

Databázové systémy

Spojení v relačním modelu a fyzická reprezentace dat

Petr Krajča



Katedra informatiky
Univerzita Palackého v Olomouci

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:

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

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

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

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



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



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

BAZ
101
103

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

```
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

```
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			tab2						
foo	bar	baz	bar	baz	qux	foo	bar	baz	qux
-----	-----	-----	-----	-----	-----	-----	-----	-----	-----
444	ghi	103	abc	111	zzz	555	def	102	www
555	def	102	def	102	www	555	def	102	yyy
555	ghi	103	def	102	yyy	444	ghi	103	vvv
666	abc	101	ghX	103	xxx	555	ghi	103	vvv
			ghi	103	ttt	444	ghi	103	ttt
			ghi	103	uuu	555	ghi	103	ttt
			ghi	103	vvv	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

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

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;
```

Motivace: chceme spojovat data ze dvou tabulek tak, aby kritérium spojitelnosti nebylo dán 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:

$$\mathcal{D}_1 \bowtie_{\theta} \mathcal{D}_2 = \{rt \mid r \in \mathcal{D}_1 \text{ a } t \in \mathcal{D}_2 \text{ tak, že } rt \text{ splňuje } \theta\}$$

SQL

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

Mějme relace \mathcal{D}_1 a \mathcal{D}_2 na schématech R a T takových, že $R \cap T = \emptyset$ a nechť $\{y_1, \dots, y_n\} \subseteq R$ a $\{y'_1, \dots, y'_n\} \subseteq T$ 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 $y_1 = y'_1 \wedge \dots \wedge y_n = y'_n$ nazýváme **spojení na rovnost** relací \mathcal{D}_1 a \mathcal{D}_2 a označujeme jej $\mathcal{D}_1 \bowtie_{y_1=y'_1, \dots, y_n=y'_n} \mathcal{D}_2$.

SQL

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

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


$$\begin{array}{|c|c|c|} \hline \text{FOO} & \text{BAR} & \text{BAZ} \\ \hline \end{array} \times \begin{array}{|c|c|c|} \hline \text{BAR} & \text{BAZ} & \text{QUX} \\ \hline \end{array} = \begin{array}{|c|c|c|} \hline \text{FOO} & \text{BAR} & \text{BAZ} \\ \hline \end{array}$$

First row of FOO: 444, 555, 555, 666

Second row of FOO: 555, 444, 555, 666

Third row of FOO: 555, 555, 444, 666

Fourth row of FOO: 666, 666, 666, 444

First row of BAR: abc, def, def, ghX, ghi, ghi, ghi

Second row of BAR: 111, 102, 102, 103, 103, 103, 103

Third row of BAR: zzz, www,yyy,xxx,ttt,uuu,vvv

First row of BAZ: 103, 102, 103, 103, 103, 103, 101

Second row of BAZ: 102, 102, 103, 103, 103, 103, 103

Third row of BAZ: 103, 103, 103, 103, 103, 103, 103

Fourth row of BAZ: 101, 103, 103, 103, 103, 103, 103

$$\begin{array}{|c|c|c|} \hline \text{BAR} & \text{BAZ} & \text{QUX} \\ \hline \end{array} \times \begin{array}{|c|c|c|} \hline \text{FOO} & \text{BAR} & \text{BAZ} \\ \hline \end{array} = \begin{array}{|c|c|c|} \hline \text{BAR} & \text{BAZ} & \text{QUX} \\ \hline \end{array}$$

First row of BAR: abc, def, def, ghX, ghi, ghi, ghi

Second row of BAR: 111, 102, 102, 103, 103, 103, 103

Third row of BAR: zzz, www,yyy,xxx,ttt,uuu,vvv

First row of BAZ: 103, 102, 102, 103, 103, 103, 101

Second row of BAZ: 102, 102, 103, 103, 103, 103, 103

Third row of BAZ: 103, 103, 103, 103, 103, 103, 103

Fourth row of BAZ: 101, 103, 103, 103, 103, 103, 103

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)

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

$$\begin{aligned}\mathcal{D}_1 \div_{\mathcal{D}_3} \mathcal{D}_2 = & \{r(R \cap T) \mid r \in \mathcal{D}_1 \text{ tak, že pro každou } s \in \mathcal{D}_2 \text{ splňující podmínu} \\ & r(R \cap S \cap T) = s(R \cap S \cap T) \text{ platí, že } r(R \cap T)s(S \cap T) \in \pi_{(R \cup S) \cap T}(\mathcal{D}_3)\}\end{aligned}$$

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

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 .

- 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 ne definovaným hodnotám v SQL

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

\wedge	0	ω	1	\vee	0	ω	1	\rightarrow	0	ω	1	\neg	0
0	0	0	0	0	0	ω	1	0	1	1	1	0	1
ω	0	ω	ω	ω	ω	ω	1	ω	ω	ω	1	ω	ω
1	0	ω	1	1	1	1	1	1	0	ω	1	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 bud' $zn = 'Paris'$ a tedy $yn \neq zn$, nebo $zn \neq 'Paris'$

Skutečný výsledek:

x	y

Protože $\omega \vee \omega = \omega$

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 zahrnutы 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			tab2						
foo	bar	baz	bar	baz	qux	bar	baz	foo	qux
-----	-----	-----	-----	-----	-----	-----	-----	-----	-----
444	ghi	103	abc	111	zzz	abc	101	666	
555	def	102	def	102	www	def	102	555	www
555	ghi	103	def	102	yyy	def	102	555	yyy
666	abc	101	ghX	103	xxx	ghi	103	444	vvv
			ghi	103	ttt	ghi	103	444	ttt
			ghi	103	uuu	ghi	103	444	uuu
			ghi	103	vvv	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			tab2						
foo	bar	baz	bar	baz	qux	foo	bar	baz	qux
-----	-----	-----	-----	-----	-----	-----	-----	-----	-----
444	ghi	103	abc	111	zzz		abc	111	zzz
555	def	102	def	102	www	555	def	102	www
555	ghi	103	def	102	yyy	555	def	102	yyy
666	abc	101	ghX	103	xxx	444	ghi	103	vvv
			ghi	103	ttt	555	ghi	103	vvv
			ghi	103	uuu	444	ghi	103	ttt
			ghi	103	vvv	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			tab2						
foo	bar	baz	bar	baz	qux	foo	bar	baz	qux
-----	-----	-----	-----	-----	-----	-----	-----	-----	-----
444	ghi	103	abc	111	zzz	666	abc	101	
555	def	102	def	102	www		abc	111	zzz
555	ghi	103	def	102	yyy		ghX	103	xxx
666	abc	101	ghX	103	xxx	555	def	102	www
			ghi	103	ttt	555	def	102	yyy
			ghi	103	uuu	444	ghi	103	vvv
			ghi	103	vvv	444	ghi	103	ttt
						444	ghi	103	uuu
						555	ghi	103	vvv
						555	ghi	103	ttt
						555	ghi	103	uuu

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

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

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

foo	bar	baz
666	abc	101

bar	baz	qux
ghX	103	xxx
abc	111	zzz

- 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;
```

