

Registry (hardware); primární (operační) paměť (software); sekundární paměť (disk); magnetické pásky, CD, ...
Posbíraná data -> vyčištěná data -> použitelná data

Data – logický pohled (jaké atributy...); fyzický pohled (jak jsou řešeny); implementace (jak jsou umístěny)
Délka záznamu R , velikost bloku B ; $B/R > 1$ snaha o celočíselné, =0 ideální, <1 přerostlé záznamy – problém

Magnetické pásky – 9 stop z 1 strany (8 data, 1 parita) mezi bloky prázdno, abych se nemusel vracet na konci

Drahé, dlouho vydrží, rychlé na sekvenční přístup, proudová data, zálohování; desítky GB za hodinu

Magnetický disk – hlavičky v zákrytu, aktivní jen 1 (posuny při zahřívání); tisíce ot./min.; až 1TB

parametry s (seek) – vystavení hlavy; r (otation delay) – polovina otáčky disku; b (lock)t(ansfer)t(ime) přenos

Diskové pole RAID – redundantní pole pevných disků; ke zvýšení kapacity/ rychlosti/ bezpečnosti...

RAID 0 – střídavý zápis na jednotlivé disky – při zničení jednoho ztratím vše; rychlý zápis (do obou naráz)

RAID 1 – stejná data na oba disky – pomalý zápis, rychlé hledání; nejvíc plýtvání/ nejbezpečnější

RAID 0+1 – levné souborové systémy; kombinace 0, 1; alespoň 4 disky

RAID 1+0 – databáze; kombinace 0, 1; alespoň 4 disky

RAID 3 – pracuje po bitech, jeden vyhrazen pro paritu; rychlé IO pro sekvenční data; dražší řadič...

RAID 4 – data zapisována po blocích, jeden blok pro paritu; rychlé IO pro sekvenční data; pomalý zápis

RAID 5 – parita postupně na různé disky; rozumný kompromis mezi bezpečností, kapacitou a výkonem

RAID 6 – 2 paritní disky – horizontální a vertikální; složité a drahé/ bezpečné – pro kritické aplikace

Optické disky – CD, DVD, Blue-ray...; Jukeboxy – data uložená na více médiích, přístup až sekundy

Flash paměti – na všechna data stejně rychle; zápis pomalejší než čtení; nevydrží moc zápisů; větší spotřeba

Připojování – přímo DAS; přes síť NAS; bloková úložiště SAN

Soubor – identifikovaná kolekce logicky souvisejících záznamů; jsou-li stejného typu a velikosti – homogenní s.

Klíč – množina atributů jednoznačně identifikujících záznam – hodnotové, hashované, relativní (od zač. soub.)

Operace nad soubory – insert, delete, update, fetch

Schema organizace souboru – abstrakce zobecňující soubor s určitými vlastnostmi – struktura, algoritmy, data
dynamické – rovnoměrná naplněnost stránek; omezená délka cesty; jinak statické

Operace nad schematy organizace souboru – build, reorganization, stav souboru, close

Čtení zadaného souboru – sériové (dle zadaného uspořádání), sekvenční (dle uložení)

Hromada – nehomogenní soubor; k atributům i jména;

Sekvenční – nejjednodušší, dávkové systémy; nesetříděný pro sesbíraná data/ uložený – pro práci se všemi daty
primární soubor + s. aktualizací, reorganizace = setřídění a slití, hledání půlením intervalu $\log_2(N/|b|)(s+r+btt)$

Index-sekvenční – přístup sekvenčně i přímo; data, index, oblast přečtení; účetní systémy platebních karet.

Kapsy – indexované množiny bloků ~ spojový seznam; bitová mapa co obsazeno $\lfloor \log_{B/R} \lfloor N/|B/R| \rfloor \rfloor$

Indexový – vyhledávání dle různých klíčů; primární soubor a indexy – setříděné klíče + odkazy; $\lfloor \log_{B/R} N \rfloor$

Částečná shoda – vyváření průniků adres; kombinovaný index pro více atributů zároveň

Nepřímé adresování – primární a sekundární klíč – mohou reorganizovat soubor bez změny indexů

Bitové mapy – pro malé domény hodnot (až 1000); booleovské dotazy; združování procesů – rychlejší

Indexy: Statické, seznamy adres, bitové mapy, B stromy, kombinované indexy, vícerozměrné indexy

S přímým přístupem – velmi rychlé přístupy dle konkrétního klíče; adresa dána klíčem; nevhodné pro řídká data
přímo (logická/ fyzická adresa); nepřímo (transformovaná adresa musí být jednoznačná)

1 vyhl. klíč -> indexový s.; jen sekvenční přístup -> sekvenční s.; jen přímý přístup -> s. s přímým p.; index-s. s.

