



OSNOVE RAČUNALNIŠKE ARHITEKTURE II

10 Predpomnilnik

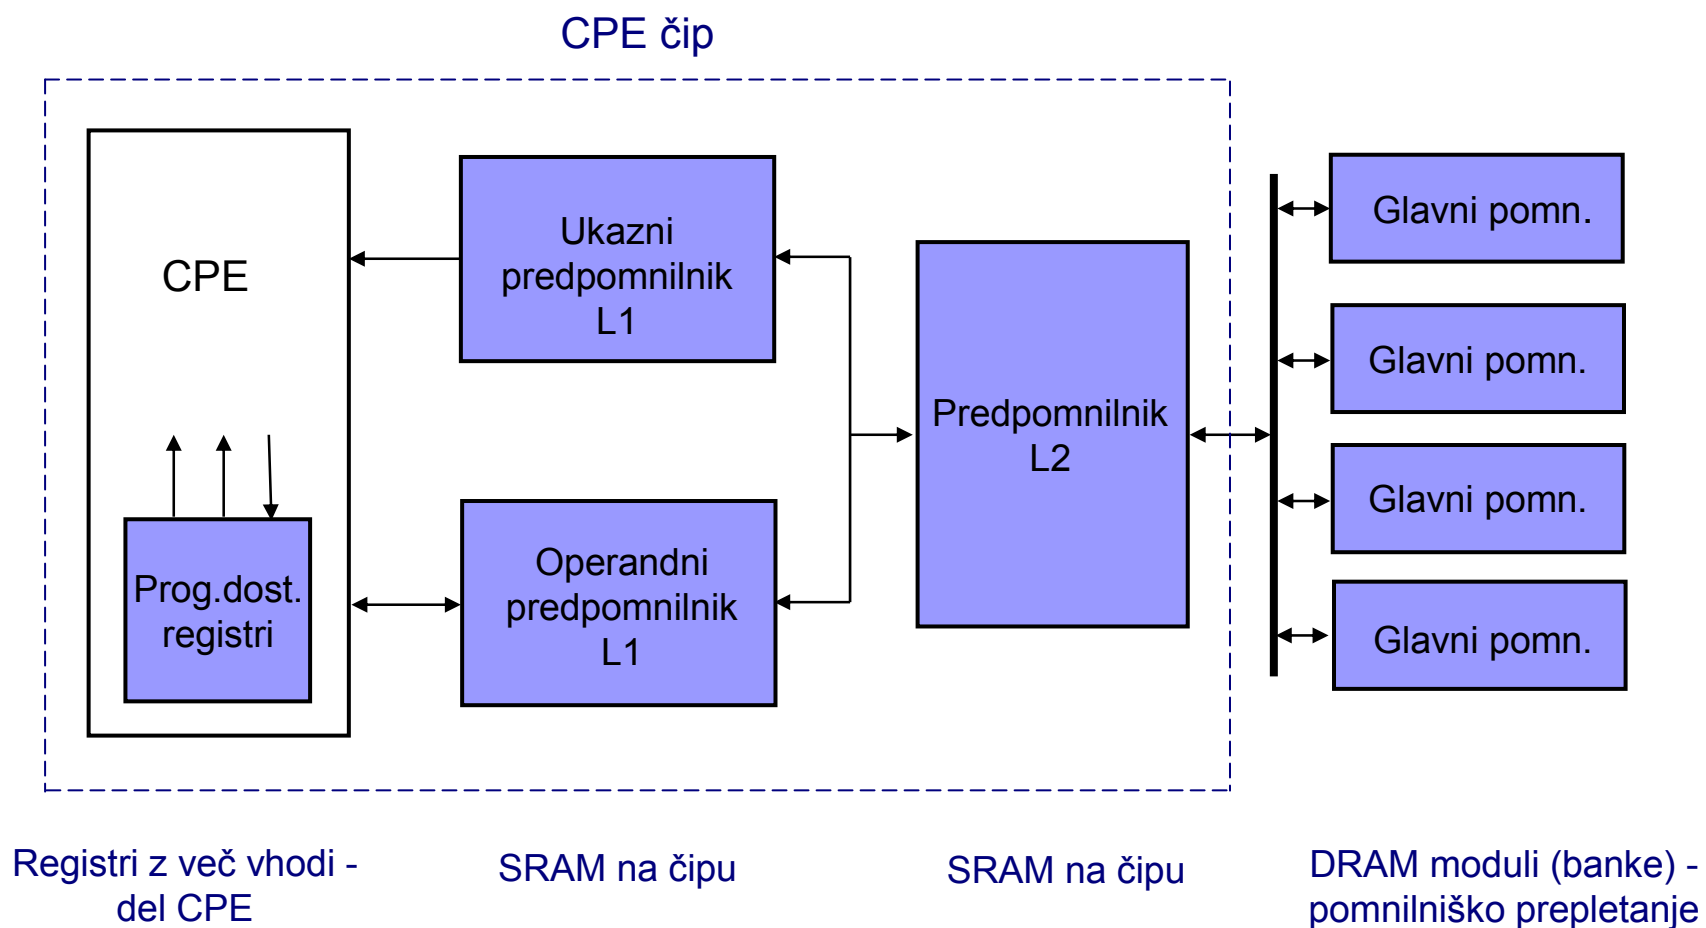
- Razkorak med zmogljivostjo CPE in hitrostjo DRAM pomnilnikov se stalno povečuje.
- Razliko med hitrostjo CPE in DRAMov lahko zmanjšamo z uporabo predpomnilnika, vendar samo to ni dovolj.
- Dodatni možnosti za pohiترitev pri uporabi predpomnilnika sta:
 - Uporaba dveh predpomnilnikov enega za ukaze in drugega za operande (Harvardska arhitektura)
 - Uporaba širših podatkovnih poti med predpomnilnikom in CPE

- Če iskane besede ni v predpomnilniku, je potreben dostop do glavnega pomnilnika (DRAM) in prenos novega bloka, ki vsebuje iskano besedo, v predpomnilnik.
- Zato je potrebno pohitriti tudi ta prenos, rešitve so:
 - Ker so besede v bloku sosednje, se lahko uporabi pri dostopu do DRAMa page mode način prenosa
 - Tudi pri prenosu med predpomnilnikom in DRAMom se lahko uporabi širše podatkovne poti
 - Razdelitev glavnega pomnilnika na več modulov - pomnilniško prepletanje

- Drugi predpomnilniški nivo L2 izven CPE, ki je vedno homogen (Princetonska arhitektura). Včasih tudi tretji nivo L3.
- S CPE je predpomnilnik L2 lahko povezan s posebno prenosno potjo. V tem primeru ima CPE dve prenosni poti:
 - Eno za povezavo z glavnim pomnilnikom
 - Drugo za povezavo s predpomnilnikom nivoja L2

- Te rešitve se lahko kombinirajo, čeprav se danes pri zmogljivejših računalnikih uporabljajo večinoma kar vse.

Predpomnilnik



Osnove delovanja predpomnilnikov

- Predpomnilnik (cache) je majhen hiter pomnilnik med CPE in glavnim pomnilnikom.
- Vsebina predpomnilnika so deli vsebine glavnega pomnilnika, oziroma podmnožica vsebine glavnega pomnilnika.
- Razlog, da bo iskana informacija dovolj pogosto v predpomnilniku je **lokalnost pomnilniških dostopov**.
- Predpomnilnik mora biti narejen tako, da vsebuje delovno množico $V(t, T)$ in se prilagaja njenemu spreminjanju.

