

Vyhledávání:


- ▶ interní
- ▶ externí – uvažujeme, že získáváme informaci z velkých dat, které se vyskytují na uložiscích s přímým přístupem.

Stromy se hodí k externímu vyhledávání, pokud zvolíme vhodnou formu jejich reprezentace.

Při použití naivního přístupu potřebujeme asi $\lg n$ přístupů.
(přístup = načtení uzlu).

Takže pro 1 000 000 uzlů 20 přístupů na disk.

ukradený obrázek hned na prvním slajdu.



Pokud ovšem budeme načítat 7 uzlů současně, budeme potřebovat jen asi 1/3 přístupů.

Seskupení uzlů do *stránek* (pages) o sedmi uzlech z toho vlastně udělá oktonární strom.

- ▶ pokud budeme používat 128-ární větvení, stačí při milionu prvku asi 3 přístupy.
- ▶ kořenovou stránku můžeme udržovat stále v interní paměti.
- ▶ Jen dvě reference v interní paměti jsou potřeba (kořen a aktuální uzel), takže celkově 254 klíčů.

Nechceme mít libovolnou velikost stránky, protože

- ▶ velikost interní paměti je omezená,
- ▶ načíst velkou stránku trvá dlouho.


B-stromy

1970 – R. Bayer & E. McCreight, M. Kaufman

Binární strom řádu m je strom, který splňuje následující vlastnosti

1. Každý uzel má nejvýše m uzlů.
2. Každý uzel, mimo kořene a listů, má alespoň $m/2$ potomků.
3. Kořen má alespoň 2 potomky (pokud není listem)
4. Všechny listy jsou na stejné úrovni a nenesou žádné informace.
5. Všechny nelistové uzly s k -uzly obsahují $k - 1$ klíčů.


Uzel, který obsahuje j klíčů, $j + 1$ ukazatelů může být reprezentován jako




kde $K_1 < K_2 < \dots < K_j$ a ukazatel P_i ukazuje na podstrom s klíči mezi K_i a K_{i+1} .

Vyhledávání je přímočaré

Vkládání je snadné (a studentům známé)



Rozlomení (split) uzlu (obecně),



- ▶ vkládání zachovává vlastnosti B-stromu

Čas vyhledávání

Kolik uzlů musíme načíst v nejhorším případě, když hledáme v B-stromu řádu m .

Předpokládejme, že je v něm n klíčů, a tedy $n+1$ listů je na úrovni l .

Pak počet uzlů na úrovni 1,2,3... je nejméně

$2, 2^{\lceil m/2 \rceil}, 2^{\lceil m/2 \rceil^2}, \dots$

takže

$$n + 1 \geq 2^{\lceil m/2 \rceil^{l-1}}$$

A tedy

$$l \leq 1 + \log_{m/2} \left(\frac{n+1}{2} \right)$$

Potřebujeme přistoupit k nejvýše l uzlům.

Když je nový klíč vkládán, můžeme rozložit až $\lceil m/2 \rceil$ uzlů.

Pokud máme p interních uzlů, existuje nejméně $1 + (\lceil m/2 \rceil - 1)(p - 1)$ klíčů, takže

$$p \leq 1 + \frac{n - 1}{\lceil m/2 \rceil - 1}$$

během vložení.

Z toho plyne, že průměrný počet splitů při budování stromu o n klíčích je méně, než

$$\frac{1}{\lceil m/2 \rceil - 1}$$

pro každé vkládání.

Varianty

všechny ukazatele v hloubce $l - 1$ jsou NIL, žádné jiné nejsou NIL. Můžeme odstranit všechny tyto ukazatele a použít jinou hodnotu m pro nejnižší patro.

Vlastně bychom mohli mít různé m pro každé patro a zobecnit na B-strom řádu $m_1, m_2, \dots$. Algoritmus vkládání zůstane v podstatě stejný.

Totéž můžeme ještě rozvinout a mít úplně jiný formát uzlu v každém patře.

Někdy klíče tvoří jenom malou část, pak by byla chyba ukládat celé záznamy v uzlech blízko kořene – snižuje se tím m


Můžeme prvky duplikovat a data záznamů přesunout až do listů.

Pokud ještě spojíme všechny listy do seznamu, dostáváme B^+ -strom.

B-stromy s klíči proměnlivé délky – stačí udržovat uzel polonaplněný.

B-stromy s přetečením (**overflow**) – přeplněné uzly přetékají do sourozenců. Pokud jsou naplněny uzel i sourozenec, splitneme jejich sjednocení do potomků. A navíc musí být větší kořen.

T H I S _ I S _ T H E _ H O U S E _ T H A T _ J A C K _ B U I L T _ ?
101110100001001101100000010011011000000101110100000101000001000010000110001100010100000101101000000010111000000010110000100101101101111111



Digitální vyhledávání (digital searching)

Namísto porovnávání klíčů můžeme využít jejich reprezentace jako posloupnosti čísel nebo znaků abecedy.

