



PA152: Efektivní využívání DB
6. Hašování

Vlastislav Dohnal

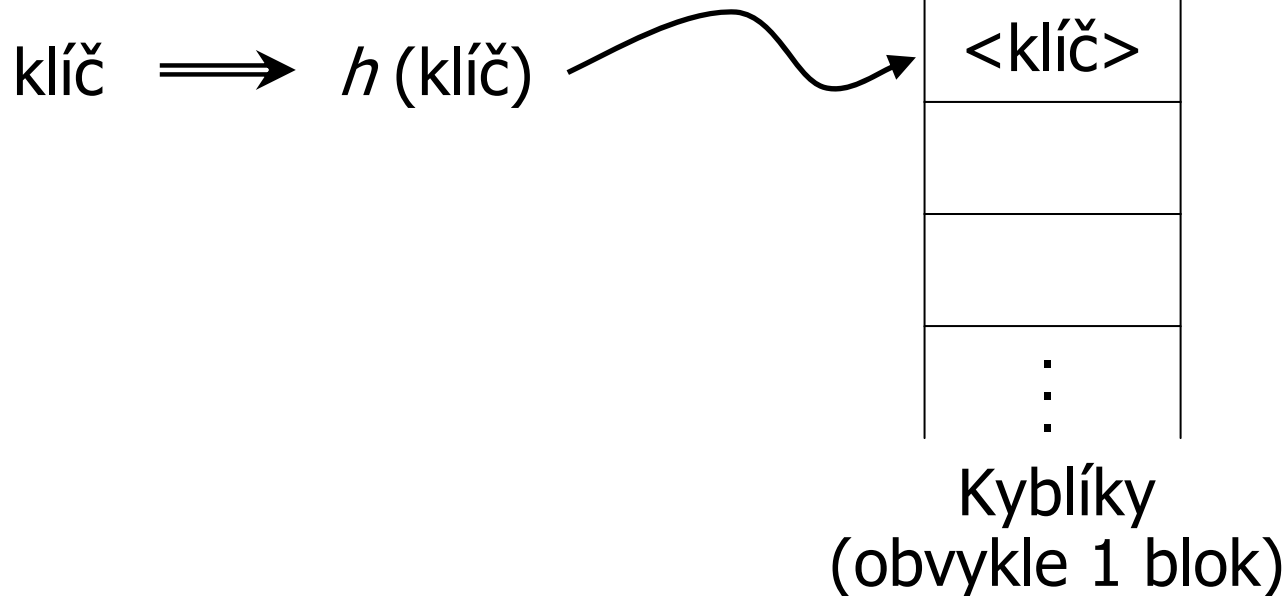
Poděkování

- Zdrojem materiálů tohoto předmětu jsou:
 - Přednášky CS245, CS345, CS345
 - Hector Garcia-Molina, Jeffrey D. Ullman, Jennifer Widom
 - Stanford University, California

Hašování

- Transformace klíče na adresu
 - Funkce vracející adresu pro vstupní klíč

- Idea:




