

Základy forenzních databází

Tereza Uhlíková

verze y25

Kdo jsem

Tereza Uhlíková

Ústav analytické chemie

skupina teoretické spektroskopie

místnost A277

<https://web.vscht.cz/~uhlikovt/>

tereza.uhlikova@vscht.cz

Co bude dnes


- Index v databázích
- Datové struktury
- Ukládání
- Řazení
- Vyhledávání

Zahřívací příklad


Vytvořte databázi (aplikaci),
kde registrovaní uživatelé mohou vkládat příspěvky do různých diskusních skupin.

Uživatelé se budou přihlašovat pomocí loginu, diskusní skupiny se budou rozlišovat podle názvu a příspěvky v nich potom podle datumu vložení.

Zahřívací příklad



Zahřívací příklad



primární klíč a cizí klíč jsou indexy

Indexy v databázi

Index je speciální datová struktura, která umožňuje rychlejší vyhledávání v databázi — podobně jako rejstřík v knize.

*Bez indexu by databáze musela při vyhledávání číst celý „obsah knihy“ (všechny řádky tabulky).
S indexem si ale může „skočit“ přímo na místo, kde se hledaná informace nachází.*

Jak to funguje (stručně):

Uživatel databáze označí daný sloupec indexem - databázový program data v tomto sloupci uspořádá **interně** do formy nějaké datové struktury (kterou programátor předtím naprogramuje; např. B-strom).

Tato struktura udržuje hodnoty v daném pořadí ⇒ umožňuje rychlé hledání.

Indexy v databázi - příklad

entita vzorek:

ID	latka	koncentrace	datum_analyzy
001	ethanol	0.12	1.12.2023
002	toluen	0.45	5.8.1999
003	benzen	0.22	15.10.2020

Když se pak provede dotaz typu:

```
SELECT * FROM vzorek WHERE cislo_vzorku = '123';
```

databáze neprochází celou tabulku, ale použije index, tedy datovou strukturu, která ji rychleji (záleží na složitosti vyhledávacího algoritmu) navede na správný záznam.

Pokud databáze obsahuje 100 000 nesetříděných záznamů a my chceme najít „vzorek 003“, bez indexu musí databáze projít všech 100 000 řádků. S indexem na sloupci *cislo_vzorku* najde výsledek během zlomku milisekundy. Proč? pokusíme se to pochopit na formátu datových struktur.

indexy - výhody a nevýhody

Výhody:

- rychlejší vyhledávání
- umožňují třídění bez nutnosti procházet celou tabulku
- zvyšují efektivitu u velkých databází (tisíce–miliony řádků)

Nevýhody:

- zabírají místo na disku
- zpomalují vkládání a mazání (musí se aktualizovat)
- u malých tabulek bývá zbytečný


Zahřívací příklad - pokračování

Vytvořte databázi (aplikaci),
kde registrovaní uživatelé mohou vkládat příspěvky do různých diskusních skupin.

Uživatelé se budou přihlašovat pomocí loginu, diskusní skupiny **chceme vypisovat seřazené** podle názvu a příspěvky v nich potom podle datumu vložení.

Jaký sloupec označíme indexem?

Indexů v databázi



vytvoreno - vypisování několika nejnovějších příspěvků nezávisle na skupině
(skupina, vytvoreno) - výpis ve skupinách ...

Datové struktury

Datová struktura

způsob, jakým jsou data organizována, uložena a propojena, aby bylo možné s nimi efektivně:

- vyhledávat,
- třídit,
- vkládat,
- mazat,
- zpracovávat další výpočty.

Např. vyhledat položku v neuspořádaném seznamu trvá $O(n)$, ale v binárním stromu jen $O(\log n)$.

Znáte nějaké datové struktury?
Dokážete nějaké vymyslet?


10 Data Structures Used in Daily Life

ByteByteGo

Data Structure	Illustration	Use Cases
List		Twitter feeds
Array		Math operations Large data sets
Stack		Undo/Redo of word editor
Queue		Printer jobs User actions in game
Heap		Task scheduling
Tree		HTML document AI decision
Suffix Tree		Search string in document
Graph		Friendship tracking Path finding
R-tree		Nearest neighbour
Hash Table		Caching systems

Lineární struktura - Seznam (List)


Seznam (List) - Sekvence prvků, do které lze vkládat a mazat položky. uzly a ukazatele



zápisník měření, kam se může přidávat a mazat stránky; sada vzorků v sérii analýz.

Lineární struktura - Pole (array)


Pole (array) - Souvislý blok paměti s pevnou velikostí. Přístup podle indexu. V mnoha prog. jazycích



zkumavky v přesně dané řadě (indexované pořadím); data spektra: intenzita v jednotlivých bodech.

Lineární struktura

Zásobník (Stak) - LIFO (last in first out) – poslední vložený prvek se čte první.



