

OBSAH

DBS 1

- **T01 DB, Modely; SQL dopyty, WHERE**
- **T02 MySQL - dátové typy a funkcie num. a reť.**
- **T03 Dátové funkcie; JOIN; Agregácia, GROUP BY**
- **T04-5-6 Dátové modely; Integrita; Návrh DB, ER diagramy**
- **T07 Systémové príkazy; Kaskádovité mazanie**
- **T08 Vnorené dopyty; CASE**
- **T09 Trojh. logika; Kvantif. a NOT; Množ. operácie**
- **T10 Dátové sklady DWH, dátové kocky, pivot**
- **T11 Data science, R, dplyr, NASA**
- **T12 Normalizácia, NF – 1. Relačná algebra.**

1. Týždeň

DB, Modely, SQL dopyty, WHERE

- 1) DB
- 2) Modely DB
- 3) SQL
- 4) Príklady
- 5) WHERE klauzula <http://dev.mysql.com/doc/refman/5.5/en/select.html>

1) Databáza (DB)

Údaj vs. informácia

Údaj môže byť text, číslo, obrázok, zvuk, video, ...

Informácia je zaznamenaný a overený **údaj (správa)** ktorý v rámci kontextu


- vedie k zvýšeniu znalosti a zníženiu neistoty a
- ovplyvňuje rozhodovanie, správanie sa.

Nižšie uvedieme niektoré pojmy, ktoré súvisia s databázami.

- **Báza dát, databáza (DB)** – súhrn dát (údajov), ktoré podľa možnosti sú príbuzné a štruktúrované (papierové [kartotéky](#), “clay tables sumer”, banka d.)
- **Počítačová (digitálna) DB** – štruktúrovaná kolekcia **dát** a **metadát**, ktoré sú uložené v počítačovom systéme.
- **DB model** – štruktúra je realizovaná na základe DB modelu pomocou metadát.
 - **relačná algebra**: n-tice a atribúty
- **DB server** – DB je uložená a s ňou súvisiace príkazy sú vykonané na DB servri Server je v prvom rade software až potom je hardware.
- **DBMS** (DB management system) – riadi ukladanie, editovanie, prezeranie dát a administráciu. Prístup k dátam je možné iba cez DBMS.

System pre správu databáz (DBMS) je sada programov umožňujúca riadenie databázy. K **funkciám** DBMS patria:

- definície dát (vzťahy, závislosti, integrity, pohľady, atď.)
- manipulácia s dátami (pridávanie, aktualizácia, mazanie, vyhľadávanie, atď.)
- bezpečnosť dát a kontrola ich integrity
- podpora programovacieho jazyka.



Zložky DB-ho systému zahŕňajú:

- hardvér a operačný systém
- DBMS
- DB
- súvisiace softvérové systémy a / alebo aplikácie
- koncoví užívatelia.

Primárne **ciele** databázového systému sú:

- dostupnosť - jednoduchý a rýchly prístup k dátam
- spoľahlivosť - presnosť a konzistencia
- zníženie redundancie (nadbytočnosť, duplicita) a anomálií
- bezpečnosť a ochrana

Okrem rôznych web a desktop aplikácií (informačné, expertné, atď. systémy) DB-y potrebujú aj operačný systém.

Životný cyklus vývoja databázy:

- prieskum a analýza požiadaviek a špecifikácií
- modelovanie DB
- DB dizajn
- implementácia DB
- použitie DB
- správa DB.

Vo svete existujú rôzne DB systémy:

- Oracle Database, **MySQL** - Oracle Corporation
- DB2 - IBM
- SQL Server – MS
- Ingres
- NoSQL - MongoDB, Elasticsearch, ...

Celkový stav trhu DB v 2006		Stav DB na Windows serveroch v 2008	
Oracle	44.6 %	MS	51.4%
IBM	21.4 %	Oracle	28.8%
MS	16.8 %	IBM	9.8%