Možnosti implementace

■ Přímá adresace

□ Adresa záznamu

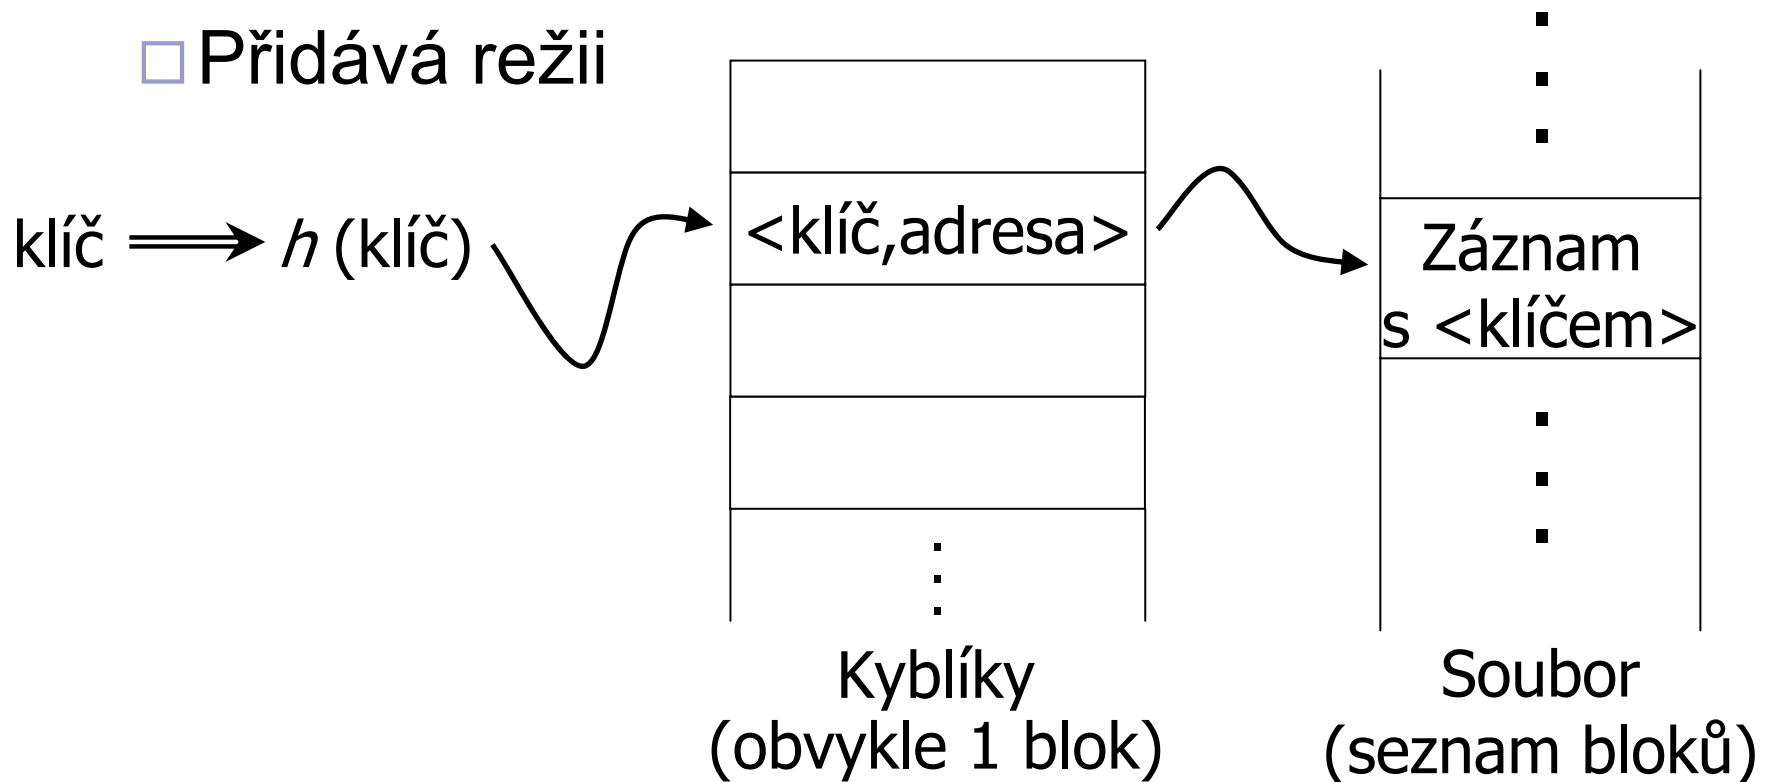
■ Obvykle adresa bloku



Možnosti implementace

■ Nepřímá adresace

- Vhodné pro sekundární indexy
- Přidává režii



Příklad hašovací funkce

- Klíč je řetězec znaků
 - n bajtů
- Adresní prostor
 - B kyblíků
- Hašovací funkce $h(x_0x_1\dots x_{n-1})$
 - $(x_0+x_1+\dots+x_{n-1}) \bmod B$
 - $(x_0*31^{n-1}+x_1*31^{n-2}+\dots+x_{n-1}) \bmod B$
 - Lze i na proměnlivou délku

Hašovací funkce

■ Požadavky:

□ Rovnoměrná

- Stejné obsazení všech kyblíků

□ Náhodná

- Bez korelace vstupu a výstupu

■ „Velká věda“ → speciální literatura

□ Dobrá funkce je alespoň rovnoměrná

Použití kyblíků

- Kyblík má větší kapacitu než 1
 - Uspořádat klíče?
 - Ano, pokud chceme zrychlit přístup
 - Ano, pokud je málo aktualizací
 - Ne, pokud je hodně aktualizací

Základní pojmy

- Hašovací funkce

- Kolize

- Na vypočtené adrese je již něco uloženo
- Není problém, pokud je lze uložit více klíčů

- Přetečení

- Kapacity kyblíku je naplněna
- Přetoková oblast

- Statické vs. dynamické hašování

- Podle změny velikosti adresového prostoru

Řešení kolizí

■ Uzavřené hašování


- Vypočtená adresa je fixní
- Při přetečení vytvoř nový kyblík (přetoková oblast)
 - Řetězení přetokových oblastí

■ Otevřené hašování

- Existence kolizní funkce
 - Lineární, kvadratické, dvojité hašování
 - Viz Organizace souborů

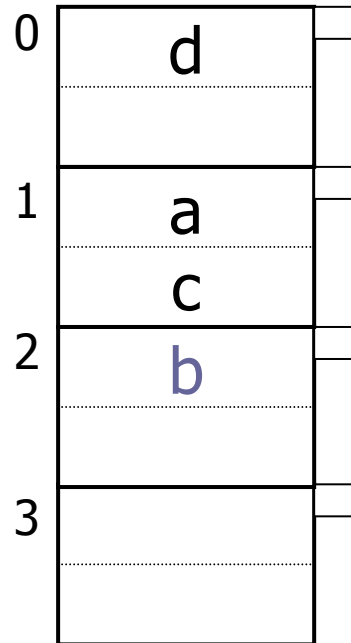
Příklad

- Statické uzavřené hašování
 - Kolize pomocí přetokových oblastí
 - Kapacita kyblíku = 2 klíče