Hashování – řešení kolizí – prostá fce, první volné místo za, sekundární fce, perfektní hashování

Cormack – dvoufázové – do adresáře a primárního souboru; sekundární fce $(k \gg i) \bmod r$

$h(k, s)$ do tabulky délky s ; p počátek oblasti, i o kolik jsem shiftoval; p počet prvků

Larson+Kalja – 2 sady fci; data do m stránek, každá zámeček; $h_i(k) = (k+i) \bmod s$; test zámku $s_i(k) = (k \text{ XOR } i) \bmod z$

Fagin (rozšiřitelné) – hlavičky po kolika bitech se liší co je ve stránce; dělení – rozpůlím, inkrementace hlavičky

Litwin (lineární) – vždy po L záznamech rozštěpím stránku, která je na řadě; oblast přečtení, vždy pak projít

Skupinové štěpení – dělím po L záznamech G stránek do $G+1$, jsou-li všechny, přerovnáám a znovu...

přístup simuluje tvorbu – $h()$, $h_1()$, $h_2()$,... $k \bmod s$, $k \bmod (G+1)$, $(k \text{ div } (G+1)) \bmod (G+1)$

B-strom – redundantní (všechna data v listech), neredundantní (v každém uzlu, data unikátní)

kořen $2-m$ potomků, ostatní uzly $\lfloor m/2 \rfloor - m$ potomků; všechny větve stejně dlouhé, v uzlu setříděné

B+strom – poslední člen odkazuje na další list; jen u redundantních – pro rychlé sekvenční čtení

B^* strom – kouknu k sousedům, mají-li místo, podstrčím jim prvek, nemají-li místo, vezmu je a rozdělím do $n+1$
Proměnná délka záznamu – řetězce...; mít znak pro konce slov...; u redundantních netřeba v nelistech celá slova
 B -strom s odkládaným štěpením – nerozdělím uzel hned, jen stránka přetečení a teprve až přeteče i ta...
Více rozměrný B -strom – v jednotlivých úrovních různé klíče – problém když ty horní neznám...
Vícerozměrná mřížka – obdélníčky na tutéž stránku, nad tím indexy, když přeteče rozdělím na obdélníčky
při dělení 1×1 musím rozdělit matici a přestavět to...; velmi náročné na údržbu

Spojené klíče – jak je seřadit, kolik dát kterému bitů, neznáme-li vždy všechny
 d # bitů, p_i pravděpodobnosti; $d_i = (d - \sum \log_2 p_j) / n + \log_2 p_i$; $d_i < 0$ -> eliminuj A_i přepočti; $d_i > d$ -> $d_i = d$, zbytek := 0;
 $d_i > \log_2 |A_i|$ -> $d_i = \log_2 |A_i|$, $d = d_i$, eliminuj A_i , přepočti; zaokrouhlit
problém – musíme prohledat hodně stránek, zda tam něco není... -> deskriptory, grayovy kódy...
deskriptory – 2. hašovací fce nastaví při vložení bit, nejdřív testuji, zda tam má cenu hledat
rozdělit na dvě části a testovat nejdřív první pak druhý... - víc úrovní...; pro větší domény hodnot
Grayovy kódy – upravené číslování stránek – změna vždy jen v jednom bitě

Prohledávání kolekcí dokumentů – procházet (slovo, dokument, pozice) – je třeba mít dost místa na disku
setřídíme primárně dle slov -> slovo, dokument, pozice, pozice..., dokument,... a v tom hledám...
hledání „slovo1 slovo2“ vs „slovo1. Slovo2“ - členit raději ještě na odstavec, věta; ale Karel IV. ...
potřeba program na základní tvary, problém „travička“...

(a, b) stromy – počet potomků mezi a a b ; když chci vkládat a po cestě narazím na plný uzel, tak ho rozštěpím
méně časté štěpení vs. zhoršení naplnění

Spirálová paměť - ???

Bitemporální databáze – občas si musím pamatovat i změny, kdo ji provedl.../ odkdy do kdy platí (jízdni řády)