

Soubory a databáze

Datový typ soubor

- **Soubor**
 - označuje množinu dat, která jsou kompletní k určitému zpracování a popisují vybrané vlastnosti reálných objektů
- **Záznam**
 - soubor se skládá ze záznamů, které popisují vybrané vlastnosti jediného objektu
- **Položka záznamu**
 - popisuje určitou vlastnost objektu
- **Klíč záznamu**
 - jedna z položek záznamu, která je pro každý záznam jedinečný (unikátní)
- **Návěstí souboru**
 - sdružuje všechny informace potřebné k identifikaci souboru
 - jméno souboru
 - evidenční a pořadové číslo
 - datum vytvoření a doba platnosti
 - oprávnění přístupu
 - způsob práce se souborem
 - způsob kódování záznamů
 - délka souboru – počet záznamů
 - uloženo na začátku nebo konci souboru

Operace se soubory

- **Rozdelení souborů podle způsobu přístupu k záznamům**
 - **sekvenční soubor**
 - přístupný je pouze aktuální záznam podle pořadí zpracovávání počínaje prvním záznamem
 - **soubor s náhodným přístupem**
 - záznamy jsou přístupné podle svého klíče
- **Operace nad souborem rozdělujeme podle úrovně pohledu**
 - **operace na úrovni záznamu**
 - operace s jednotlivými položkami záznamu
 - **operace na úrovni souboru**
 - operace se záznamy jako celky
 - **operace se soubory**
 - operace se soubory jako celky

Implementace souborů

Sekvenční soubory

- reprezentovány posloupností **bloků** obsahujících jeden nebo více datových záznamů
- této posloupnosti předchází blok s **návěstím souboru** (PNS) a **značkou souboru** (ZS)
- soubor je ukončen blokem **konce souboru** (KS) a případně **koncovým návěstím** (KNS)



Soubory s náhodným přístupem

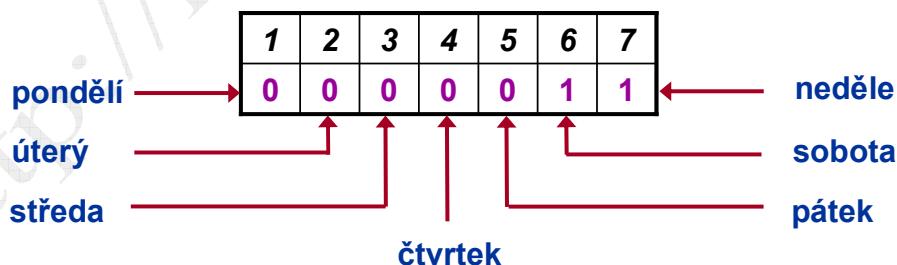
- záznamy v souboru jsou identifikovatelné pomocí **klíče**, který je součástí záznamu
- každý záznam** je adresovatelný – **zaujímá 1 blok**
- adresované soubory**
 - je definována **funkce $f(k)$** , která jednoznačně přiřadí každému klíči k z množiny klíčů K ($k \in K$) adresu $adr = f(k)$ z intervalu adres A ($adr \in A$) přidělených souboru na disku
- indexované soubory**
 - přiřazení adres daným klíčům je definováno **tabulkou indexů** – každému klíči je přiřazen adresní klíč, tj. adresa uložení záznamu

Kódování složek záznamu

Na kódování složky záznamu má vliv nejen typ hodnoty, ale i její rozsah

Pozičně kódované složky

- položka s předurčeným rozsahem k hodnot je reprezentována k -ticí bitů
- hodnota v i -tému bitu reprezentuje i -tou hodnotu z k hodnot
- např.** dny v týdnu – reprezentace víkendu:



Binární kombinační kódování

- položku s předurčeným rozsahem hodnot $1..n$ zobrazíme k -ticí bitů, $k = \lceil \log_2 n \rceil$
- každé hodnotě $h \in 1..n$ přiřadíme jednu kombinaci 0 a 1 k -tice bitů
- např.** dny v týdnu:

001 – pondělí	101 - pátek
010 – úterý	110 - sobota
011 – středa	111 - neděle
100 – čtvrttek	

- paměťově úspornější
- neumožňuje vytvářet kombinace hodnot

■ **Položky s pevnou délkou**

- položky s velkým předurčeným rozsahem hodnot se reprezentují základními datovými typy
- **integer, real, char, string, ...**

■ **Opakující se položky**

- složkou záznamu nemusí být jen jediná hodnota, ale seznam hodnot, jehož délku předem neznáme
- řešením je omezení délky seznamu (např. poslední tři hodnoty)
- některé systémy ovládání souborů připouštějí záznamy proměnné délky – položka s proměnnou délkou je pak poslední položkou záznamu

■ **Textové položky**

- hodnoty textových položek jsou řetězce znaků libovolné délky
- obvykle záznam obsahuje jedinou textovou položku nebo dokonce soubor obsahuje jediný záznam s textovou položkou
- textovou položku je obvykle nutné rozdělit do několika fyzických bloků

■ **Odkazové položky**

- hodnotou odkazové položky je odkaz na jiný záznam v souboru
- může mít formu klíče jiného záznamu, relativní pozice nebo fyzické adresy záznamu v souboru