- 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 jednoho 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

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
 - vlastnosti 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

- 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)
```

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)

dva základní typy struktur

1 indexy reprezentující uspořádané množiny

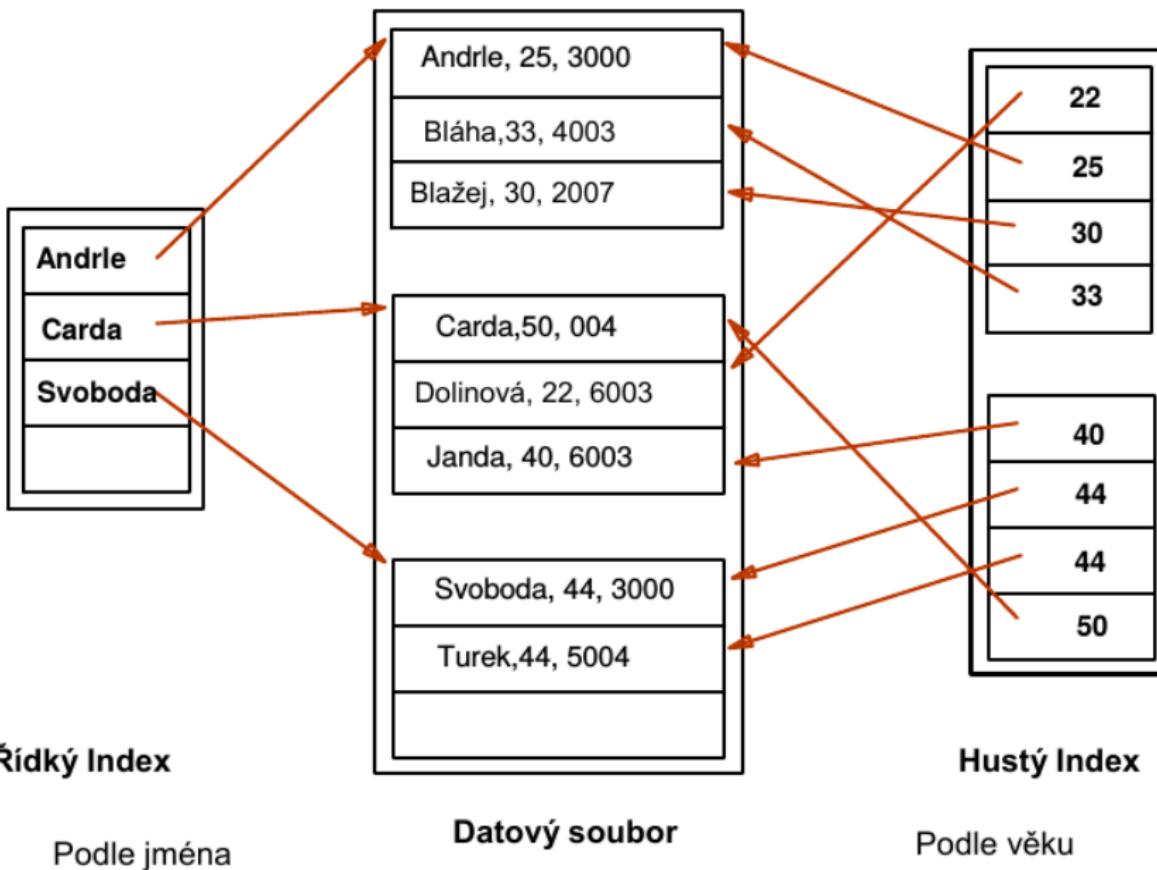
- typicky perzistentní B-strom (B+strom, apod.)
- optimalizace pro diskové (databázové) operace
- rychlé nalezení hodnot pro podmínky s $<$, \leq , $=$, \geq , $>$

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)



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);
```

-- využitelné v dotazech typu

```
SELECT * FROM foo WHERE y = 10;
SELECT * FROM foo WHERE y > 10;
SELECT * FROM foo ORDER BY y;
```

-- ale už ne pro

```
SELECT * FROM foo WHERE z = 20;
```

Vytvoření indexu (2/2)



-- použití hash

```
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 výraz

```
CREATE INDEX foo_abs_idx ON foo (abs (y + z));
```

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

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

Sort-merge Join

- obě relace musí být setříděny (bud' 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
```