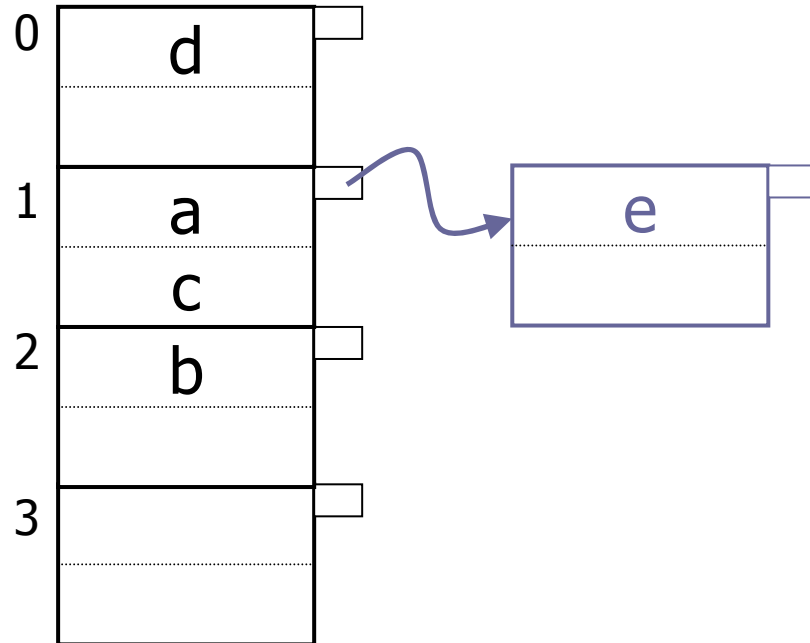
Příklad vkládání

- $h(b) = 2$



Příklad vkládání

- $h(e) = 1$

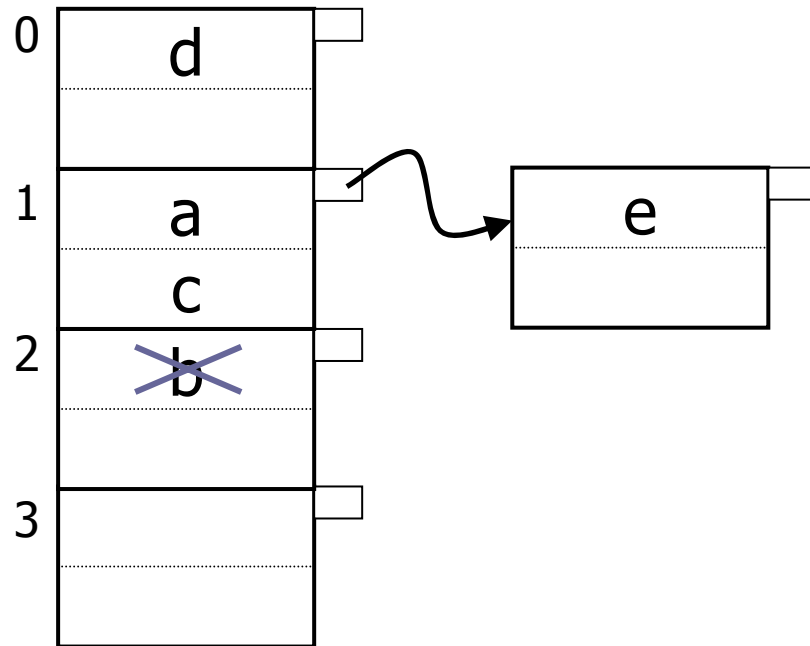


Příklad mazání

- Uvolňovat přetokové oblasti

- Smaž

 - b

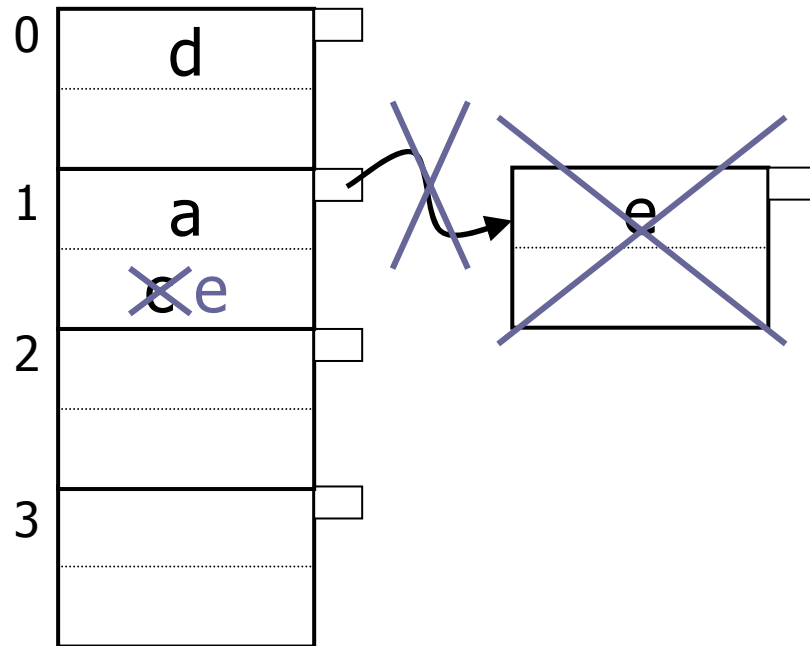


Příklad mazání

- Uvolňovat přetokové oblasti

- Smaž

- c




Příklad mazání

- Uvolňovat přetokové oblasti

- Smaž

 - a



Empirické zkušenosti

- Zaplnění udržovat mezi 50% a 80%
 - Zaplněnost = počet klíčů / max. kapacita
 - < 50% – plýtvání místem
 - \geq 80% – příliš mnoho kolizí
 - Přetokové oblasti zpomalují vyhledávání i vkládání