Operace na úrovni souboru

■ Operace nad sekvenčním souborem

■ **OPEN** – otevření souboru

- soubor lze otevřít jako vstupní (pouze pro čtení) nebo jako výstupní (pouze pro zápis)

■ **READ** – přečtení aktuálního záznamu

- záznam je k dispozici až do čtení dalšího záznamu

■ **WRITE** – zápis záznamu do souboru

■ **CLOSE** – uzavření souboru

- pro správné uložení (i čtení) souboru je nutné soubor uzavřít

■ Operace nad souborem s náhodným přístupem

- **OPEN** – otevření souboru
 - otevření souboru pouze pro čtení, pouze pro zápis nebo pro čtení i zápis
- **READ** – přečtení záznamu s daným klíčem
- **WRITE** – zápis záznamu do souboru
- **REWRITE** – zápis nové hodnoty záznamu s daným klíčem
- **DELETE** – zrušení záznamu s daným klíčem
- **CLOSE** – uzavření souboru

Operace se soubory

■ Nad celými soubory zavádíme následující operace

- **Konverze souboru**
 - kopírování souboru s případnými drobnými úpravami, souvisejícími s jinou vnitřní reprezentací souboru – **konverze pro různá vnější zařízení, komprimace a expanze**
- **Řazení souboru**
 - seřazení záznamů souboru podle hodnoty klíče
 - řazení pomocí některé metod se sekvenčním přístupem – nejčastěji **Merge-sort**
- **Slučování souborů**
 - sloučení dvou seřazených souborů v jediný soubor
- **Aktualizace souboru**
 - promítání změn do všech nebo vybraných záznamů
 - generuje se nový soubor s aktualizovanými záznamy nebo se aktualizovaný záznam zapisuje na původní místo

Soubory a databáze

■ Soubory dat jsou navrženy podle potřeb konkrétních programů, které je používají – s tím souvisí problémy:

- **redundance a konzistence**
 - **redundance** = opakovaný (nadbytečný) výskyt některé informace ve více souborech
 - **konzistence** = opakovaně uložený údaj musí zachovávat stejnou hodnotu – popisuje vlastnost jediného objektu

■ **integrita**

- všechna data uložená v souborech musí odpovídat vlastnostem popisovaných objektů reálného světa

■ **obtížná dosažitelnost dat**

- uživatelé potřebují získávat odpovědi na své dotazy ohledně stavu dat uložených v souborech
- řeší se specializovanými programy – je nutné předem znát kostru dotazu

■ **současný přístup více uživatelů**

- systémy zpracování dat umožňují nebo potřebují současný přístup více uživatelů k souborům dat

■ **ochrana dat proti zneužití**

- není žádoucí, aby mohl kdokoliv provádět s daty jakékoli operace nebo měl přístup ke všem uloženým informacím

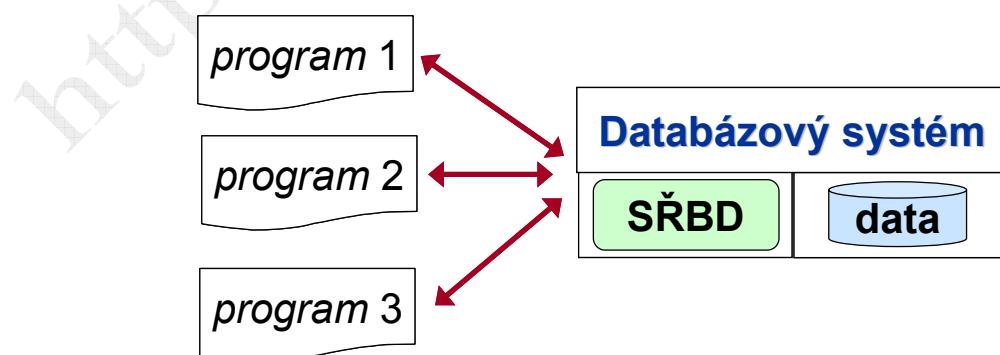
Databázové systémy

■ Uvedené problémy se staly důvodem vzniku a rozvoje **databázových systémů** s následujícími vlastnostmi:

- oddělené struktury aplikačních programů a datových souborů
- přístup k datům je možný jen prostřednictvím programů databázového systému, ne přímo
- dotazy nejsou pevné
- je umožněn přístup více uživatelů současně
- je vyřešena ochrana dat – přístupová práva

■ **Databázový systém** se skládá z

- **databáze (báze dat)** = množina vzájemně spolu souvisejících dat vztahujících se k určité problematice
- **systému řízení báze dat (SŘBD)** = programový aparát pro popis a manipulaci s uloženými daty



■ **Databázový systém** zahrnuje:

- **prostředky pro popis dat**
 - **DDL** (*Data Definition Language*)
- **prostředky pro popis algoritmu práce s daty**
 - **DML** (*Data Manipulation Language*)
- **prostředky pro popis ochrany přístupu k datům**
 - **DCL** (*Data Control Language*)
- **dotazovací jazyk** pro uživatelské dotazy
 - **SQL** (*Structured Query Language*)
 - **QBE** (*Query By Example*)