Trie je vlastně M -ární strom, jehož prvky jsou M -místné vektory s komponentami odpovídajícími



Algoritmus vyhledávání v trie – známe z KMI/FJAA

	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)
A		A				I			
B	(2)				(10)				WAS
C	(3)								
D									
E			BE		(11)				
F	(4)						OF		
G									
H	(5)							(12)	WHICH
I	(6)				HIS				WITH
J									
K									

Nějaká pozorování ve srovnání s optimálním stromem

- ▶ Zabírá to moc paměti
(tabulka o 360 políčkách reprezentuje 31 klíčů;
binární strom by zabral 62 „políček“).
- ▶ Úspěšné hledání zabere stejně, neúspěšné je v trie kratší.
- ▶ V některých případech to tuto výhodu ztrácí
(rozdíl v posledním písmeni).

Co s tím teda...




Binární případ

Uvažujme $M = 2$

- ▶ vyhledávání v digitálním stromu
- ▶ PATRICIA

Vyhledávání v digitálním stromu




Patricia (Practical Algorithm To Retrieve Information Coded In Alphanumeric)

Algoritmus vhodný pro extrémně dlouhé klíče různé délky.

Donald R. Morrison, JACM 15 (1968) 514-534


G. Gwehenberger, Elektronische Rechenanlagen 10 (1968), 223-226

T H I S _ I S _ T H E _ H O U S E _ T H A T _ J A C K _ B U I L T ?
10111010000100110110000001001101100000101110100000100000100001100010110000101000001011101000000011011100000010110000000000101100001001011011011111111



Strom, který Patricia používá pro hledání, se skládá z hlavičky a $n - 1$ uzlů, a uzly obsahují tato pole:

- ▶ KEY – ukazatel do textu.
- ▶ LLINK, RLINK – ukazatele na podstromy
- ▶ LTAG, RTAG – bity, které říkají, jestli LLINK a RLINK jsou ukazatele na potomky, nebo na předky uzlů.
- ▶ SKIP – číslo, které říká, kolik bitů se má při hledání přeskočit.



Algoritmus vyhledávání PATRICIA

Vstup: text, strom ve tvaru, jako na předchozím slajdu, klíč K

Výstup: místo v textu, které začíná na K

P1 [Inicializace] $P \leftarrow \text{HEAD}$, $j \leftarrow 0$

P2 [Vlevo] $Q \leftarrow P$

$P \leftarrow \text{LLINK}(Q)$

Pokud $\text{LTAG}(Q)=1$, pokračuj P6

P3 [Přeskoč bity] $j \leftarrow j + \text{SKIP}(P)$, pokud $j > n$, pokračuj P6

P4 [Testuj bit] Pokud j -tý bit K je 0, pokračuj P2, jinak pokračuj P5

P5 [Vpravo] $Q \leftarrow P$

$P \leftarrow \text{RLINK}(Q)$

Pokud $\text{RTAG}(Q)=0$, pokračuj P3

P6 [Porovnání] Porovnej K s klíčem, který začíná na pozici $\text{KEY}(P)$.

Pokud jsou stejné, skonči úspěchem, jinak skonči neúspěchem.

Algoritmus vkládání PATRICIA

Vstup: PATRICIA a vkládaný klíč K

Výstup: updatovaná PATRICIA

Pokud je PATRICIA prázdná:

$LLINK(HEAD) \leftarrow HEAD, LTAG(HEAD) \leftarrow 1.$

jinak:

Proved' neúspěšné vyhledávání — musí skončit neúspěchem v kroku P6.

Předpokládejme, že K se shoduje s nalezeným klíčem v prvních l bitech a liší se v $l + 1$ bitu. K tam má bit b , nalezený klíč tam má bit $1 - b$

Zopakuj vyhledávání s tím te se hledá jen prvních l bitů z K (nemusíme provádět P6).

Pak nastavíme

$R \leftarrow$ alokuj nový uzel

$\text{KEY}(R) \leftarrow$ pozice K v textu

Pokud $\text{LLINK}(Q) = P$ pak

$\text{LLINK}(Q) \leftarrow R$

$t \leftarrow \text{LTAG}(Q)$

$\text{LTAG}(Q) \leftarrow 0$

jinak

$\text{RLINK}(Q) \leftarrow R$

$t \leftarrow \text{RTAG}(Q)$

$\text{RTAG}(Q) \leftarrow 0.$

Pokud $b = 0$ pak

$$\text{LTAG}(R) \leftarrow 1$$

$$\text{LLINK}(R) \leftarrow R$$

$$\text{RTAG}(R) \leftarrow t$$

$$\text{RLINK}(R) \leftarrow P$$

jinak

$$\text{RTAG}(R) \leftarrow 1$$

$$\text{RLINK}(R) \leftarrow R$$

$$\text{LTAG}(R) \leftarrow t$$

$$\text{LLINK}(R) \leftarrow P.$$

Pokud $t = 1$ pak

$$\text{SKIP}(R) \leftarrow 1 + l - j$$

jinak

$$\text{SKIP}(R) \leftarrow 1 + l - j + \text{SKIP}(P)$$

$$\text{SKIP}(P) \leftarrow j - l - 1.$$