňuje $\theta\}$

SQL

```
SELECT t1.*, t2.* FROM tabulka t1, tabulka t2
   WHERE t1.attr > t2.attr;
```

Spojení na rovnost

Mějme relace $\mathcal{D}_1$ a $\mathcal{D}_2$ na schématech R a T takových, že $R \cap T = \emptyset$ a nechť $\{y_1, \ldots, y_n\} \subseteq R$ a $\{y'_1, \ldots, y'_n\} \subseteq T$ tak, že atributy y_i a y'_i mají stejný typ. Pak θ-spojení $\mathcal{D}_1$ a $\mathcal{D}_2$, kde θ je ve tvaru $y_1 = y'_1 \wedge \cdots \wedge y_n = y'_n$ nazýváme **spojení na rovnost** relací $\mathcal{D}_1$ a $\mathcal{D}_2$ a označujeme jej $\mathcal{D}_1 \bowtie_{y_1=y'_1,\ldots,y_n=y'_n} \mathcal{D}_2$.

SQL

```
SELECT t1.*, t2.* FROM tabulka1 t2 , tabulka2 t2
   WHERE (t1.attr1 = t2.attr1) AND (t1.attr2 = t2.attr2);
```

Polospojení

Mějme relace $\mathcal{D}_1$ a $\mathcal{D}_2$ na schématech R_1 a R_2. Pak

$$\mathcal{D}_1 \ltimes \mathcal{D}_2 = \pi_{R_1}(\mathcal{D}_1 \bowtie \mathcal{D}_2).$$

se nazývá **polospojení** relací $\mathcal{D}_1$ a $\mathcal{D}_2$

Poznámka:

- $r \in \mathcal{D}_1 \ltimes \mathcal{D}_2$ právě tehdy, když $r_1 \in \mathcal{D}_1$ a r_1 je spojitelná s nějakou $r_2 \in \mathcal{D}_2$.

SQL

```
SELECT DISTINCT tabulka1.* FROM tabulka1 NATURAL JOIN tabulka2;
```

Příklad polospojení

FOO	BAR	BAZ
444	ghi	103
555	def	102
555	ghi	103
666	abc	101

$\ltimes$

BAR	BAZ	QUX
abc	111	zzz
def	102	www
def	102	yyy
ghX	103	xxx
ghi	103	ttt
ghi	103	uuu
ghi	103	vvv

$=$

FOO	BAR	BAZ
444	ghi	103
555	def	102
555	ghi	103

BAR	BAZ	QUX
abc	111	zzz
def	102	www
def	102	yyy
ghX	103	xxx
ghi	103	ttt
ghi	103	uuu
ghi	103	vvv

$\ltimes$

FOO	BAR	BAZ
444	ghi	103
555	def	102
555	ghi	103
666	abc	101

$=$

BAR	BAZ	QUX
def	102	www
def	102	yyy
ghi	103	ttt
ghi	103	uuu
ghi	103	vvv

Relační dělení: Motivace

dotazy ve tvaru „některá A jsou B"

- *Studenti, kteří mají zapsaný nějaký předmět.*
- *Součástky, které patří do některého výrobku.*
- *Dodavatelé, kteří dodávají některé výrobky.*
- ...

dotazy ve tvaru „všechna A jsou B"

- *Studenti, kteří mají splněny všechny vyžadované předměty.*
- *Výrobky, jejichž všechny součástky jsou skladem.*
- *Dodavatelé, kteří dodávají všechny výrobky.*
- ...

Vyjadřování dotazů **existenčního** a **všeobecného charakteru**:

- existenční – polospojení (projekce a přirozené spojení)
- všeobecný – dělení (množinový rozdíl, přirozené spojení, projekce)

Relační dělení

Uvažujme následující relace: $\mathcal{D}_1$ (dělenec) na schématu R, $\mathcal{D}_2$ (dělitel) na schématu S a $\mathcal{D}_3$ (prostředník) na schématu T. Pak relace

$$\mathcal{D}_1 \div_{\mathcal{D}_3} \mathcal{D}_2 = \{r(R \cap T) | r \in \mathcal{D}_1 \text{ tak, že pro každou } s \in \mathcal{D}_2 \text{ splňující podmínku } r(R \cap S \cap T) = s(R \cap S \cap T) \text{ platí, že } r(R \cap T)s(S \cap T) \in \pi_{(R \cup S) \cap T}(\mathcal{D}_3)\}$$

se nazývá **podíl** $\mathcal{D}_1$ a $\mathcal{D}_2$ přes $\mathcal{D}_3$ na schématu $R \cap T$.