- Delovna množica $V(t, T)$ je množica različnih pomnilniških naslovov, ki jih program generira v času od $t-T$ do T .
- Če v času T pride v pomnilnik N pomnilniških naslovov, velja:
 - Velikost množice $V(t, T)$ je veliko manjša od N
 - Vsebina zaporedno si sledečih množic se spreminja počasi
- Ker je delovna množica manjša od glavnega pomnilnika, je dovolj že majhen predpomnilnik.

- Ker je v predpomnilniku samo del vsebine glavnega pomnilnika, mora biti v predpomnilniku še informacija, kateri deli vsebine glavnega pomnilnika so trenutno v njem.

- Pri dostopu CPE do informacije (ukaz, operand) sta dve možnosti:
 - **Zadetek** (hit), če je naslov v predpomnilniku
 - **Zgrešitev** (miss), če naslova ni v predpomnilniku

- Uspešnost delovanja predpomnilnika merimo:

□ Z verjetnostjo zadetka H
$$H = \frac{N_p}{N} = \frac{N_p}{N_g + N_p}$$

N - število vseh dostopov ($N = N_g + N_p$)

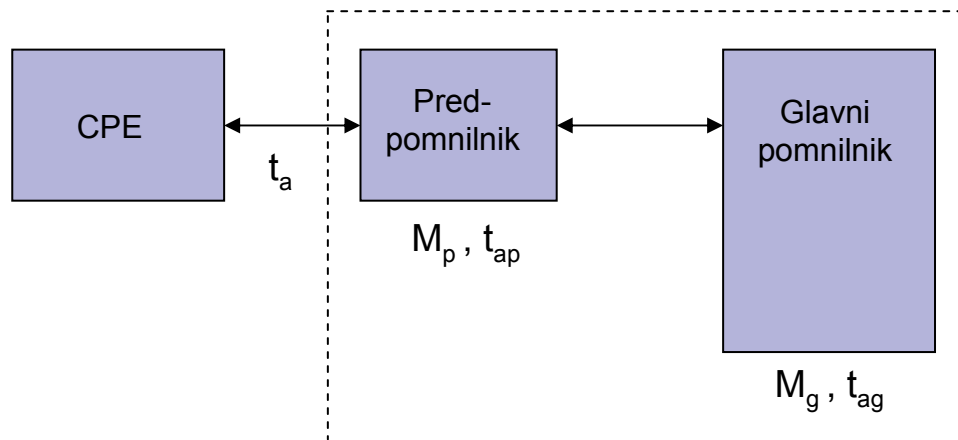
N_p - število zadetkov

N_g - število zgrešitev

□ Z verjetnostjo zgrešitve $1-H$

- **Verjetnost zadetka H** je pri današnjih predpomnilnikih večja od 0,9; večinoma celo večja od 0,95.
- To pomeni, da bo npr. pri 100 dostopih do pomnilnika pri 95 v predpomnilniku zadetek (vendar vnaprej ne vemo pri katerih), pri 5 dostopih pa zgrešitev.

- V primeru zgrešitve je potreben dostop do glavnega pomnilnika.
- Čas dostopa do predpomnilnika označimo s t_{ap} , čas dostopa do glavnega pomnilnika pa s t_{ag} .



Povprečen čas dostopa t_a do predpomnilnika in glavnega pomnilnika skupaj je:

$$t_a = t_{ap} + (1 - H)t_{ag}$$

- Pri računanju je treba upoštevati dve posebnosti predpomnilnikov:
 - Pri zgrešitvi se iz glavnega pomnilnika ne prenese samo ena beseda, temveč **predpomnilniški blok**, kar je več sosednjih besed
 - Čas v računalniku merimo z urinimi periodami
- Čas t_{ap} je število urinih period za dostop do predpomnilnika na nivoju L1 in je pri večini računalnikov 1 urina perioda.
- Pri zgrešitvi je potreben dostop do glavnega pomnilnika, čas ki je zato potreben, pa je **zgrešitvena kazen**.

- Zgrešitvena kazen t_B je število urinih period, ki se ob zgrešitvi prištejejo k času dostopa.
- Zgrešitvena kazen je odvisna od velikosti bloka, širine podatkovne poti med predpomnilnikom in DRAMom in je tipično med 10 in 100 urinimi periodami.
- Če ima računalnik tudi predpomnilnik na nivoju L2, je zgrešitvena kazen precej manjša.

- Povprečni čas dostopa t_a je potem:

$$t_a = t_{ap} + (1 - H)t_B$$

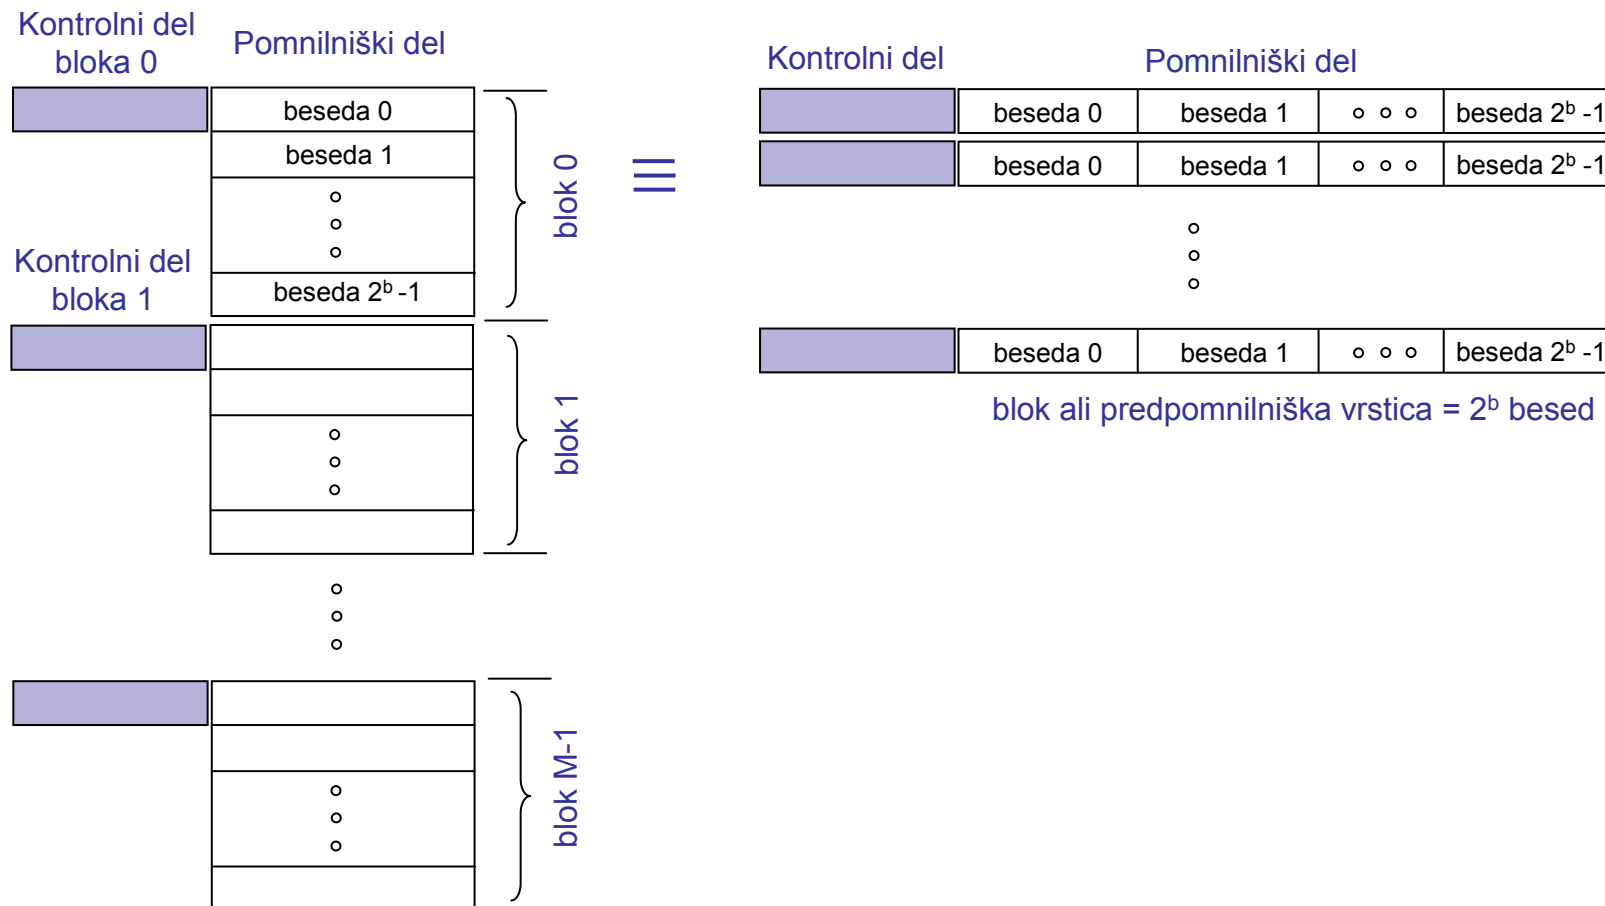
- Če sta časa t_{ap} in t_B v urinih periodah, je tudi rezultat t_a v urinih periodah.
- Povprečni dostopni čas v sekundah pa lahko izračunamo tako, da rezultat t_a v urinih periodah pomnožimo s časom trajanja ene urine periode t_{CPE} .