Dynamická data

■ Statické hašování

- Přetoky → reorganizace

- Tj. vytvoření nové hašovací funkce

■ Dynamické hašování


- Rozšiřitelné

- Lineární

Rozšiřitelné hašování

■ Idea:

- Využití pouze několika prvních bitů adresy
- Přidání další tabulky – adresář
 - Velikost je mocnina 2




Rozšiřitelné hašování: vkládání

■ Najdi kyblík

- je volné místo → ok
- není → rozštěpení kyblíku
 - přerozdělení obsahu

■ Vložení

- 0001
- 1010




Rozšiřitelné hašování: vkládání

■ Vložení

- 1010


- Rozštěpení kyblíku



Rozšiřitelné hašování: vkládání

■ Vložení 1011

- Adresář je plný → zdvojnásobení (přidání bitu)



Rozšiřitelné hašování: mazání

■ Mazání klíče

- Smaž klíč

- Kyblík je prázdný

- Nedělej nic → předpoklad nového vkládání

- Sloučení sousedních kyblíků

- Mající stejný prefix o jeden bit kratší

- Může být i zmenšen adresář

Rozšiřitelné hašování: hodnocení

■ Výhody

- Měnící se data
- Méně plýtvá místem (než statické hašování)
- Lokální reorganizace


■ Nevýhody

- Další úroveň nepřímých odkazů
 - Ok, pokud je adresář v paměti
- Adresář se zdvojnásobuje
 - Nemusí se vejít do paměti
 - Ale kyblíky rostou lineárně!

Lineární hašování

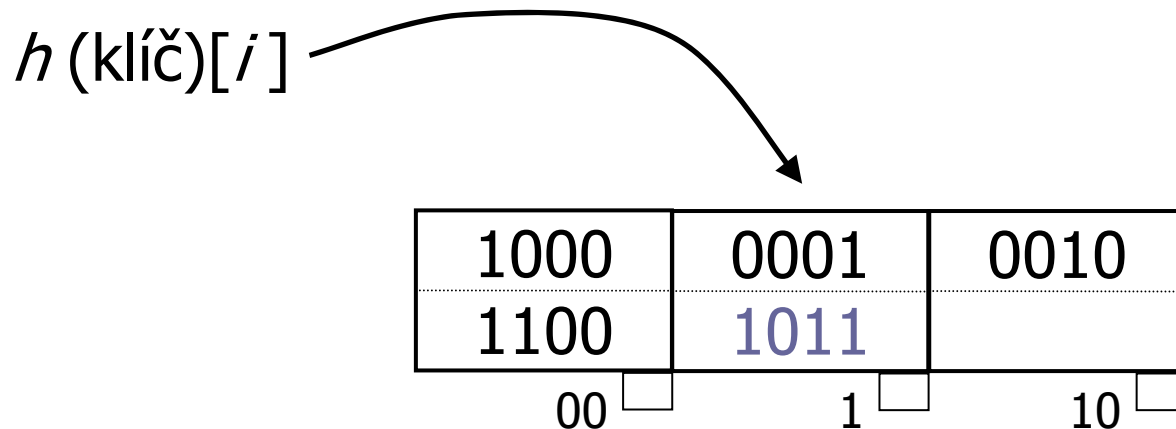
■ Idea:

- Využití pouze několika *posledních* bitů adresy
- Žádný adresář
- Soubor roste lineárně



Lineární hašování: vkládání

- Parametry: $i=2$, $n=3$
- Vlož 1011
 - $h(1011)[2] = 11 = m$
 - Pokud $m < n$, vlož do kyblíku m
 - Jinak vlož do kyblíku $m - 2^{i-1}$




Lineární hašování: vkládání

■ Vlož 1001


□ $h(1001)[2] = 01$

□ Není místo → přetoková oblast



Lineární hašování: štěpení kyblíku

- Při vkládání kontroluj naplnění
 - >80%, pak rozděl kyblík
 - Resp. přidej nový → adresa je $1abcd\dots z$
 - Rozděl data v kyblíku $0abcd\dots z$ mezi $[01]abcd\dots z$



Lineární hašování

■ Vkládání nového klíče

- Může vést k přetokové oblasti
- Může způsobit větší naplnění než 80%
 - Proveďte se štěpení kyblíku
 - Štěpený kyblík může být různý od kyblíku, do kterého se vkládá!
- Po přidání 2^i -tého kyblíku, zvětší i
 - Tj. počet kyblíků překročí 2^i