Interpretace pro $\mathcal{D}_1$ (výrobci), $\mathcal{D}_2$ (výrobek), $\mathcal{D}_3$ a (kdo vyrábí co):

- $\mathcal{D}_1 \div_{\mathcal{D}_3} \mathcal{D}_2$ – výrobci vyrábějící všechny výrobky
- ...ještě jinak: r z dělence (výrobce) je ve výsledném podílu právě tehdy, pokud pro každou s (výrobek) z dělitele platí, že rs je v prostředníkovi (výrobce-výrobek), tj. výrobce vyrábí každý výrobek.
- $\mathcal{D}_2 \div_{\mathcal{D}_3} \mathcal{D}_1$ – výrobky vyráběné všemi výrobci

Příklad dat pro relační dělení

NAME
Abbe
Blangis
Curval
Durcet

COURSE
KMI/DATA1
KMI/DATA2
KMI/PAPR1

NAME	COURSE
Abbe	KMI/DATA1
Abbe	KMI/DATA2
Blangis	KMI/DATA1
Blangis	KMI/DATA2
Blangis	KMI/PAPR1
Curval	KMI/DATA1
Curval	KMI/DATA2
Curval	KMI/PAPR1

NAME	MAJOR
Abbe	CS
Blangis	CS
Curval	EE
Durcet	SS

COURSE	VERSION
KMI/DATA1	2
KMI/DATA2	1
KMI/PAPR1	2

NAME	COURSE	YEAR
Abbe	KMI/DATA1	2011
Abbe	KMI/DATA2	2012
Blangis	KMI/DATA1	2012
Blangis	KMI/DATA2	2012
Blangis	KMI/PAPR1	2007
Curval	KMI/DATA1	2011
Curval	KMI/DATA2	2013
Curval	KMI/PAPR1	2008

Speciální případy rel. dělení

Pokud platí $R \cap S = \emptyset$:

$\mathcal{D}_1 \div_{\mathcal{D}_3} \mathcal{D}_2 = \{r(R \cap T) | r \in \mathcal{D}_1$ tak, že pro každou $s \in \mathcal{D}_2$ platí, že $r(R \cap T)s(S \cap T) \in \pi_{(R \cup S) \cap T}(\mathcal{D}_3)\}$

Pokud platí $R \cap S = \emptyset$ a $T = R \cup S$:

$\mathcal{D}_1 \div_{\mathcal{D}_3} \mathcal{D}_2 = \{r \in \mathcal{D}_1 |$ pro každou $s \in \mathcal{D}_2$ platí, že $rs \in \mathcal{D}_3\}$

Vyjádření $\div$ pomocí $\setminus, \pi$ a $\bowtie$

Pro $\mathcal{D}_1$ na R, $\mathcal{D}_2$ na S, $\mathcal{D}_3$ na T platí:

$$\mathcal{D}_1 \div_{\mathcal{D}_3} \mathcal{D}_2 = \pi_{R \cap T}(\mathcal{D}_1) \setminus \pi_{R \cap T}\left((\pi_{R \cap T}(\mathcal{D}_1) \bowtie \pi_{S \cap T}(\mathcal{D}_2)) \setminus \pi_{(R \cup S) \cap T}(\mathcal{D}_3) \right).$$

Neformální skica důkazu

a $\mathcal{D}_a = \pi_{R \cap T}(\mathcal{D}_1) \bowtie \pi_{S \cap T}(\mathcal{D}_2)$ – všechny kombinace hodnot, které můžeme uvažovat v $\mathcal{D}_3$

b $\mathcal{D}_b = (\mathcal{D}_a \setminus \pi_{(R \cup S) \cap T}(\mathcal{D}_3))$ – všechny n-tice, které mohly být v $\mathcal{D}_3$, ale nejsou.

c $\mathcal{D}_c = \pi_{R \cap T}(\mathcal{D}_b)$ – všechny n-tice z $\mathcal{D}_1$, které nemají v $\mathcal{D}_3$ **nějakou** spojitelnou n-tici.

d $\mathcal{D}_d = \pi_{R \cap T}(\mathcal{D}_1) \setminus \mathcal{D}_c$ – ponechá n-tice $\mathcal{D}_1$, kterým nechybí spojitelná n-tice v $\mathcal{D}_3$.