Sled kroků v sekvenci zpracování dat

Fronta (Queue) - FIFO – první vložený prvek se čte první. *Pořadí zpracování vzorků v automatickém měřiči.*


Stromová struktura

Hierarchická struktura uzlů (každý má potomky).


uzly (nodes) spojené hranami (edges), souvislý a acyklický

kořen, list, uzel, předchůdce (rodič), (pravý/levý) následovník (potomek),

sourozenci, stupeň uzlu, hloubka (výška)



Strom (latinských) jazyků




<https://www.adamek.cz/jazyky/mapa-slovanske-jazyky/5-evropa/indoevropsky-strom.svg>

Binární strom

kořen a každý uzel má nejvýše dva potomky. V každém uzlu je uložený právě jeden prvek.

má přesně dané, kde jaký prvek leží; počet uzlů v hladině h je 2^h




Společná práce

Vytvořte strom pro infixovou notaci pro příklad $(7+3)*(5-2)$

Společná práce

Vytvořte strom pro infixovou notaci pro příklad $(7+3)*(5-2)$
Jak se strom změní pro výraz $7+3*5-2$

Strom pro infixovou notaci




Struktura aritmetického výrazu $(7 + 3) * (5 - 2)$

Další stromy


ALV-strom - binární vyhledávací strom s jednou podmínkou navíc: V každém vrcholu stromu se hloubka jeho levého a pravého podstromu liší nejvýše o jedna.

B-stromy - vícečetný uzel, v uzlu mohou být celé další struktury, které jsou do stromu navěšené podle nějaké jejich vlastnosti (ID, jméno uživatele)

B-TREE



BINARY TREE




Graf

Uzly (node, vertex) propojené hranami (edges). Obecnější než strom.
Uzly grafu uchovávají data. Hrany jsou spojnice uzlů označující vazby, nebo vztahy mezi nimi.

molekulová síť - Molekula: uzly = atomy, hrany = vazby


Podle vnitřní struktury:

- neorientovaný graf - hrany nerozlišují směr
- orientovaný graf - hrany mají určen směr od počátečního do koncového uzlu



Hešovací tabulky kam se podíváš

hash (heš) - otisk; pomocí funkce dostaneme jednoznačný otisk; $O(1)$



tabulky s přímým přístupem, homogení datové pole,

Hešovací funkce

je matematická funkce $f(K)$ (resp. algoritmus), která převádí posloupnost vstupních dat = bitů (d) na posloupnost bitů (relativně) **malé pevné** délky (a),

$$|a| < |d|$$

vlastnosti:

- Nemůže být příliš složitá, aby se tíha prohledávání množiny údajů zbytečně nepřenášela na časově náročný výpočet $f(K)$.
- Heš musí být pro dva odlišné vyhledávací klíče s co největší pravděpodobností odlišný.
- Použití funkce $f(K)$ by mělo zajistit rovnoměrné a náhodné rozmístění prvků v tabulce.

Příklad hešovací funkce

$f(K) = \text{součin ASCII hodnot znaků v řetězci modulo } N$

Spočítejte hash index pro tyto klíče: hello, ahoj, kockopes

Příklad hešovací funkce


$f(K)$ = součin ASCII hodnot znaků v řetězci modulo N

Spočítejte hash index pro tyto klíče: hello, ahoj, kockopes

"hello" $\rightarrow (104*101*108*108*111) \bmod 10 = 6$


"ahoj" $\rightarrow (97*104*111*106) \bmod 10 = 8$

"kockopes" $\rightarrow (107*111*99*107*111*112*101*115) \bmod 10 = 0$




Hešing

Jeden hash pro dva klíče - řetězení



V ideálním případě je binární vyhledávací strom pomalejší, pro případ nejhorší je strom rychlejší.

Heš v kryptografii



Heš v kryptografii

An Example of a Hash Function



Heš v kryptografii

vstupní text	Hash hodnota
Dobry den!	D364965C90C53DBF140
Dobry den, vítám vás na přednášce ze základů forenzních databází. To jste netušili, co všechno se tu dovíte, že?	B26BACAB73C46D844C1

- Jednosměrnost: Z heše nelze zpětně získat původní data. Je to jednosměrná operace.
- Jedinečnost: I drobná změna vstupu vede k úplně jinému výslednému heši.
- Pevná délka výstupu: Bez ohledu na velikost vstupních dat je výstup (heš) vždy stejně dlouhý.

Heš v kryptografii

Ověření integrity dat: Pomocí heše lze zkontrolovat, zda data nebyla během přenosu nebo uložení poškozena nebo změněna.

Zabezpečení hesel: Místo ukládání hesel se ukládají jejich heše. Při přihlášení se porovná zadané heslo s uloženým hešem, což chrání hesla v případě úniku dat.