Lineární hašování: hodnocení

■ Výhody

- Měnící se data
- Méně plýtvá místem (než statické hašování)
- Lokální reorganizace
- Žádná dodatečná překladová tabulka


■ Nevýhody

- Přetokové oblasti

Lineární hašování: příklad

■ „Chybná“ data

- Prvních x bitů nerozliší klíče



- Jeden kyblík má všechna data, ostatní nic
 - Faktor naplnění vysoký → stále se štěpí

Hašování vs. indexování

■ Hašování

- Vhodné pro přesné dotazy
SELECT ... WHERE a=5

■ Indexování

- Vhodné pro rozsahové dotazy
SELECT ... WHERE a>5

Bitmapový index

- Kolekce bitových polí
 - Pro každou hodnotu je jedno pole
 - Délka pole je počet záznamů
- Vhodné pro atributy s „malým“ počtem hodnot

Bitmapový index: příklad

- Relace R(F,G)

F	G
30	foo
30	bar
40	baz
50	foo
40	bar
30	baz

- Bitmapový index pro G

Value	Vector
foo	100100
bar	010010
baz	001001

Bitmapový index: vlastnosti

■ Nevýhody

□ Paměťová náročnost

- Pokud je klíč primárním klíčem, pak zabírá n^2 bitů

□ Aktualizace záznamů

- Vkládání, mazání
- Nová hodnota → nové bitové pole

■ Výhody

□ Rychlé operace na bitech (AND, OR)

□ Lze použít pro rozsahové dotazy

□ Snadné kombinace více indexů dohromady

Bitmapový index: komprese

■ Zmenšení polí

- Málo 1, hodně 0
- Obvykle Run-Length Encoding (RLE)
 - Sekvence i nul následovaná jedničkou
 - Kódování je uložení čísla i binárně

■ Příklad

- Kód: 11101101001011
- Sekvence: 00000000000000110001
 - Najdi první nulu → počet bitů pro uložení i
 - Načti i

■ Problém

- Sekvence vždy končí jedničkou!
- Chybějící nuly lze doplnit podle počtu záznamů

Bitmapový index: operace

- Bitové operace
 - AND, OR
- RLE řetězce
 - Dekomprimovat → snadné
 - Bez dekomprese
 - Složitější algoritmus, ale možné
 - AND: čísla i v kódech se musí shodovat
 - OR: analogicky...

Bitmapový index: použití

- Otázky pro efektivní použití:
 1. Nalezení bitového pole pro konkrétní hodnotu klíče
 2. Mám bitové pole, jak načtu záznamy?
 3. Aktualizace záznamů, co s indexem?

Bitmapový index: řešení

■ Ad 1:

- Pro hodnotu klíče máme bitové pole

- B⁺-strom pro hodnoty klíče
- V listu odkaz na bitové pole

- Uložení bitových polí

- Záznamy variabilní délky

■ Ad 2:

- Nalezení záznamu x (pořadí záznamu)

- Sekvenční soubor → snadné
- Sekundární index pro čísla záznamů

Bitmapový index: řešení

■ Ad 3:

□ Čísla záznamů jsou fixní

■ Mazání záznamu

→ náhrobek v souboru

→ změna na nuly ve všech bitových polích

■ Vkládání záznamu

→ přidej na konec souboru (nové číslo záznamu)

→ do správného bitového pole připojit 1

→ pole nemusí existovat, vytvoř nové

□ Čísla záznamů nejsou fixní

■ Reorganizace všech polí

■ Málo používaná verze

Víceklíčový index

- Index pro více atributů

- Důvod:


```
SELECT ... WHERE oddělení='Hračky'  
AND plat < 10000
```

- Řešení

- Index pro jeden atribut + filtrování
- Oddělené indexy pro atributy + průnik vyhovujících
- Index v indexu
- Spojení klíčů v jeden

Index pro jeden atribut



- `SELECT ... WHERE oddělení='Hračky'`
`AND plat < 10000`
- Index pro oddělení
 - Nalezené záznamy filtruj pomocí *plat < 10000*



Nezávislé indexy

- Index pro oddělení
- Index pro plat
- Každý index vrátí seznam kandidátů
 - Průnik → výsledek dotazu

oddělení='Hračky'