NULL

- do relačního modelu byl přidán příznak ω značící absenci hodnoty; v SQL `NULL`
- řeší některé problémy (např. nespojitelné n-tice)
- přináší řadu nových problémů
- formální model s ω má nedostatky, potenciál pro vznik chyb

Přístup k nedefinovaným hodnotým v SQL

- aritmetická operace a `NULL` dává `NULL (1 + NULL) --> NULL`
- logický operátor a `NULL` dává `NULL (1 = NULL) --> NULL`
- pozor, i `(NULL = NULL) --> NULL` (potřeba použít operátor `foo IS NULL`)
- Kleeneho tříhodnotová logika

$\wedge$	0	ω	1
0	0	0	0
ω	0	ω	ω
1	0	ω	1

$\vee$	0	ω	1
0	0	ω	1
ω	ω	ω	1
1	1	1	1

$\rightarrow$	0	ω	1
0	1	1	1
ω	ω	ω	1
1	0	ω	1

$\neg$	
0	1
ω	ω
1	0

Příklady problémů s NULL (1/2)

```
CREATE TABLE r1 (x NUMERIC NOT NULL PRIMARY KEY, yn VARCHAR);
CREATE TABLE r2 (y NUMERIC NOT NULL PRIMARY KEY, zn VARCHAR);
INSERT INTO r1 VALUES (45, 'London');
INSERT INTO r2 VALUES (33, NULL);
SELECT x, y FROM r1, r2 WHERE (yn <> zn OR zn <> 'Paris');
```

Očekávaný výsledek:

```
 x  | y
----+----
 45 | 33
```

Protože buď `zn = 'Paris'` a tedy `yn <> zn`, nebo `zn <> 'Paris'`
Skutečný výsledek:

```
 x  | y
----+----
```

Protože $\omega \vee \omega = \omega$

Příklady problémů s NULL (2/2)

Neplatí některá tvrzení

Např. $\mathcal{D} \bowtie \mathcal{D} = \mathcal{D}$ nebo $\mathcal{D}_1 \bowtie \mathcal{D}_2 = \mathcal{D}_1 \cap \mathcal{D}_2$, kde $\mathcal{D}, \mathcal{D}_1, \mathcal{D}_2$ jsou relace nad relačním schématem R.

```
CREATE TABLE foo (a INTEGER PRIMARY KEY, b INTEGER);
INSERT INTO foo (a, b) VALUES (1, 10), (2, 20), (3, NULL);
```

```
SELECT * FROM foo f1
         NATURAL JOIN foo f2;
```

```
 a | b
---+----
 1 | 10
 2 | 20
```

```
SELECT * FROM foo
INTERSECT SELECT * FROM foo;
```

```
 a | b
---+----
 1 | 10
 2 | 20
 3 |
```

Nekonzistentní chování

```
SELECT 10 + 20 + NULL;  // --> NULL
SELECT SUM(b) FROM foo; // --> 30
```

Vnější spojení

- pokud se v relacích, které spojujeme, nacházejí nějaké nespojitelné n-tice, ve výsledku dochází ke ,,ztrátě informace"
- zavedení vnějších spojeních a konceptu chybějících hodnot (koncepčně špatně)
- doposud diskutována **vnitřní spojení**

vnější přirozená a θ-spojení v SQL

```
SELECT * FROM tab1 NATURAL FULL OUTER JOIN tab2;
SELECT * FROM tab1 NATURAL LEFT OUTER JOIN tab2;
SELECT * FROM tab1 NATURAL RIGHT OUTER JOIN tab2;

SELECT * FROM tab1 FULL OUTER JOIN tab2 ON podminka;
SELECT * FROM tab1 LEFT OUTER JOIN tab2 ON podminka;
SELECT * FROM tab1 RIGHT OUTER JOIN tab2 ON podminka;
```