- Ker se vsebina v predpomnilniku spreminja, mora predpomnilnik vsebovati poleg besed iz glavnega pomnilnika tudi naslove teh besed. (Kopija katerih besed iz glavnega pomnilnika je v predpomnilniku).

- Zato je vsak predpomnilnik sestavljen iz dveh delov:
 - Kontrolnega dela
 - Pomnilniškega dela

- Pomnilniški del je razdeljen na enake dele, **bloke** ali **predpomnilniške vrstice**.


Zgradba predpomnilnika



- Blok je nekaj sosednjih pomnilniških besed. Velikost bloka ($B = 2^b$) je tipično 4 do 512 pomnilniških besed.
- Kontrolni del vsebuje informacijo, ki enolično določa, kateri blok iz glavnega pomnilnika je v pomnilniškem delu, to je naslov bloka v glavnem pomnilniku.
- Vsak blok ima v predpomnilniku svoj kontrolni del, ki je skupen za cel blok.
- Med glavnim pomnilnikom in predpomnilnikom se vedno prenaša cel blok.

Predpomnilnik - osnove delovanja predpomnilnikov


Predpomnilnik, blok = 4 bajte $\Rightarrow b=2$



Pomnilniški naslov	8 bitov	Glavni pomnilnik
000 00		\$12
000 01		\$31
000 10		\$CB
000 11		\$74
001 00		\$67
001 01		\$45
001 10		\$0B
001 11		\$23
010 00		\$A4
CPE → 010 01		\$1F
010 10		\$36
010 11		\$06
011 00		\$FE
011 01		\$7A
011 10		\$CC
011 11		\$5F
100 00		


Predpomnilnik - osnove delovanja predpomnilnikov

Predpomnilnik, blok = 4 bajte $\Rightarrow b=2$



Predpomnilnik - osnove delovanja predpomnilnikov


Predpomnilnik, blok = 4 bajte $\Rightarrow b=2$



Pomnilniški naslov	8 bitov	Glavni pomnilnik
000 00	\$12	—
000 01	\$31	—
000 10	\$CB	—
000 11	\$74	—
001 00	\$67	—
001 01	\$45	—
001 10	\$0B	—
001 11	\$23	—
010 00	\$A4	—
010 01	\$1F	—
CPE 010 10	\$36	—
010 11	\$06	—
011 00	\$FE	—
011 01	\$7A	—
011 10	\$CC	—
011 11	\$5F	—
100 00		—

Predpomnilnik - osnove delovanja predpomnilnikov



Predpomnilnik, blok = 4 bajte $\Rightarrow b=2$



Pomnilniški naslov	8 bitov	Glavni pomnilnik
000 00	\$12	—
000 01	\$31	—
000 10	\$CB	—
000 11	\$74	—
001 00	\$67	—
001 01	\$45	—
001 10	\$0B	—
001 11	\$23	—
010 00	\$A4	—
010 01	\$1F	—
010 10	\$36	—
CPE 010 11	\$06	—
011 00	\$FE	—
011 01	\$7A	—
011 10	\$CC	—
011 11	\$5F	—
100 00		—


Predpomnilnik - osnove delovanja predpomnilnikov

Predpomnilnik, blok = 4 bajte $\Rightarrow b=2$



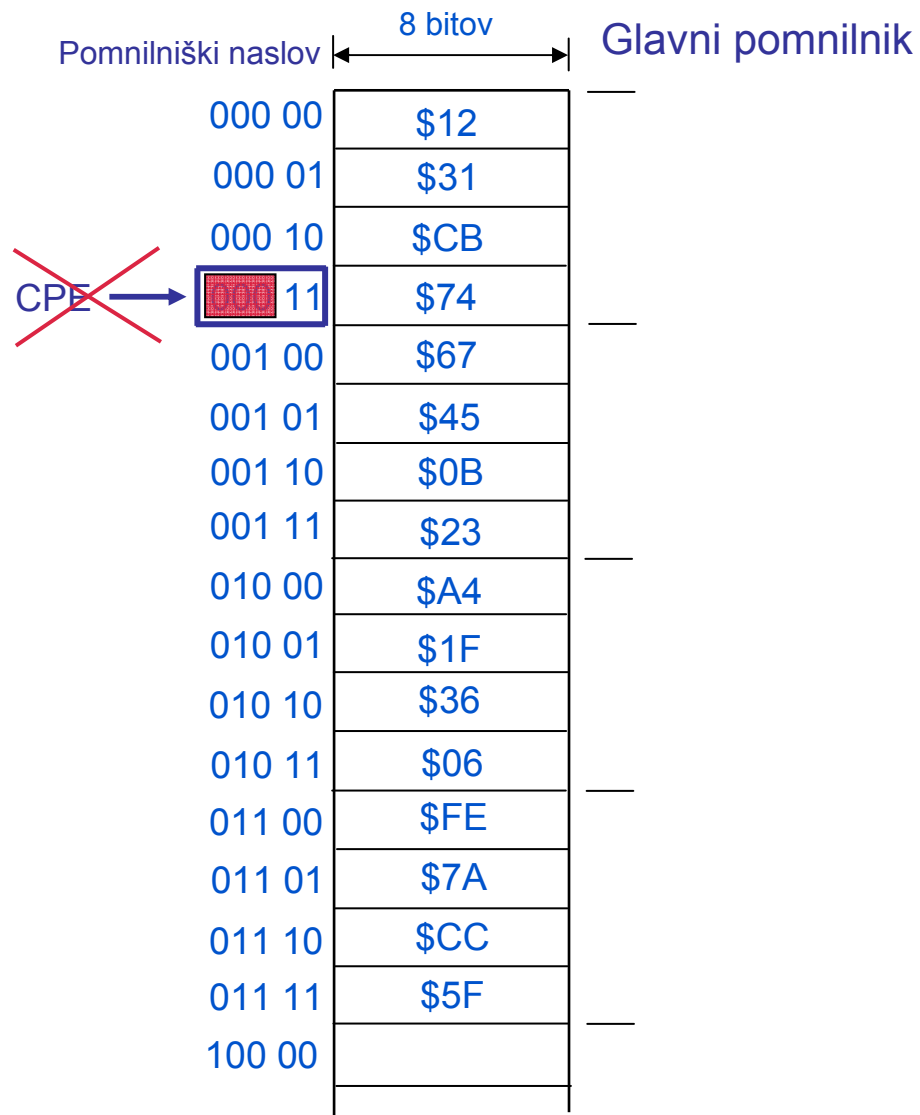
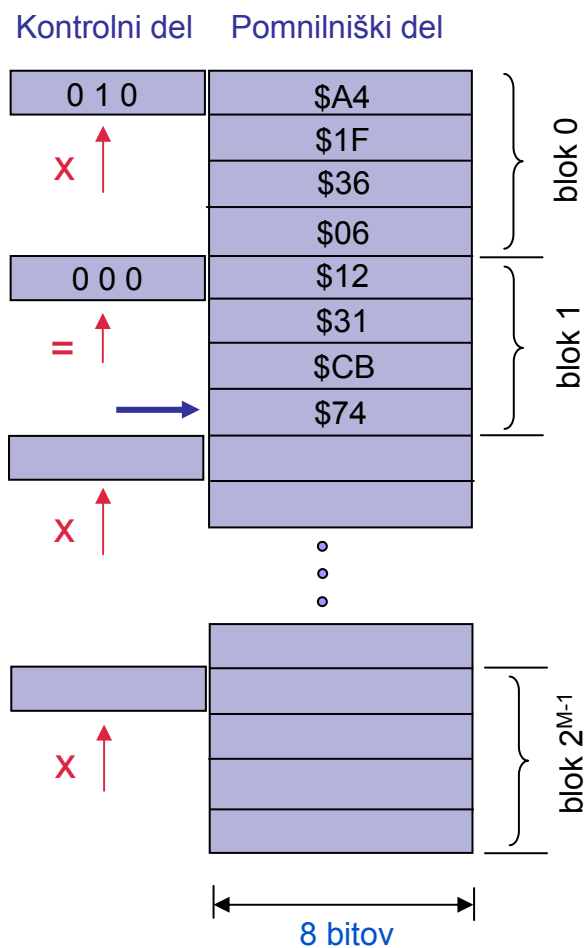
Predpomnilnik - osnove delovanja predpomnilnikov