Rank			DBMS		Score		
Sep 2017	Aug 2017	Sep 2016	DBMS	Database Model	Sep 2017	Aug 2017	Sep 2016
1.	1.	1.	Oracle 🏆	Relational DBMS	1359.09	-8.78	-66.47
2.	2.	2.	MySQL 🏆	Relational DBMS	1312.61	-27.69	-41.41
3.	3.	3.	Microsoft SQL Server 🏆	Relational DBMS	1212.54	-12.93	+0.99
4.	4.	4.	PostgreSQL 🏆	Relational DBMS	372.36	+2.60	+56.01
5.	5.	5.	MongoDB 🏆	Document store	332.73	+2.24	+16.74
6.	6.	6.	DB2 🏆	Relational DBMS	198.34	+0.87	+17.15
7.	7.	8.	Microsoft Access	Relational DBMS	128.81	+1.78	+5.50
8.	8.	7.	Cassandra 🏆	Wide column store	126.20	-0.52	-4.29
9.	9.	10.	Redis 🏆	Key-value store	120.41	-1.49	+12.61
10.	10.	11.	Elasticsearch 🏆	Search engine	120.00	+2.35	+23.52





Ukazovatele databázového trhu

- 1995, MySQL Ab (aktiebolag = stock company), Michael "Monty" Widenius, David Axmark, Upsala
- 1996, MySQL
- 2008, Sun Microsystems
- 2009, Oracle

2) Modely DB

Z historického hľadiska rozlišujeme:

- Súborový model (slabá štruktúra - oddelovače)
- Hierarchický DB model – strom, predstavuje dáta ako množinu relácií, tabuľky sú prepojené ako rodič & potomok väzbou typu **1:n (1 vstup/rodič a n výstupov/potomkov)**
- Sieťový DB model – predstavuje dáta ako množinu entít a párových vzťahov medzi nimi, väzba typu **m:n**
- **RDB** – **relačný** DB je v súčasnosti najviac rozšírený model
- Objektový DB model – trojrozmerná štruktúra, rýchly prístup k prvkom, dedičnosť, dáta+metódy
- XML – semištrukturovaný model dát



Každý model má mať svoj dopytovací jazyk: RDB – SQL, XML - XQuery

- NoSQL = Not only SQL
NoSQL databáza
 - umožňuje ukladanie a rýchle načítanie dát na základe key–value
 - jeho konzistenčný model má slabšie požiadavky na konzistenciu dát (dáta sú spoľahlivé bez protirečení a výsledok operácie je predvídateľný)
 - podporuje horizontálne škálovanie, distribuované ukladanie dát na viacerých serveroch

ACID a CAP

Pre charakterizáciu DB Uvedieme dve skupiny vlastností, ACID a CAP, ktoré *by mali byť* v databázových systémoch garantované. Prvú relačné databázy garantujú, druhú v distribuovaných počítačových systémoch nie je možné garantovať.

Množina vlastností ACID zabezpečuje spoľahlivé vykonanie databázových operácií.

ACID (Atomicity, Consistency, Isolation, Durability)

A – prevod dát/**transakcia** je buď úplná alebo žiadna - "all or nothing"

C – stav po transakcii nenarušuje zadané pravidlá

I – konkurentné vykonanie transakcie končí stavom, ako keby transakcia bola vykonaná sériovo

D – trvanlivosť stavu (výpadok prúdu, ...)

Pod **transakciou** rozumie práve také operácie, ktoré spĺňajú ACID vlastnosti.

CAP (Consistency, Availability, Partition tolerance) – veta Brewer-a hlási, že v distribuovaných počítačových systémoch nie je možné zabezpečiť súbežné garantovanie všetkých troch požiadaviek:

- **konzistencia** (v danom čase všetky uzly vidia ten istý údaj) – jediná aktuálna kópia dát
- **dostupnosť** (spätne potvrdenie požiadavky \Leftrightarrow request) – vysoká dostupnosť dát
- **tolerančná partícia** (aj keď došlo k strate dát, systém beží ďalej)

Dokonalá dôslednosť a dostupnosť v prípade partície je zriedkavá. _____

Hnutie NoSQL je o voľbe, ktorá sa zameriava predovšetkým na **dostupnosť** až potom na konzistenciu.

Pozri aj ďalšiu charakterizáciu \Rightarrow **PACELC = CAP + Else Latency Consistency**

Relačný DB model (RDB)

V súčasnosti najviac sú rozšírené relačné databázy, ktoré charakterizujú:

- **n-tice** a **atribúty**, **relácia** – **tabuľka**, **množina**, **domény** a **ohraničenia**, dvoj/trojhodnotová logika, *NULL* nie je relačný prvok, chýbajúca informácia
- priamy prístup ku každej tabuľke, tabuľky môžu byť prepojené
- jazyky: **relačná algebra**, relačný kalkulus, **SQL**
 - relácia / relation vs. hlavička (**schéma**) \Rightarrow tabuľka je inštancia rel. schémy
 - vzťah / relationship medzi tabuľkami pomocou **klúčov**
- funkčná závislosť, normalizácia (odstránenie duplicit, anomálií a zabezpečenie integrity)

Teória RDB bola vytvorená s **Edgar Frank Codd**, 1970, IBM. Základnými pojmami relačnej teórie, **relácia**, **n-tica**, **atribút** v SQL DB zodpovedajú **tabuľka**, **riadok**, **stĺpec**. Codd používal pojem doména, v súčasnosti v computer science používame skôr typ.