- ve výsledku levého (pravého/oboustranného) vnějšího spojení jsou zahrnuty i n-tice z první (druhé/obou) relace, které jsou nespojitelné
- v tabulkách se projevuje přítomností NULL (značí „absenci hodnot)

Vnější spojení: Příklad (1/3)

```
SELECT * FROM tab1 NATURAL LEFT OUTER JOIN tab2;
```

tab1

foo	bar	baz
444	ghi	103
555	def	102
555	ghi	103
666	abc	101

tab2

bar	baz	qux
abc	111	zzz
def	102	www
def	102	yyy
ghX	103	xxx
ghi	103	ttt
ghi	103	uuu
ghi	103	vvv

bar	baz	foo	qux
abc	101	666	
def	102	555	www
def	102	555	yyy
ghi	103	444	vvv
ghi	103	444	ttt
ghi	103	444	uuu
ghi	103	555	vvv
ghi	103	555	ttt
ghi	103	555	uuu

Vnější spojení: Příklad (2/3)

```
SELECT * FROM tab1 NATURAL RIGHT OUTER JOIN tab2;
```

tab1

foo	bar	baz
444	ghi	103
555	def	102
555	ghi	103
666	abc	101

tab2

bar	baz	qux
abc	111	zzz
def	102	www
def	102	yyy
ghX	103	xxx
ghi	103	ttt
ghi	103	uuu
ghi	103	vvv

foo	bar	baz	qux
	abc	111	zzz
555	def	102	www
555	def	102	yyy
444	ghi	103	vvv
555	ghi	103	vvv
444	ghi	103	ttt
555	ghi	103	ttt
444	ghi	103	uuu
555	ghi	103	uuu
	ghX	103	xxx

Vnější spojení: Příklad (3/3)

```
SELECT * FROM tab1 NATURAL FULL OUTER JOIN tab2;
```

tab1

foo	bar	baz
444	ghi	103
555	def	102
555	ghi	103
666	abc	101

tab2

bar	baz	qux
abc	111	zzz
def	102	www
def	102	yyy
ghX	103	xxx
ghi	103	ttt
ghi	103	uuu
ghi	103	vvv

foo	bar	baz	qux
666	abc	101	
	abc	111	zzz
	ghX	103	xxx
555	def	102	www
555	def	102	yyy
444	ghi	103	vvv
444	ghi	103	ttt
444	ghi	103	uuu
555	ghi	103	vvv
555	ghi	103	ttt
555	ghi	103	uuu

Polorozdíl

Mějme relace $\mathcal{D}_1$ a $\mathcal{D}_2$ na schématech R_1 a R_2 takových, že $R_1 \cap R_2 = \emptyset$. Pak

$$\mathcal{D}_1 \triangleright \mathcal{D}_2 = \mathcal{D}_1 \setminus \pi_{R_1}(\mathcal{D}_1 \bowtie \mathcal{D}_2).$$

se nazývá **polorozdíl** relací $\mathcal{D}_1$ a $\mathcal{D}_2$

Poznámka:

- $r_1 \in \mathcal{D}_1 \triangleright \mathcal{D}_2$ právě tehdy, když $r_1 \in \mathcal{D}_1$ a r_1 není spojitelná s nějakou $r_2 \in \mathcal{D}_2$.

SQL

```
SELECT * FROM tabulka1
   EXCEPT
SELECT tabulka1.* FROM tabulka1 NATURAL JOIN tabulka2
```

Polorozdíl: Příklad

tab1

foo	bar	baz
444	ghi	103
555	def	102
555	ghi	103
666	abc	101

tab2

bar	baz	qux
abc	111	zzz
def	102	www
def	102	yyy
ghX	103	xxx
ghi	103	ttt
ghi	103	uuu
ghi	103	vvv

$\mathcal{D}_1 \triangleright \mathcal{D}_2$

foo	bar	baz
666	abc	101

$\mathcal{D}_2 \triangleright \mathcal{D}_1$

bar	baz	qux
ghX	103	xxx
abc	111	zzz

Pohledy

- Snaha vytvořit nové (virtuální) relační proměnné představující abstrakci nad existujícími (základními) proměnnými a jejich typy. Hodnoty (virtuálních) proměnných jsou dány vyhodnocováním dotazů.
- Virtuální relační proměnná (pohled) daného typu je proměnná, která v čase t nabývá hodnoty vzniklé vyhodnocením daného relačního výrazu v čase t.