Predpomnilnik, blok = 4 bajte $\Rightarrow b=2$



Predpomnilnik - osnove delovanja predpomnilnikov

Predpomnilnik, blok = 4 bajte $\Rightarrow b=2$



- Pri vsakem dostopu CPE pošlje v pomnilnik n -bitni pomnilniški naslov. Zgornjih $n-b$ bitov se primerja z naslovi v kontrolnih delih vseh blokov predpomnilnika (spodnjih b -bitov določa naslov besede znotraj bloka).
 - Če pri nekem bloku obstaja enakost, je iskana beseda v predpomnilniku - govorimo o zadetku v predpomnilniku in CPE izvrši dostop do besede v pomnilniškem delu predpomnilnika
 - Če enakosti ni, je to zgrešitev in iz glavnega pomnilnika se v predpomnilnik prenese blok v katerem je iskana beseda - **preslikava bloka**
 - Če so predpomnilniku vsi bloki zasedeni, novi blok zamenja enega od obstoječih - govorimo o **zamenjavi bloka**

- Potrebna je hitra primerjava vsebine kontrolnega dela predpomnilnika in dela pomnilniškega naslova, do katerega želi CPE dostop.
- Če primerjava ni hitra, je dostop počasen, zato je treba pri preslikavi bloka iz glavnega pomnilnika v predpomnilnik vpeljati omejitve.
- Glede na strogost omejitev pri preslikavi razlikujemo tri vrste predpomnilnikov:
 - Čisti asociativni predpomnilnik
 - Set-asociativni predpomnilnik
 - Direktni predpomnilnik

- Razlika med temi tremi vrstami predpomnilnikov je predvsem v zgradbi kontrolnega dela.
- Pri čistem asociativnem in set-asociativnem predpomnilniku je kontrolni del zgrajen z asociativnim pomnilnikom, pri direktnem pomnilniku pa je kontrolni del navadni z naslovom naslovljiv pomnilnik.
- Pri čistem asociativnem predpomnilniku zato pri preslikavi bloka iz glavnega pomnilnika v predpomnilnik ni nobenih omejitev.

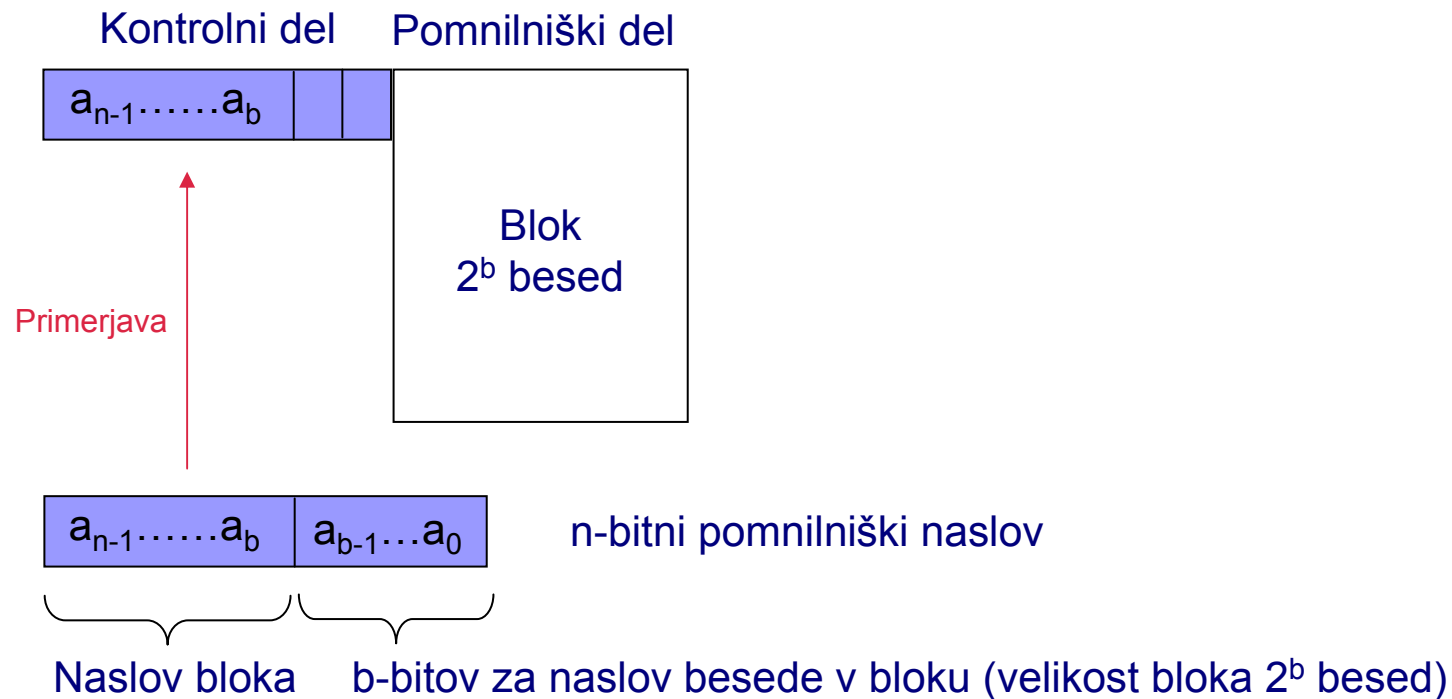
- To pomeni, da se poljuben blok iz glavnega pomnilnika lahko preslika v poljuben blok predpomnilnika (ker je iskanje po vsebini v kontrolnem delu hitro).
- Najstrožje omejitve pri preslikavi ima direktni predpomnilnik, kjer se določen blok iz glavnega pomnilnika lahko preslika samo v točno določen blok predpomnilnika (ker iskanje po vsebini v kontrolnem delu ni mogoče).
- Set-asociativni predpomnilnik je kompromis med čistim asociativnim in direktnim predpomnilnikom, zato so omejitve pri preslikavi delne.