U Codd **relácia**¹ je množina n-tíc, teda **podmnožina** karteziánskeho súčinu $A_1 \times A_2 \times \dots \times A_n$.

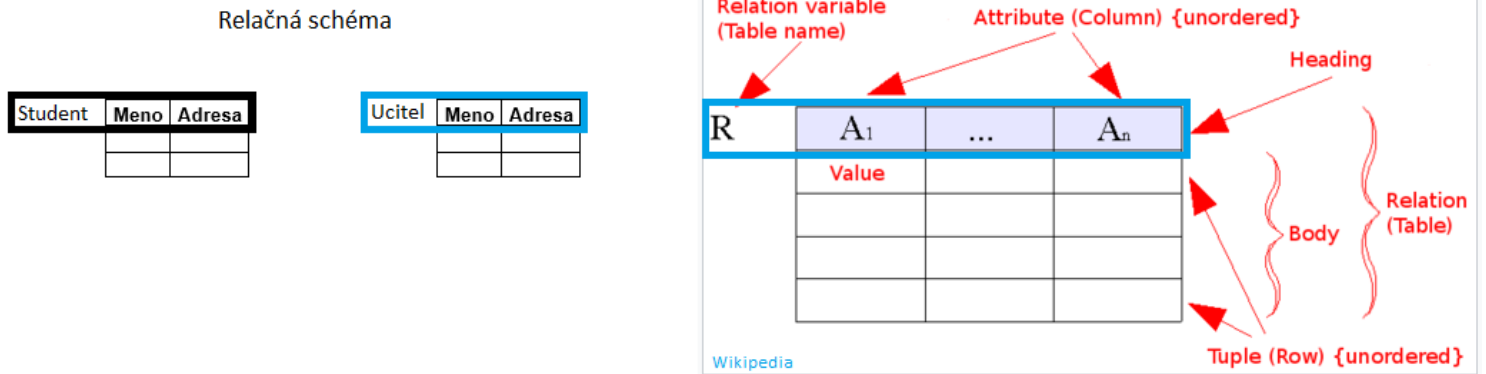
Relácia r je usporiadaný pár (H, T), kde

- H je hlavička **r**, **atribúty** H sú atribúty **r** a
- T je množina n-tíc (tuples, telo **r**), ktoré všetky majú hlavičku H, **n-tice** T zodpovedajú n-tice **r**.

¹ Pripomíname, že binárna **relácia** R medzi dvomi množinami A a B je **podmnožina** karteziánskeho súčinu $A \times B$, teda $R \subseteq A \times B$. Prvok R sa označuje (a,b), resp. aRb (a je v relácii s b, a súvisí s b).

Funkcia je taká binárna relácia medzi dvomi množinami A a B, pre ktoré platí, že každý prvok A je v relácii iba s jedným prvkom B: $\forall x \in A \exists! y \in B : xRy$.

Teda **hlavička** A je množina atribútov, **telo** T je množina n-tíc, zodpovedajúcich tej istej hlavičke. Pomenovaná hlavička s obmedzeniami na A je **relačná schéma R**



Relácia r je **inštancia** relačnej schémy, pozri 4. týždeň.

C.J. Date narába s pojmom **relvar** (relačná premenná), ktorá je premenná, obsahujúca relačnú hodnotu, teda inštanciu relácie.

Zdôrazňujeme, že:

relácia ~ tabuľka (relácie sú reprezentované tabuľkami)

relácia != tabuľka - každá relácia môže byť reprezentovaná ako tabuľka, ale nie každá tabuľka zodpovedá nejakej relácii.

Základná požiadavka Codda, teda relačnej teórie DB, na reláciu:

každý riadok v tabuľke obsahuje hodnotu pre každý stĺpec.

C1	C2
1	a
2	b
1	

C1	C2
1	a
2	b
1	a

- takéto tabuľky v relačnej algebre (RA) nie sú dovolené (\rightarrow null, jedinečnosť riadkov), v SQL áno.