SQL

```
CREATE VIEW nazev AS dotaz;

CREATE VIEW it_oddeleni AS
   SELECT * FROM zamestnanci WHERE pozicie = 'IT';

SELECT * FROM it_oddeleni;
```

Transakce

- operace s databází jsou prováděny v **transakcích**
- transakce zajišťují
  - přechod z jednoho konzistentního stavu databáze do druhého (ochrana před poškozením)
  - izolaci souběžně prováděných změn
- požadavky na transakci (ACID)
  - atomic – transakce musí být provedena atomicky, buď celá, nebo vůbec
  - consistent – databáze přechází z jedhono konzistentního stavu do druhého
  - isolated – izolace transakcí, dokud není změna potvrzena, jiná transakce ji nevidí
  - durable – potvrzené změny jsou trvalé

Základní operace s transakcemi

- `BEGIN TRANSACTION` – zahájení transakce
- `COMMIT` – potvrzení transakce
- `ROLLBACK` – vrácení změn nepotvrzené transakce

Zpracování dotazu

1. dotaz je přeložen z textové reprezentace do interní formy
   - blízká relační algebře
   - stromová struktura
   - listy – rel. proměnné (tabulky)
   - uzly – operace rel. algebry
2. následně jsou provedeny optimalizace a dotaz je transformován do proveditelné podoby
   - využívá se
     - vlastností rel. algebry
     - statistik o datech (velikosti tabulek, četnost hodnot, nejčastější hodnoty)
     - heuristik (známá pravidla, odhad času pro čtení z disku)
   - ,,abstraktní operace" rel. algebry jsou nahrazeny fyzickými operátory určenými pro přímou práci s dat
3. dotaz je vyhodnocen

Prováděcí plán

- množství fyzických operátorů a způsob provádění se mězi SŘBD významně liší
- většina SŘBD dovoluje zobrazit informace o tom, jak bude dotaz vyhodnocen

```
EXPLAIN SELECT * FROM foo INTERSECT SELECT * FROM foo;
                                  QUERY PLAN
-------------------------------------------------------------------------------
 HashSetOp Intersect  (cost=0.00..127.00 rows=2140 width=8)
   ->  Append  (cost=0.00..105.60 rows=4280 width=8)
         ->  Subquery Scan on "*SELECT* 1"  (cost=0.00..52.80 rows=2140 width=8)
               ->  Seq Scan on foo  (cost=0.00..31.40 rows=2140 width=8)
         ->  Subquery Scan on "*SELECT* 2"  (cost=0.00..52.80 rows=2140 width=8)
               ->  Seq Scan on foo  (cost=0.00..31.40 rows=2140 width=8)
```

Jak efektivně provést operace rel. algebry

Naivní řešení

- σ – iterace přes všechny řádky tabulky
- $\cap, \cup, \setminus, \pi, \bowtie$ – iterace ve vnořené smyčce

Optimalizované řešení

- zjednodušování dotazů na základě vlastností operací
- využití dodatečných struktur (indexů) umožňujících rychlé vyhledávání n-tic, příp. procházení setříděnou posloupností n-tic

Poznámka:

- udržování indexů má svou režii (zpomalení operací `INSERT`, `UPDATE` a `DELETE`)

Implementace indexů

dva základní typy struktur

1. indexy reprezentující **uspořádané množiny**
   - typicky perzistentní B-strom (B+strom, apod.)
   - optimalizace pro diskové (databázové) operace
   - rychlé nalezení hodnot pro podmínky s $<, \leq, =, \geq, >$
2. indexy reprezentující **asociační pole**
   - perzistentní hashovací tabulky
   - rychlé nalezení hodnot pro podmínky s $=$