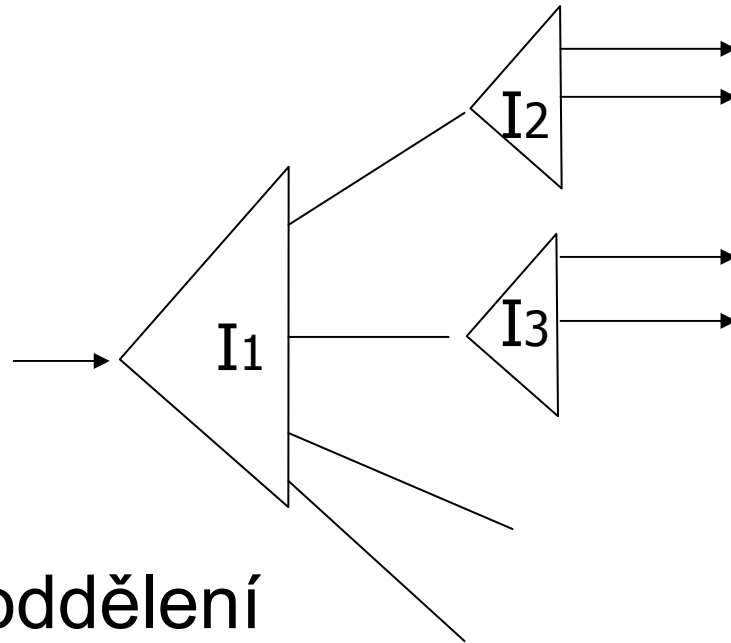


plat < 10000

Index v indexu

■ Index pro první atribut


- V listu je odkaz na index pro druhý atribut



- I_1 pro oddělení
- I_2 pro plat obsahuje pouze záznamy se stejným oddělením

Index v indexu: příklad

- `SELECT ... WHERE oddělení='Hračky'`
`AND plat < 10000`



Index v indexu

- Pro které dotazy je použitelný?

- SELECT ... WHERE

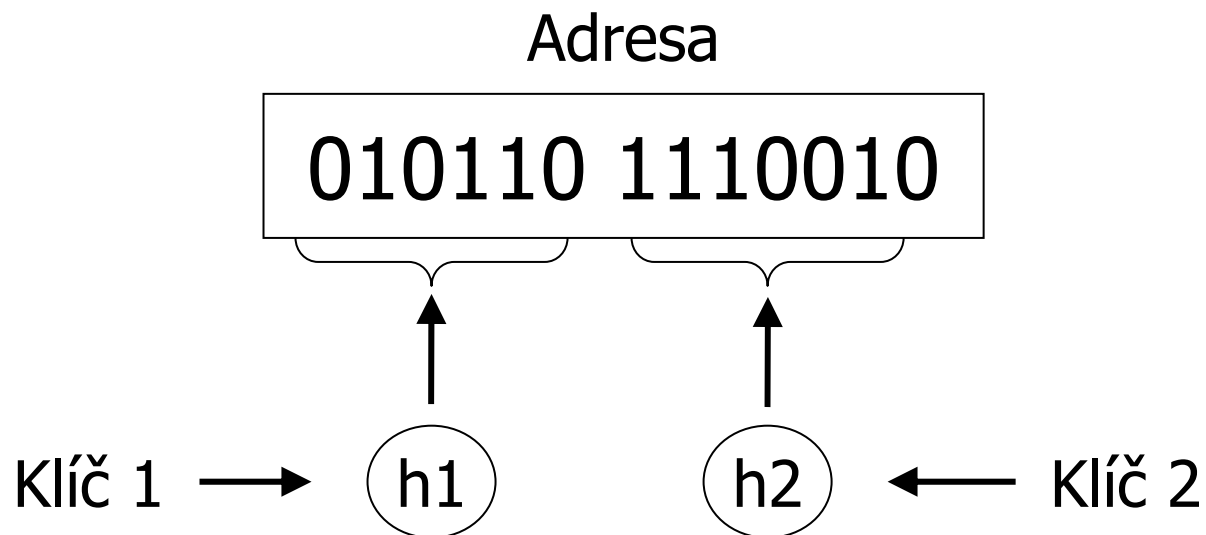
- oddělení = 'Hračky' AND plat = 10000
 - oddělení = 'Hračky' AND plat ≥ 10000
 - oddělení = 'Hračky'
 - plat = 10000

Spojení klíčů v jeden

- Podobné indexu pro jeden klíč
 - Hodnota klíče je spojená
 - Spojení řetězců, vynásobení čísel, ...
- V indexování se příliš nepoužívá
- V hašování tzv. dělená hašovací funkce
 - Partitioned hash function

Dělená hašovací funkce

- Dva klíče
- Idea:



Dělená hašovací funkce: příklad

■ Oddělení

$h_1(\text{Elektro}) = 0$

$h_1(\text{Hračky}) = 1$

$h_1(\text{Zahrada}) = 1$

■ Plat

$h_2(10000) = 01$

$h_2(20000) = 11$

$h_2(30000) = 10$

$h_2(40000) = 00$

■ Záznamy ke vložení

□ $\langle \text{Petr}, \text{Elektro}, 10000 \rangle$

□ $\langle \text{Jan}, \text{Hračky}, 10000 \rangle$

□ $\langle \text{Alice}, \text{Zahrada}, 30000 \rangle$

000	
001	$\langle \text{Petr} \rangle$
010	
011	
100	
101	$\langle \text{Jan} \rangle$
110	$\langle \text{Alice} \rangle$
111	

Dělená hašovací funkce: příklad

■ Oddělení

$h_1(\text{Elektro}) = 0$

$h_1(\text{Hračky}) = 1$

$h_1(\text{Zahrada}) = 1$

■ Plat

$h_2(10000) = 01$

$h_2(20000) = 11$

$h_2(30000) = 10$

$h_2(40000) = 00$

■ Najdi zaměstnance

□ z oddělení hraček a platem 40000

000	<Pavel> <Lukáš>
001	<Petr>
010	<Marie>
011	
100	<Anna>
101	<Jan>
110	<Alice>
111	<Veronika>