Rozlišujeme **tri dátové modely** pri príprave a návrhu DB s rôznymi úrovňami abstrakcie

- konceptuálny model – sémantika (význam)
- logický model – usporiadať dáta do logických štruktúr – tabuľky; doména
- fyzický model – typy atribút, indexy (tieto rozhodnutia ovplyvňujú ukladanie)

a **štyri štruktúry** (\neq modely) v DB:

- konceptuálna štr.
- logická štr. – tabuľky
- interná / fyzická štr. – stránky (dát a indexov), 8 KB stránky/pages
- externá / užívateľská štr. – pohľady

3) SQL

Komunikácia s DB sa uskutočňuje príkazmi jazyka **SQL** (Structured Query Language)
- neprocedurálny, deklaratívny prístup k dátam, D. Chamberlin, 1974 – SEQL
Na rozdiel od **imperatívnych** (píkazových [stav]) jazykov, ako napr. C, Java a C#, SQL je **deklaratívny** jazyk, kde dôraz nie je na presnom predpise príkazov ale na logickej formulácii úlohy.

V rámci SQL rozlišujeme DDL, **DML** (Data Definition & **Manipulation** Language) a **dopyt** (**query** – prezeranie / prehľadávanie)

V jazyku definície dát (**DDL**) môžeme vytvárať, zmeniť a odstrániť databázy; vytvárať, zmeniť a odstrániť tabuľky, definovať stĺpce tabuľky, indexy a vykonať ďalšie kroky, ktoré majú vplyv na štruktúru databázy.

V jazyku na manipuláciu s dátami (**DML**) môžeme pridávať, upravovať a mazať riadky, záznamy a inak manipulovať obsah databázy.

Pomocou dopytov (**SELECT**) prehľadávame obsah tabuliek.

DDL	DML	Dopyt
DB / Table	Údaje v tabuľke	Obsah tabuliek
- CREATE - ALTER - DROP	- INSERT - UPDATE , MERGE - DELETE	SELECT

V SQL príkaze SELECT môžeme používať:

- filtráciu hor. a vert. WHERE a SELECT
- usporiadanie ORDER BY
- agregáciu SUM, MEAN
- zoskupenie GROUP BY
- spojenie JOIN
- vnorené dopyty SELECT ... SELECT ...

Jazyk SQL bol štandardizovaný organizáciami

- ANSI (American National Standards Institute)
- ISO (International Standards Organization) <http://www.iso.org/iso/home/standards.htm>

niekoľkokrát

SQL1986, SQL1989

SQL1992, SQL1999

SQL2003, 2008, ...

Nižšie nájdete (pre zaujímavosť) syntax príkazu CREATE TABLE

<http://dev.mysql.com/doc/refman/5.7/en/create-table.html> <https://docs.microsoft.com/en-us/sql/t-sql/statements/create-table-transact-sql>

4) Príklady

<http://www.mysql.com/>

<http://dev.mysql.com/doc/refman/5.7/en/>

Nižšie uvedieme niekoľko ilustračných príkladov v MySQL.

```
###
### 0)
###
SELECT USER();    # MySQL

SELECT 1+1;    #Komentar - MySQL
SELECT 1*1;    -- Komentar s medzerou
```

```
SHOW databases;
USE world;
SHOW TABLES FROM world;
SELECT * from city;
```

```
###
### 1) CREATE DATABASE
###
CREATE DATABASE DBmaz;
# CREATE DATABASE DBmaz; # NO
DROP DATABASE DBMaz;
CREATE DATABASE DBmaz;
CREATE DATABASE IF NOT EXISTS DBmaz;
```

```
DROP DATABASE IF EXISTS DbMaz;
CREATE DATABASE IF NOT EXISTS DbMaz;
```

```
###
### 2a) CREATE TABLE
###
USE DBmaz;
CREATE TABLE TabMaz (id int, meno varchar(20));
# CREATE TABLE TabMaz (id int, meno varchar(20)); # NO
DROP TABLE IF EXISTS TabMaz;
CREATE TABLE IF NOT EXISTS TabMaz (id int, meno varchar(20));
```



```

###
### 02b): INSERT pomocou VALUES
###
INSERT TabMaz VALUES(1,'Ja');
INSERT INTO TabMaz(id, meno) VALUES(2,'Ty'), (3,'On');
INSERT TabMaz VALUES
(4,'Ona'),
(5,'Ono');
SELECT * FROM TabMaz;

SELECT DATABASE();           -- current DB
SHOW VARIABLES LIKE "%version%"; -- 8.0.17

-- select db_name(); select @@SERVERNAME; -- SQL Server