Typy indexů

- **jednosloupcové** / **vícesloupcové**
- **husté** / **řídké** (indexovány jsou pouze první hodnoty bloků)
- index může být **unikátní**
- **úplné** / **částečné** (indexují jen část tabulky)

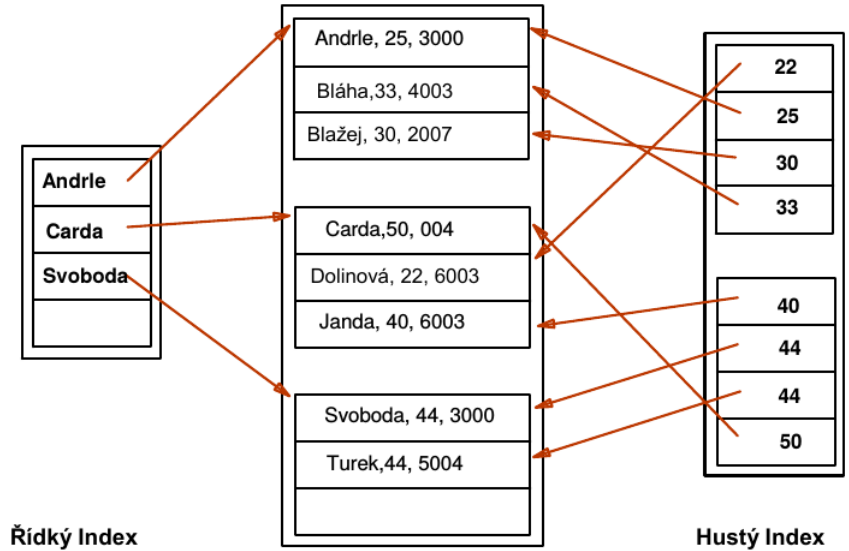
Andrle
Carda
Svoboda
Andrle, 25, 3000
Bláha,33, 4003
Blažej, 30, 2007
Carda,50, 004
Dolinová, 22, 6003
Janda, 40, 6003
Svoboda, 44, 3000
Turek,44, 5004
22
25
30
33
40
44
44
50
Řídký Index
Podle jména
Datový soubor
Hustý Index
Podle věku

Vytvoření indexu (1/2)

```
CREATE TABLE foo (
x INTEGER PRIMARY KEY,
y INTEGER NOT NULL,
z INTEGER NOT NULL);

CREATE INDEX foo_yz_idx ON foo (y, z);
CREATE UNIQUE INDEX foo_yz_idx ON foo (y, z);

-- vyuzitelne v dotazech typu
SELECT * FROM foo WHERE y = 10;
SELECT * FROM foo WHERE y > 10;
SELECT * FROM foo ORDER BY y;

-- ale uz ne pro
SELECT * FROM foo WHERE z = 20;
```

Vytvoření indexu (2/2)

```
-- pouziti hashe
CREATE INDEX foo_y_idx ON foo USING hash (y);

-- castecny index
CREATE INDEX foo_z_idx ON foo (z) WHERE z > 1000;

-- index na vyraz
CREATE INDEX foo_abs_idx ON foo (abs (y + z));

SELECT * FROM foo WHERE abs (y + z) > 200;
```

Vybrané algoritmy pro zpracování dotazů (1/2)

Nested-loop join

```
forEach r in Table1
   forEach s in Table2
     if (isJoinable(r, s))
        emit(join(rs))
```

- nepříliš efektivní
- vnitřní smyčku lze nahradit vyhledáváním pomocí indexu

Vybrané algoritmy pro zpracování dotazů (2/2)

Sort-merge Join

- obě relace musí být setříděny (buď pomocí indexu nebo dočasně, jako první krok algoritmu)
- níže nastíněná verze pro unikátní indexy

```
left = fetchFirst(Table1)
right = fetchFirst(Table2)

while (left and right)
    if (isJoinable(left, right))
         emit(join(rs))
         left = fetchNext(Table1)
         right = fetchNext(Table2)
    else if (left > right)
         right = fetchNext(Table2)
    else (left < right)
         left = fetchNext(Table1)
end
```