- Določen blok iz glavnega pomnilnika se pri set-asociativnem predpomnilniku lahko preslika samo v določen set, znotraj seta pa omejitev pri preslikavi ni.
- Pomnilniški del je pri vseh treh vrstah predpomnilnikov navadni z naslovom naslovljiv pomnilnik, seveda čim hitrejši (SRAM).

Čisti asociativni predpomnilnik

- Kontrolni del predpomnilnika je narejen kot asociativni pomnilnik do katerega je dostop preko vsebine.
- Vsebina kontrolnega dela so naslovi blokov in predpomnilnik lahko na osnovi naslova, ki ga da CPE, takoj ugotovi ali je zadetek ali zgrešitev.
- Pri zadetku se opravi dostop do besede v bloku, ki je določena s spodnjimi b -biti pomnilniškega naslova.

- Ker so vse besede asociativnega pomnilnika (kontrolnega dela) ekvivalentne, ni pri preslikovanju blokov iz glavnega pomnilnika v predpomnilnik nobenih omejitev.

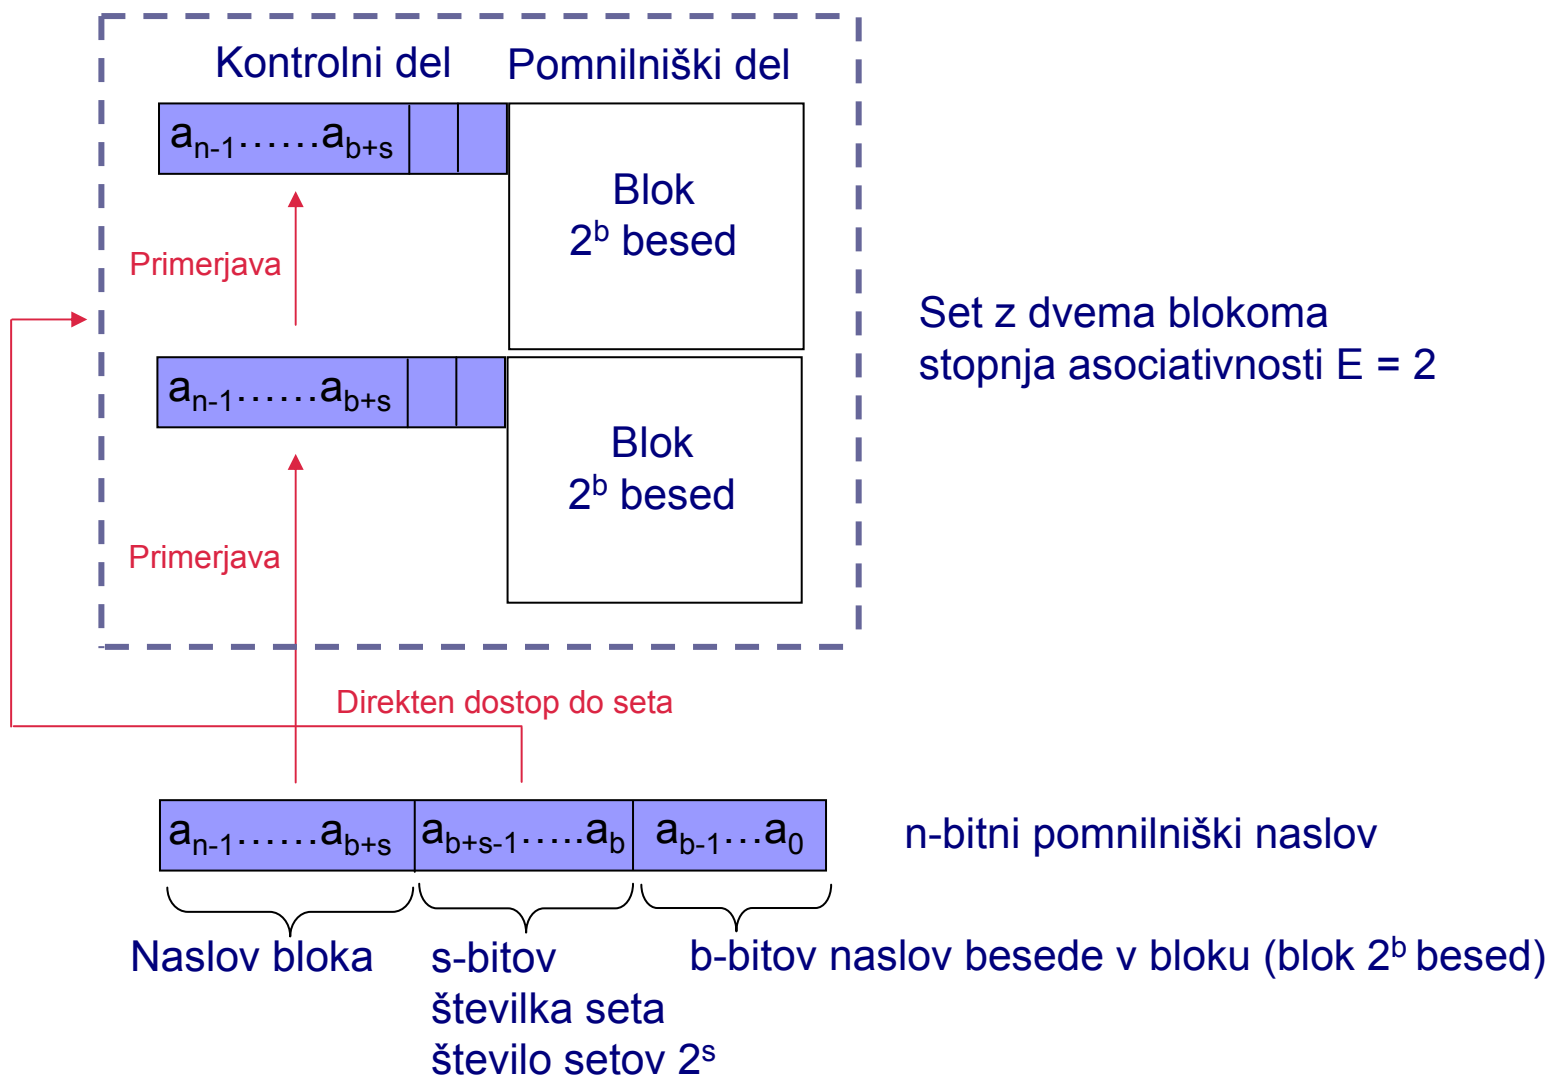


- Asociativnih pomnilnikov z nekaj 10.000 besedami z današnjo tehnologijo ni mogoče narediti.
- Zato se čisti asociativni predpomnilniki danes uporabljajo samo v posebnih primerih, kjer so velikosti predpomnilnika samo nekaj 10 besed.
- Če želimo velik predpomnilnik, za kontrolni del namesto enega velikega asociativnega pomnilnika uporabimo več majhnih, ki so cenejši in jih lahko naredimo.