```

5) WHERE klauzula <http://dev.mysql.com/doc/refman/5.5/en/select.html>

```

SELECT [DISTINCT] zoznam
FROM
zoznam/zdroj_tabuliek
[WHERE podmienka]
[GROUP BY zoznam
[HAVING podmienka] ]
[ORDER BY]

```

WHERE klauzula príkazu SELECT špecifikuje
vyhľadávaciu podmienku / [filter](#)

pre riadky, ktoré dopyt má vrátiť.

Syntax:

WHERE <vyhľadávacia podmienka> [**WITH ROLLUP**]

kde vyhľadávacia podmienka je kombináciou niekoľkých predikátov spájaných logickými operátormi AND, OR a NOT.

Predikát používa atribúty ako premenné a nadobúda hodnoty T, F na n-ticiach.

WHERE, podobne ako HAVING, je **filter**: určuje sériu vyhľadávacích podmienok a do výsledku sa zaraďujú iba tie riadky, ktoré spĺňajú dané podmienky.

Vyhľadávacia podmienka môže obsahovať:

- porovnávacie operátory ako: =, >, ...
- intervaly: [NOT] BETWEEN
- zoznamy: [NOT] IN
- zhodu schém: [NOT] LIKE
- IS NULL, IS NOT NULL
- = ALL, > ALL, <= ALL, ... ANY

- kombináciu týchto podmienok vďaka OR, AND, NOT

ALL, ANY<=>SOME, EXISTS

ALL a ANY pre každý riadok porovnávajú skalárnu hodnotu so zoznamom alebo množinou hodnôt jediného stĺpca vnoreného dopytu - (SELECT ako vonkajší dopyt môže obsahovať ďalšie SELECTy, ako poddopyty ↔ vnorené dopyty, pozri 8.týždeň)

ALL / ANY vráti TRUE ak dané porovnanie je
TRUE pre **všetky** dvojice / **aspoň** pre jednu dvojicu.

Syntax:

```
... WHERE LavStr > ALL (VnorDop) ...
```

teda skalárna veličina LavStr VonkDopytu (ľavá strana porovnania) sa porovnáva s **každou** vrátenou hodnotou VnorDopytu

EXISTS vráti TRUE ak poddopyt vráti **aspoň** jeden riadok.

Príklady

```
### A) WHERE IN, BETWEEN
###
```

```
DROP TABLE IF EXISTS T;
CREATE TABLE T(i INT);
INSERT INTO T VALUES (1), (2), (6), (7);
```

```
SELECT * FROM T WHERE i IN (1,3,6);           # 1 / 6
SELECT * FROM T WHERE i BETWEEN 3 AND 7;      # 6 / 7  <=>:
SELECT * FROM T WHERE 3<=i AND i <= 7;       # 6 / 7
```

```
### B) ALL, ANY + prvé poddopyty: pozri podrobnejšie Tyzdne 8 a9.
###
```

```
DROP TABLE IF EXISTS T;
CREATE TABLE T(i INT, j INT, k INT);
INSERT INTO T VALUES
```

```
(1, 10, 5),
(2, NULL, 4),
(3, 50, 3),
(4, 50, 2),
(5, 10, 1),
(6, 50, 2);
```

```
ALTER TABLE T DROP COLUMN k; # podrobnejšie Tyzden 6
DROP TABLE IF EXISTS U; CREATE TABLE U(i INT);
```

```
INSERT INTO U VALUES (11), (12), (13), (14);
```

```
SELECT * FROM T WHERE i+10 IN (SELECT * FROM U);    -- vnoreny dopyt
SELECT * FROM T WHERE i+10 >= ANY (SELECT * FROM U);
SELECT * FROM T WHERE i+10 >= ALL (SELECT * FROM U);
SELECT * FROM T WHERE i+10 <= ALL (SELECT * FROM U);
```

Tab. T		Tab. U
i	j	i
1	10	11
2	NULL	12
3	50	13
4	50	14
5	10	
6	50	

Výsledky

i	j	i	j	i	j	i	j
1	10	1	10	4	50	1	10
2	NULL	2	NULL	5	10		
3	50	3	50	6	50		
4	50	4	50				
		5	10				
		6	50				