Dělená hašovací funkce: příklad

■ Oddělení

h1(Elektro) =0

h1(Hračky) =1

h1(Zahrada) =1

■ Plat

h2(10000) =01

h2(20000) =11

h2(30000) =10

h2(40000) =00

■ Najdi zaměstnance

s platem 30000

000	<Pavel> <Lukáš>
001	<Petr>
010	<Marie>
011	
100	<Anna>
101	<Jan>
110	<Alice>
111	<Veronika>

Dělená hašovací funkce: příklad

■ Oddělení

h1(Elektro) =0

h1(Hračky) =1

h1(Zahrada) =1

■ Plat

h2(10000) =01

h2(20000) =11

h2(30000) =10

h2(40000) =00

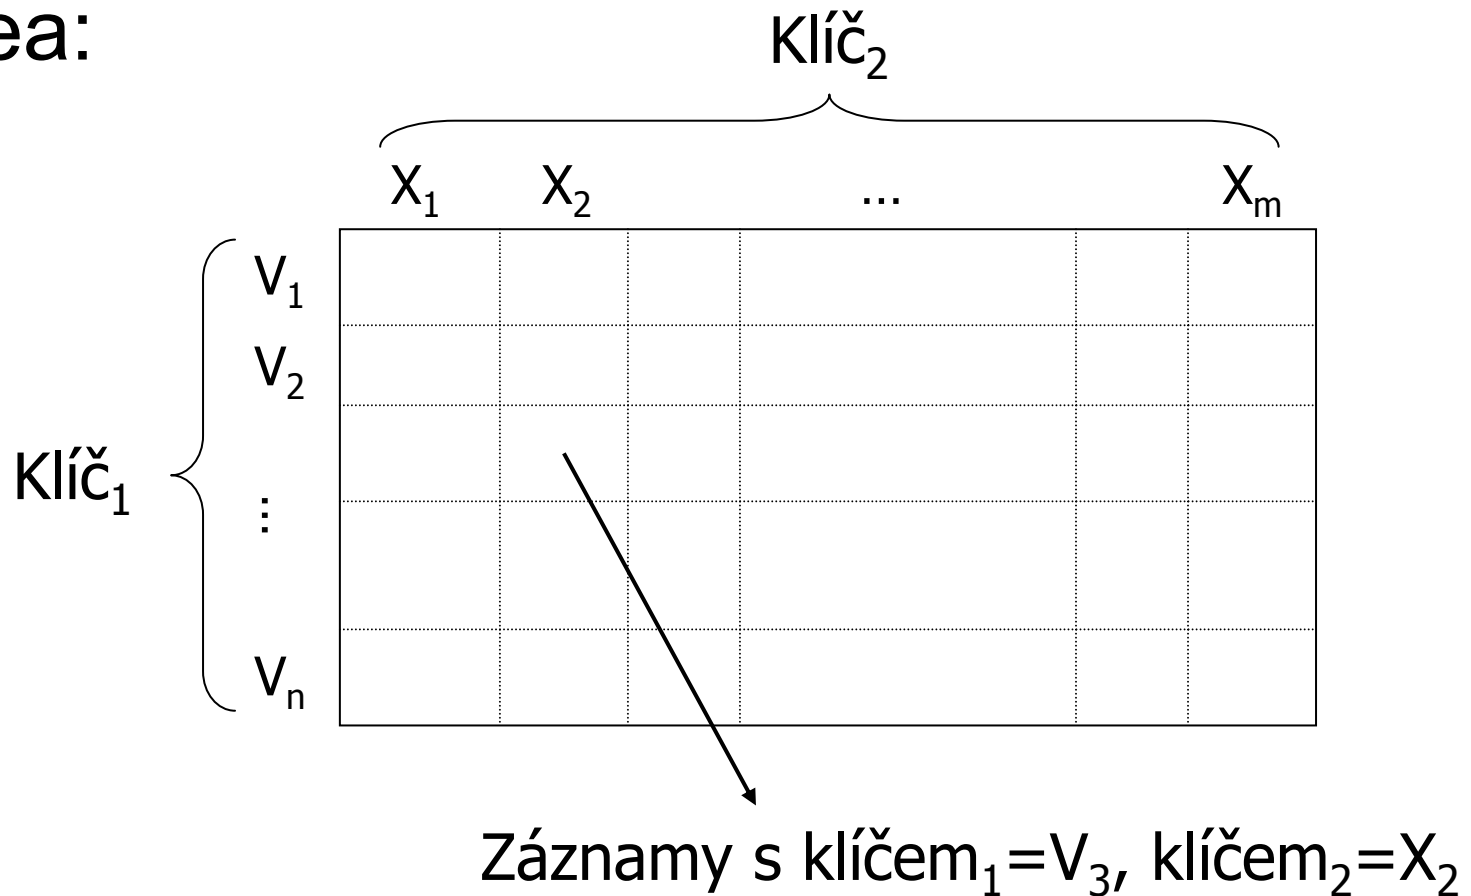
■ Najdi zaměstnance

□ z oddělení hraček

000	<Pavel> <Lukáš>
001	<Petr>
010	<Marie>
011	
100	<Anna>
101	<Jan>
110	<Alice>
111	<Veronika>