Šifra (Encryption) - je něco, co lze použít na transformaci textu do něčeho, co nelze přechíst použitím algoritmu a klíče. Ale!! zašifrovaný text lze zase nazpátek dešifrovat použitím stejného klíče (symetrická šifra) nebo jiným klíčem/algoritmem (asimetrická šifra).

Kryptografická hašovací funkce - jakmile jednou zahašujete data, už je nazpátek nedostanete (jednosměrný proces).

Porovnání

Struktura	Přístup k prvku	Vložení	Vyhledání	Poznámka
Pole	$O(1)$	$O(n)$	$O(n)$	pevná délka
Seznam	$O(n)$	$O(1)$	$O(n)$	flexibilní, ale pomalejší
Strom	$O(\log n)$	$O(\log n)$	$O(\log n)$	např. binární, B-strom
Heš	$O(1)$	$O(1)$	$O(1)$	závisí na hashovací funkci
Graf	$O(V+E)$	-	$O(V+E)$	závisí na počtu uzlů a hran


Ukládání dat



Segment a záznam

Segmenty -> záznamy -> soubory -> báze dat

Fyzický záznam na fyzickém mediu



Logický záznam

Student	Předmět	Kruh
---------	---------	------

Paměť

data se ukládají na **lineárním** fyzickém mediu - magnetická páska... HD...
paměť - velmi dlouhý list bajtů

adresa	hodnota
0x00	01001010
0x01	10111010
0x02	01011111
0x03	00100100
0x04	10010111
...	...
0xEF	00110011
0xFF	11001100

adresa - Každé paměťové místo má svou unikátní číselnou adresu

procesor - používá tyto adresy k přesnému určení, kam má data zapsat nebo odkud je má přečíst

adresová směrnice - sada elektrických vodičů přes které jsou adresy přenášeny z CPU do paměti

Metody ukládání

- Postupné uložení dat

Metody ukládání

- Postupné uložení dat
 - sekvenční - podle toho jak přicházejí v čase

Metody ukládání

- Postupné uložení dat
 - sekvenční - podle toho jak přicházejí v čase
 - sériové - nejprve data setřídím a pak uložím od největšího k nejmenšímu

Metody ukládání

- Postupné uložení dat
 - sekvenční - podle toho jak přicházejí v čase
 - sériové - nejprve data setřídím a pak uložím od největšího k nejmenšímu
 - ostatní - např. podle četnosti (PageRank)

Metody ukládání

- Postupné uložení dat
 - sekvenční - podle toho jak přicházejí v čase
 - sériové - nejprve data setřídím a pak uložím od největšího k nejmenšímu
 - ostatní - např. podle četnosti (PageRank)
- Rozptýlené uložení dat
 - pomocnou evidenci volného místa v paměti

Uložení s odkazy

- Uložení s odkazy - při ukládání se provádí dodatečné akce -> přidá se odkaz

Uložení s odkazy

- Uložení s odkazy - při ukládání se provádí dodatečné akce -> přidá se odkaz
 - Odkaz NIL (neukazuje nikam)


Uložení s odkazy

- Uložení s odkazy - při ukládání se provádí dodatečné akce -> přidá se odkaz
 - Odkaz NIL (neukazuje nikam)
 - Odkaz na předchůdce

Uložení s odkazy

- Uložení s odkazy - při ukládání se provádí dodatečné akce -> přidá se odkaz
 - Odkaz NIL (neukazuje nikam)
 - Odkaz na předchůdce
 - Odkaz na souseda

Ukazatel na první
uzel v seznamu →



Uzel = hodnota + ukazatel

Ukazatel v posledním uzlu
obsahuje nulovou adresu
jako příznak, že tento
uzel nemá následníka.

Ukládání s indexy/pomocí klíčů

Ukládání s indexy/pomocí klíčů

688 | Index

Hertz (unit), 73

Hessian matrix, 483, 487–489, 496, 592

Hess–Schaad resonance energy, 615

Heteronuclear diatomics:

MO treatment of, 393–395

VB treatment of, 396

HF method (*see* Hartree–Fock method)

Hidden variables, 186

Higher-level correction, 573

Hirshfeld-I charges, 464

HMO method (*see* Hückel molecular-orbital (HMO) method)

Hoffmann, R., 621, 622

Hybridization, 365, 392, 475, 585, 586

Hybridizational invariance, 624

Hydrogen atom, 127–147 (*see also* Hydrogen atom wave functions)

degeneracy in, 134–135, 268, 315

energy levels of, 134

hyperfine splitting in, 320

quantum numbers for, 134–135

reaction with H_2 , 593–594

and spin, 268

terms of, 315

and virial theorem, 418

Hydrogen-atom wave functions, 135–147

for ground state, 135

Ukládání s indexy/pomocí klíčů

688 | Index

Hertz (unit), 73

Hessian matrix, 483, 487–489, 496, 592

Hess–Schaad resonance energy, 615

Heteronuclear diatomics:

MO treatment of, 393–395

VB treatment of, 396

HF method (*see* Hartree–Fock method)

Hidden variables, 186

Higher-level correction, 573

Hirshfeld-I charges, 464

HMO method (*see* Hückel molecular-orbital (HMO) method)

Hoffmann, R., 621, 622

Hybridization, 365, 392, 475, 585, 586

Hybridizational invariance, 624

Hydrogen atom, 127–147 (*see also* Hydrogen atom wave functions)

degeneracy in, 134–135, 268, 315

energy levels of, 134

hyperfine splitting in, 320

quantum numbers for, 134–135

reaction with H₂, 593–594

and spin, 268

terms of, 315

and virial theorem, 418


Hydrogen-atom wave functions, 135–147

záznam ve tvaru


vyhledávací klíč	ukazatel
------------------	----------

databázové indexy slouží ke zrychlení přístupu k datům, nesmí se to přehnat

Stromové uspořádání indexů




Vyváženost



Složitost O

funkce / n	10	20	50	100	1000	10^6
$\log_2 n$	3.3 ns	4.3 ns	4.9 ns	6.6 ns	10.0 ns	19.9 ns
n	10 ns	20 ns	50 ns	10 ns	1 μ s	1 ms
$n \log_2 n$	33 ns	86 ns	282 ns	664 ns	10 μ s	20 ms
n^2	100 ns	400 ns	900 ns	100 μ s	1 ms	1000 s
n^3	1 μ s	8 μ s	27 μ s	1 ms	1 s	10^9 s
2^n	1 μ s	1 ms	1 s	10^{21} s	10^{292} s	∞
$n!$	3 ms	10^9 s	10^{23} s	10^{149} s	10^{2558} s	∞

Porovnání funkcí složitosti



Řazení

Máme datovou strukturu (lineární, strom,..),
uloženou v paměti,
víme jak porovnávat algoritmy,
před vyhledáváním si data seřadíme.

Skupinová práce

Navrhněte algoritmy pro třídění dat.

13	16	8	4	16	17	9	10	14	6	5	15	12	11
↓													
4	5	6	7	8	9	10	11	12	13	14	15	16	17


Algoritmy řazení

<https://brilliant.org/wiki/sorting-algorithms/>

- **Vkládáním** (insert) – v řazené posloupnosti prvků se postupně berou jednotlivé prvky a vkládají se na správné místo v budované seřazené posloupnosti.
- **Výběrem** – nalezne vždy nejmenší z (zbývajících neseřazených) prvků a umístí na konec postupně budované posloupnosti.
- **Záměnou** (bubble) – algoritmy vyberou dvojici prvků, které jsou ve špatném pořadí, a tyto prvky navzájem zamění.
- **Slučováním** (merge) - vstupní posloupnost prvků rozdělí na části, které seřadí; seřazené části se poté sloučí tak, aby výsledná posloupnost byla seřazená.
- **Rychlé řazení výměnou** (Quicksort) - rozděl a panuj
- **Haldou** - vyvážený binární strom - jen pro trpělivé

Vlastnost algoritmů řazení

stabilní - relativní pořadí prvků se shodným klíčem se v procesu řazení nemění



přirozený - algoritmus rychleji zpracuje seřazenou množinu než neseřazenou

Přehled řazení

<https://www.toptal.com/developers/sorting-algorithms>

název	max. složitost	stabilní	přirozený
Vkládáním	$O(n^2)$	ano	ano
Výběrem	$O(n^2)$	ne	ne
Záměnou	$O(n^2)$	ano	ano
Slučováním	$O(n \log n)$	ano	ano
R. výměnou	$O(n^2)$	ne	ne
Haldou	$O(n \log n)$	ne	ne

Skripta, stránky a materiály

ZÁKLADNÍ ALGORITMY. ARNOŠT VEČERKA. Univerzita Olomouc

<https://runestone.academy/ns/books/published/welcomecs/ComputerArchitecture/Memory>

<https://homel.vsb.cz/~hom50/DATABAZE/SLBDBASE/DBS3METU.HTM>

[https://cs.wikipedia.org/wiki/Index_\(datab%C3%A1ze\)](https://cs.wikipedia.org/wiki/Index_(datab%C3%A1ze))

<https://www.toptal.com/developers/sorting-algorithms>

<https://www.root.cz/clanky/vyuziti-databazovych-indexu/>

<https://www.vox.com/a/internet-maps>

<https://www.elonx.cz/vse-o-konstelaci->

[starlink/https://bytebytego.com/guides/10-key-data-structures-we-use-every-day/](https://bytebytego.com/guides/10-key-data-structures-we-use-every-day/)