Set-asociativni predpomnilnik

- Če predpomnilnik razdelimo na **sete**, ki so vsak zase majhen asociativni predpomnilnik, dobimo set-asociativni predpomnilnik.
- Predpomnilnik razdelimo na $S=2^s$ setov, vsak set je majhen asociativni predpomnilnik.
- Število blokov v setu $E=2^e$ imenujemo **stopnja asociativnosti ali asociativnost**.
- Naslov seta v katerega se lahko preslika blok iz glavnega pomnilnika je: $S_i = A_i(b:n-1) \bmod 2^s$
 - $A_i(b:n-1)$ - zgornjih $n-b$ bitov pomn. naslova = številka bloka
 - 2^s - število setov v predpomnilniku

Predpomnilnik - direktni predpomnilnik



- Stopnja asociativnosti je velikost asociativnega pomnilnika s katerim je narejen kontrolni del vsakega seta.

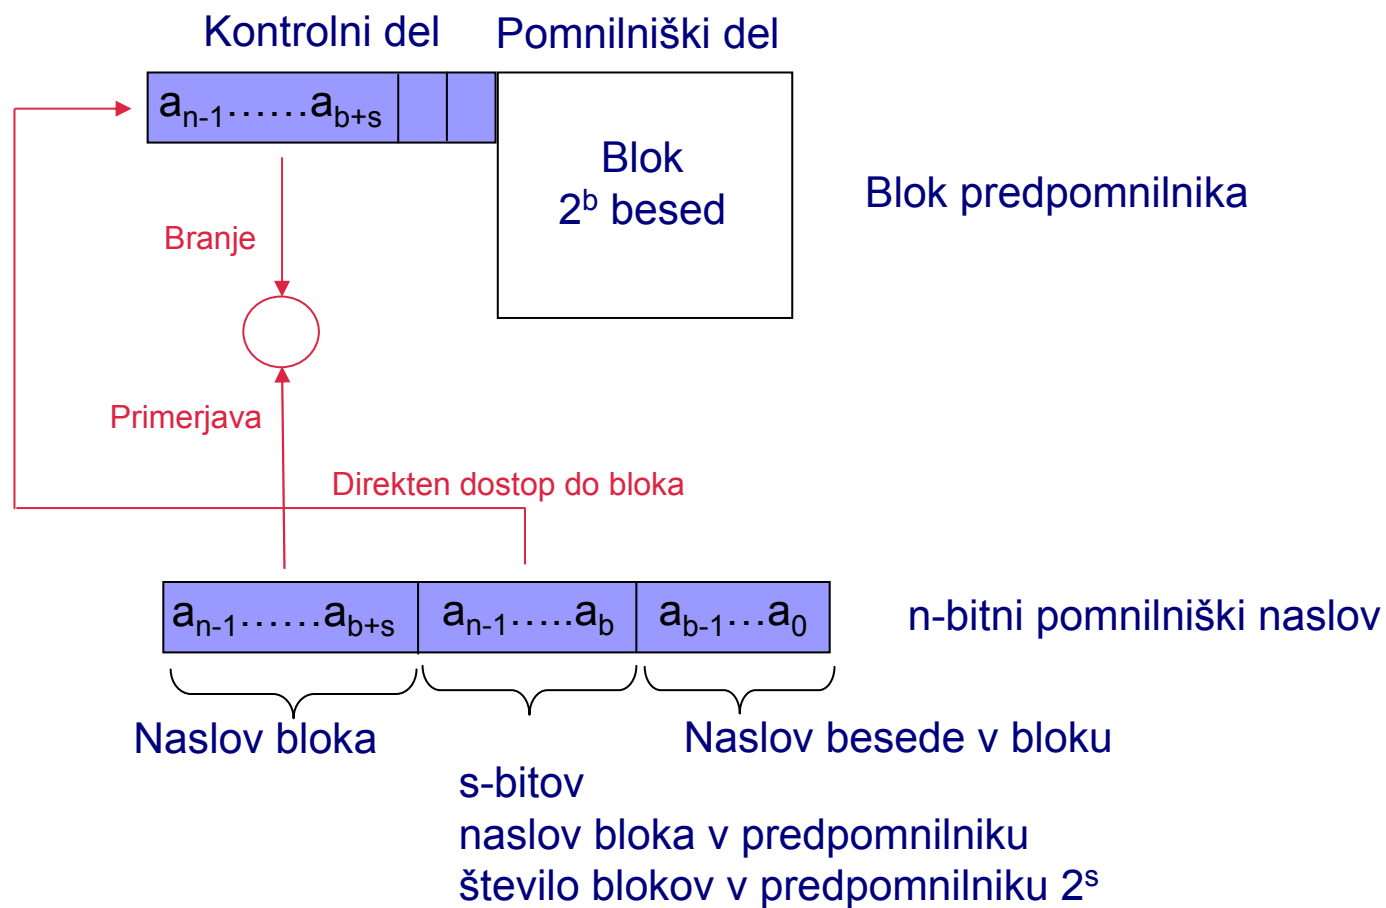
- Stopnja asociativnost je tipično od 2 do 16 (2 do 16 blokov v setu \Rightarrow 2 do 16 besed velik asociativni pomnilnik za kontrolni del seta)

- Velikost predpomnilnika je $M = S * E * B = 2^{s+e+b}$
 - $S = 2^s$ število setov
 - $E = 2^e$ stopnja asociativnosti (število blokov v setu)
 - $B = 2^b$ velikost bloka (število besed v bloku)

Direktni predpomnilnik

- Če je stopnja asociativnosti ena, je v vsakem setu samo en blok in za kontrolni del seta ne potrebujemo več asociativnega pomnilnika.
- Tak predpomnilnik je direktni predpomnilnik. Vsak blok iz glavnega pomnilnika se lahko preslika samo v točno določen blok predpomnilnika (znotraj “seta” ni več izbire, ker je v setu samo en blok)
- Naslov (številka) bloka v katerega se mora preslikati blok iz glavnega pomnilnika je: $S_i = A_i(b:n-1) \bmod 2^s$
 - $A_i(b:n-1)$ - zgornjih $n-b$ bitov pomn. naslova = številka bloka
 - 2^s - število blokov v predpomnilniku

Predpomnilnik - direktni predpomnilnik



Predpomnilnik - preslikava bloka v predpomnilnik pri različnih vrstah predpomnilnikov

Predpomnilnik 8 blokov

		Blok
Čisti asociativni predpomnilnik	Številka bloka	0
		1
		2
		3
		4
		5
		6
		7
Set-asociativni predpomnilnik stopnja asoc. E=2	Številka seta	0
		1
		2
		3
Direktni predpomnilnik	Številka bloka (seta)	0
		1
		2
		3
		4
		5
		6
		7

Glavni pomnilnik

	Blok
Številka bloka 00	\$12...53
01	\$31...4A
02	\$CB...1F
03	\$74...12
04	\$67...7A
05	\$45...9C
06	\$0B...AA
07	\$23...86
08	\$A4...64
09	\$1F...39
10	\$36...5C
11	\$06...1B
12	\$FE...00
13	\$7A...0B
14	\$CC...52
15	\$5F...22
16	

Predpomnilnik - vrste predpomnilnikov

Predpomnilnik 8 blokov

		Blok
Čisti asociativni predpomnilnik	Številka bloka	0
		1
		2
		3
		4
		5
		6
		7
Set-asociativni predpomnilnik stopnja asoc. E=2	Številka seta	0
		1
		2
		3
Direktni predpomnilnik	Številka bloka (seta)	0
		1
		2
		3
		4
		5
		6
		7