Jiný víceklíčový index

- Grid (mřížka)
- Idea:



Grid: vlastnosti

■ Rychlé pro přesné dotazy

- klíč₁ = V_i \wedge klíč₂ = X_j

- klíč₁ = V_i

- klíč₂ = X_j


■ Rozsahové dotazy

- klíč₁ $\geq V_i$ \wedge klíč₂ $< X_j$

- Vznikne čtvercová oblast

Grid: implementace

- Jak ukládat mřížku na disku
 - Jako pole




- Nevýhoda

- Potřeba pevné délky pro výpočet indexu políčka $\langle V_x, X_y \rangle$

Grid: implementace

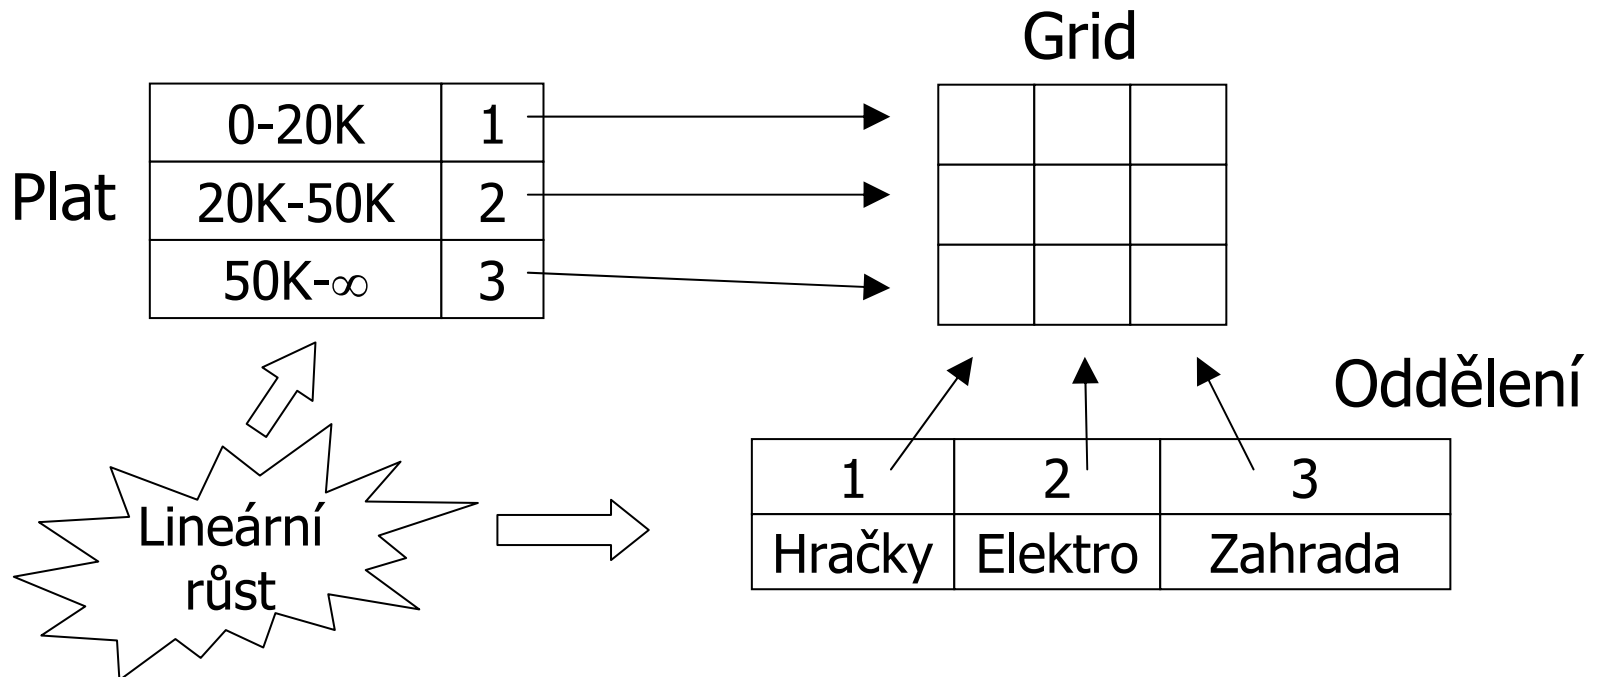
- Použití kyblíků, tj. nepřímé adresování
 - Políčko mřížky odkazuje na kyblík



- Nyní je mřížka pevné velikosti
 - Ovšem přibyla režie s odkazy

Grid: definice mřížky

- Analýzou dat a požadavků na hledání
 - Zjistíme rozměry mřížky
 - Políčko mřížky může být i interval
 - Např. číselné domény



Grid index: hodnocení

■ Výhody

- Vhodné pro víceklíčové indexy

■ Nevýhody

- Mřížka je pevná, zabírá místo
- Volba rozsahů mřížky → rovnoměrné rozdělení dat