Glavni pomnilnik

	Blok
Številka bloka	00
	01
	02
	03
	04
	05
	06
	07
	08
	09
	10
	11
	12
	13
	14
	15
	16

\$12...53

\$31...4A

\$CB...1F

\$74...12

\$67...7A

\$45...9C

\$0B...AA

\$23...86

\$A4...64

\$1F...39

\$36...5C

\$06...1B

\$FE...00

\$7A...0B

\$CC...52

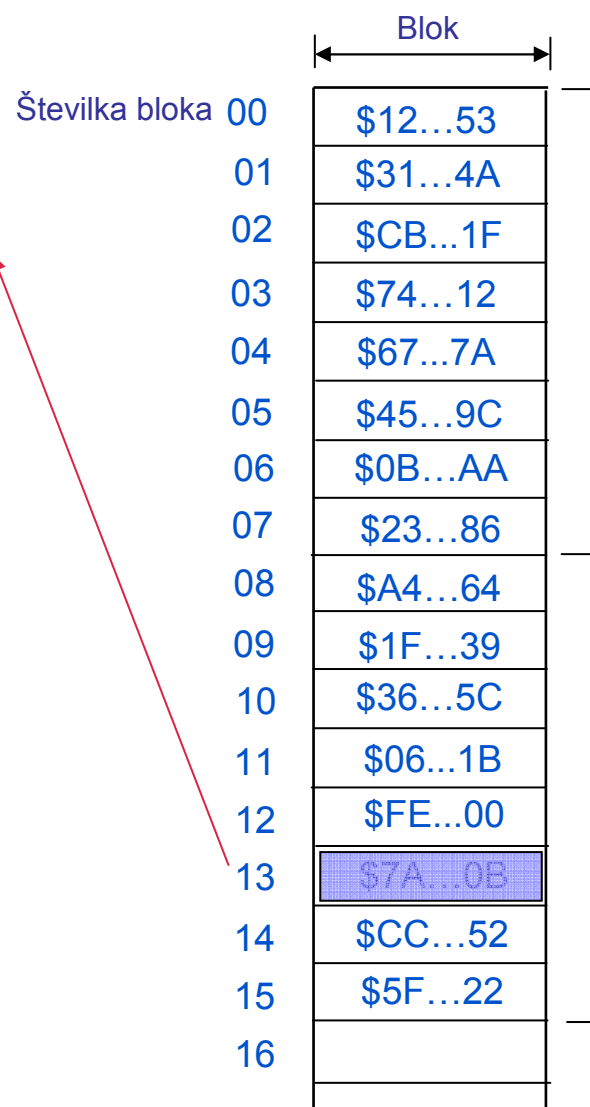
\$5F...22

Predpomnilnik - vrste predpomnilnikov

Predpomnilnik 8 blokov



Glavni pomnilnik

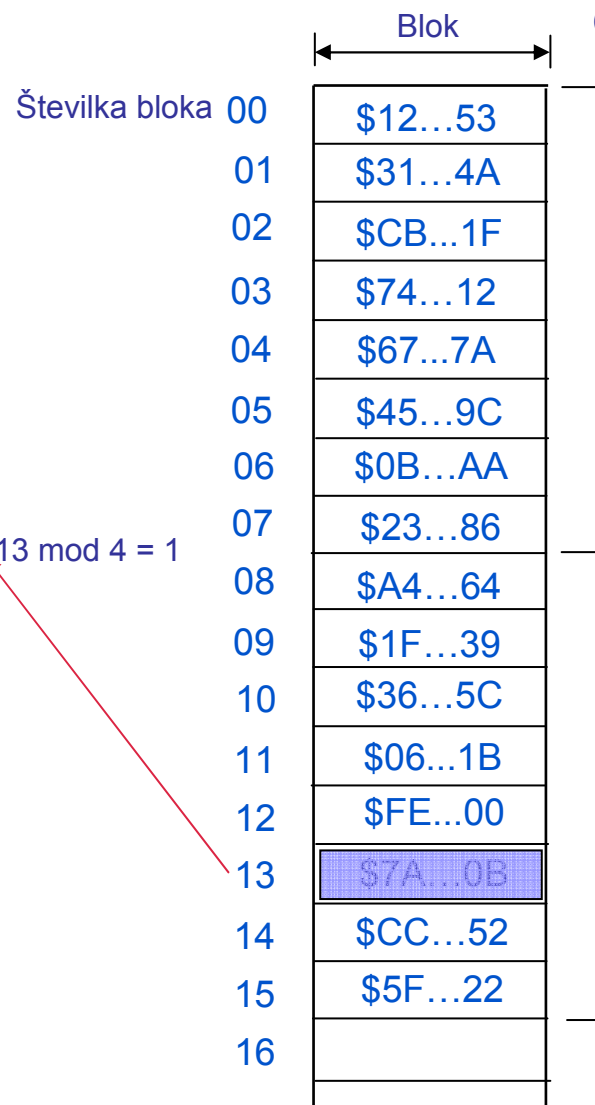


Predpomnilnik - vrste predpomnilnikov

Predpomnilnik 8 blokov




Glavni pomnilnik



Predpomnilnik - vrste predpomnilnikov

Predpomnilnik 8 blokov



■ Na verjetnost zadetka H vplivajo:

- Velikost predpomnilnika M
- Stopnja asociativnosti E
- Velikost bloka B

■ Predpomnilnik lahko povečamo tako, da povečamo:

- Stopnjo asociativnosti E - v setu je več blokov, zato je večji kontrolni del (najdražje)
- Število setov S
- Velikost bloka B - kontrolni del ostane nespremenjen (najceneje)

- Večja kot je stopnja asociativnosti E , večja je verjetnost zadetka. Direktni predpomnilnik ima najmanjšo verjetnost zadetka. Ker pa je najcenejši, je lahko tudi velik, kar verjetnost zadetka popravi.

- Predpomnilniško pravilo 2 : 1
 - Verjetnost zadetka direktnega predpomnilnika velikosti M je približno enaka verjetnosti zadetka set-asociativnega predpomnilnika s stopnjo asociativnosti $E=2$ in velikostjo $M/2$.

- Verjetnost zadetka H z večanjem bloka do neke meje narašča, nato pa pada.
- Pri enaki velikosti predpomnilnika:
 - je s povečanjem velikosti bloka v bloku več sosednjih ukazov ali operandov (prostorska lokalnost)
 - hkrati se število blokov v predpomnilniku zmanjša (časovna lokalnost)
- Na verjetnost zadetka vpliva tudi izbira bloka, ki naj se zamenja pri zgrešitvi

- Pri direktnem predpomnilniku izbire ni, zamenja se blok, ki je določen s preslikavo.
- Pri čistem asociativnem in set-asociativnem predpomnilniku se blok lahko preslika v poljuben blok seta. Ko je predpomnilnik poln, potrebujemo strategijo za določanje bloka, ki naj se zamenja.
- Uporabljajo se naslednje strategije:
 - **Naključna strategija** (Random) - blok se izbere naključno, verjetnost, da bo blok zamenjan je enaka za vse bloke

- **LRU strategija** (Least Recently Used) - zamenja se blok, ki najbolj dolgo ni bil uporabljen. Ta strategija je boljša od naključne, ker zmanjša nevarnost, da bi se zamenjal blok, ki je bil pred kratkim uporabljen
 - **FIFO strategija** (First In First Out) - zamenja se blok, ki je najbolj dolgo v predpomnilniku
-
- Realizacija LRU strategije je precej zapletena, zato se običajno uporablja pri manjših stopnjah asociativnosti ($E=2$). Pri predpomnilnikih z višjo stopnjo asociativnosti se uporablja naključna ali FIFO strategija.

Branje in pisanje v predpomnilnik

- Pri delovanju računalnika lahko opazimo, da je bralnih dostopov veliko več kot pisalnih (4 : 1)
- Pri branju je hitra rešitev dokaj enostavna:
 - Branje bloka je lahko istočasno s primerjavo kontrolne informacije
 - Pri zadetku je podatek na voljo CPE takoj
 - Ob zgrešitvi je podatek neuporaben, kar pa ne povzroči škode
- Pisanje v predpomnilnik se lahko začne le, če se ugotovi zadetek. Pisanje spremeni vsebino bloka v predpomnilniku, kar pomeni da se razlikuje od vsebine v glavnem pomnilniku.

- Dve vrsti pisalnih strategij se med seboj razlikujeta po tem, kdaj se sprememba vsebine bloka v predpomnilniku odrazi tudi v glavnem pomnilniku:
 - **Pisanje skozi** (write through) - informacija se vedno piše v predpomnilnik in v glavni pomnilnik, tako je vsebina bloka v predpomnilniku in glavnem pomnilniku vedno enaka
 - **Pisanje nazaj** (write back) - informacija se piše samo v predpomnilnik. Vsebina bloka v predpomnilniku je lahko različna od vsebine v glavnem pomnilniku, pri zamenjavi je zato spremenjeni blok treba prenesti nazaj v glavni pomnilnik.

- **Umazani bit** (dirty bit) poseben bit v kontrolnem delu bloka, ki pove ali je bila vsebina bloka spremenjena. Ob prenosu bloka v predpomnilnik se postavi na 0, ko se v blok piše, se umazani bit postavi na 1.
- Pri zamenjavi bloka se morajo nazaj v glavni pomnilnik prenesti samo bloki, ki imajo umazani bit postavljen na 1.

Vrste zgrešitev v predpomnilniku

- Majhno število zgrešitev je ključnega pomena za dobro delovanje predpomnilnika.
- Za zgrešitev v predpomnilniku so trije osnovni vzroki in glede na to ločimo tri vrste zgrešitev:
 - Obvezne zgrešitve
 - Velikostne zgrešitve
 - Konfliktne zgrešitve

■ Obvezne zgrešitve

- Ob prvem dostopu do besede te ni v predpomnilniku. Tem zgrešitvam se ni mogoče izogniti, zato tudi zgrešitve prvega dostopa ali mrzle zgrešitve.
- Velikost predpomnilnika, stopnja asociativnosti in zamenjalna strategija na te zgrešitve ne vpliva.
- Pri večjih blokih je obveznih zgrešitev manj.

■ Velikostne zgrešitve

- Nastopijo zaradi končne velikosti predpomnilnika ko je predpomnilnik poln.
- Z večanjem predpomnilnika se število teh zgrešitev manjša.

■ Konfliktne zgrešitve

- Nastopajo samo pri set-asociativnih in direktnih predpomnilnikih zaradi omejitev pri preslikavi
- Do konfliktne zgrešitve pride, ko se zamenja blok, ki se bo kmalu spet uporabil
- Do zamenjave pride, ker se morata oba bloka zaradi omejitev pri preslikavi preslikati v isti set (ali blok)
- Če bi bil predpomnilnik čisti asociativni, konfliktnih zgrešitev ne bi bilo

Skladnost predpomnilnika

- Problem skladnosti predpomnilnika (cache coherency) nastopi, kadar se vsebina nekega bloka v predpomnilniku razlikuje od vsebine istega bloka v glavnem pomnilniku in v drugih predpomnilnikih.
- V računalniku s predpomnilnikom je treba zagotoviti, da zaradi neskladnosti ne pride do napak.
- Problem skladnosti nastopa predvsem pri predpomnilnikih, ki uporabljajo pisanje nazaj.

- Za napačno delovanje zaradi neskladnosti sta dva glavna vzroka:
 - Prenosi med V/I napravami in glavnim pomnilnikom. Če se prenos v ali iz glavnega pomnilnika nanaša na naslove, ki so tudi v predpomnilniku, lahko vsebini nista enaki
 - Pri računalnikih z več procesorji, ki imajo vsak svoj predpomnilnik, lahko obstaja več različnih kopij iste pomnilniške besede

- Rešitve:
 - V/I naprave so lahko priključene tako, da gredo prenosi skozi predpomnilnik - ta rešitev se malo uporablja, ker močno poslabša verjetnost zadetka (\Rightarrow v predpomnilnik se vpisujejo V/I podatki, ki jih CPE redko potrebuje)

- Pred izvrševanjem V/I ukazov se s posebnimi ukazi, ki jih ima vsak procesor s predpomnilnikom:
 - pri V/I branju razveljavi vsebina predpomnilnika
 - pri V/I pisanju prenese v glavni pomnilnik vse umazane bloke

- Mehanizem (dodatna logika) za zagotavljanje skladnosti:
 - **Centralni imenik** (central directory) - informacija o blokih, ki so trenutno v predpomnilniku, je shranjena na enem mestu v centralnem imeniku, ki je vgrajen v krmilnik pomnilnika
 - **Vohunjenje** (snooping) - se uporablja kadar so procesorji in glavni pomnilnik priključeni na isto vodilo. Vsi procesorji znajo vohuniti (opazovati dogajanje na vodilu) za naslovi na vodilu

- Protokol MESI (Modified, Exclusive, Shared, Invalid) - vsak blok v predpomnilniku ima dva kontrolna bita, ki določata v katerem od teh štirih stanj je blok.
 - Protokol deluje na osnovi vohunjenja, ob zgrešitvi se novemu bloku v predpomnilniku dodeli stanje E ali S (odvisno ali je blok samo v tem predpomnilniku ali tudi v kakšnem drugem)
 - Protokol MESI je za programerja neviden in se uporablja v operandnem predpomnilniku in predpomnilniku L2. V ukazni predpomnilnik pisanje ni dovoljeno, zato poseben protokol ni potreben

Vpliv predpomnilnika na hitrost delovanja CPE

■ Dostop do predpomnilnika:

□ Zadetek:

- Branje - običajno 1 urina perioda
- Pisanje - branje bloka

spreminjanje vsebine

pisanje bloka nazaj - tipično ena urina perioda več

□ Zgrešitev:

- dostop do glavnega pomnilnika
- prenos bloka do predpomnilnika
- pisanje bloka v predpomnilnik
- sledi branje ali pisanje kot pri zadetku
- če je predpomnilnik poln, je potrebna še zamenjava bloka

- Za vse te operacije pri zgrešitvi je potrebnih od 10 do 100 urinih period (zgrešitvena kazen).
- Predpomnilniške zgrešitve zmanjšujejo hitrost delovanja CPE, oziroma povečujejo CPI (povprečno število urinih period za izvedbo enega ukaza)
- Realni CPI z upoštevanjem zgrešitev v predpomnilniku je:

$$CPI_R = CPI_I + M_I(1 - H)Zgrešitvena\ kazen$$

CPI_R - realni CPI

CPI_I - idealni CPI brez zgrešitev
v predpomnilniku

M_I - povprečno število
pomn. dostopov na ukaz

- Čas izvajanja programa z I ukazi pa je:

$$CPE_{čas} = I (CPI_l + M_l(1 - H)Zgreš.kazen) t_{CPE}$$

- Zgrešitve v predpomnilniku imajo večji vpliv pri hitrih procesorjih z majhnim CPI, eden od načinov za zmanjšanje zgrešitvene kazni je drugi nivo predpomnilnika (predpomnilnik L2)