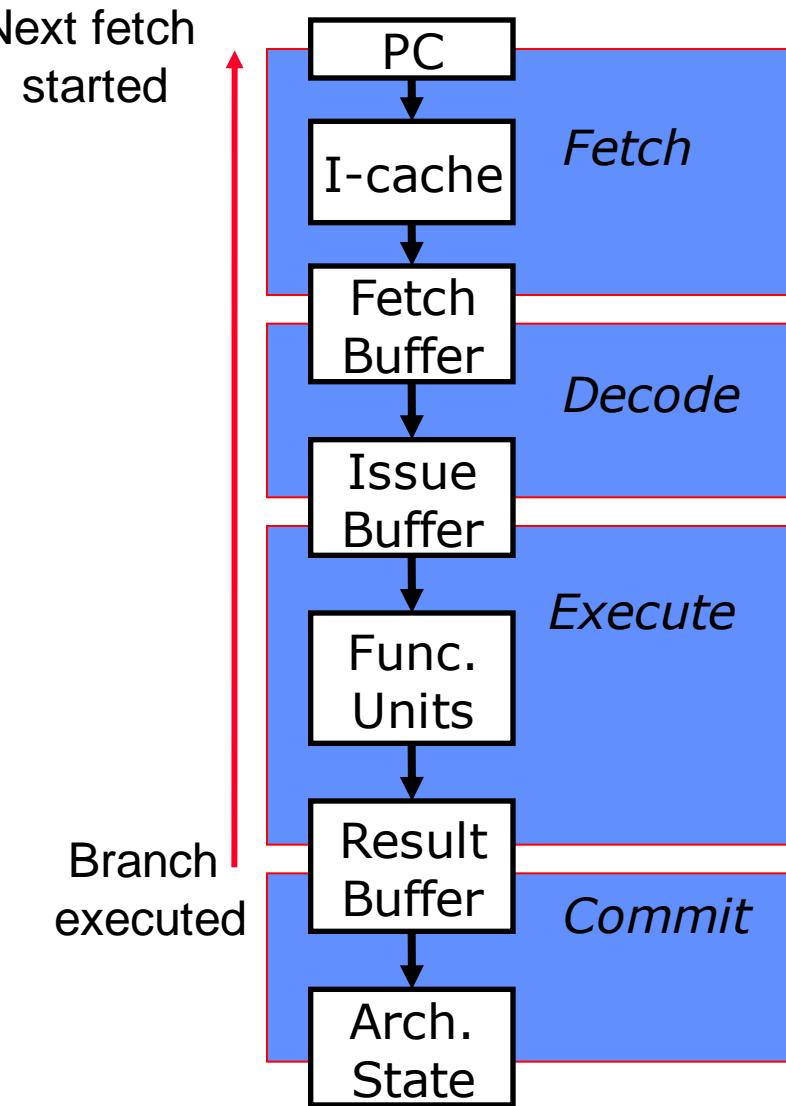


# Μέθοδοι Πρόβλεψης Διακλαδώσεων (Branch Prediction Mechanisms)

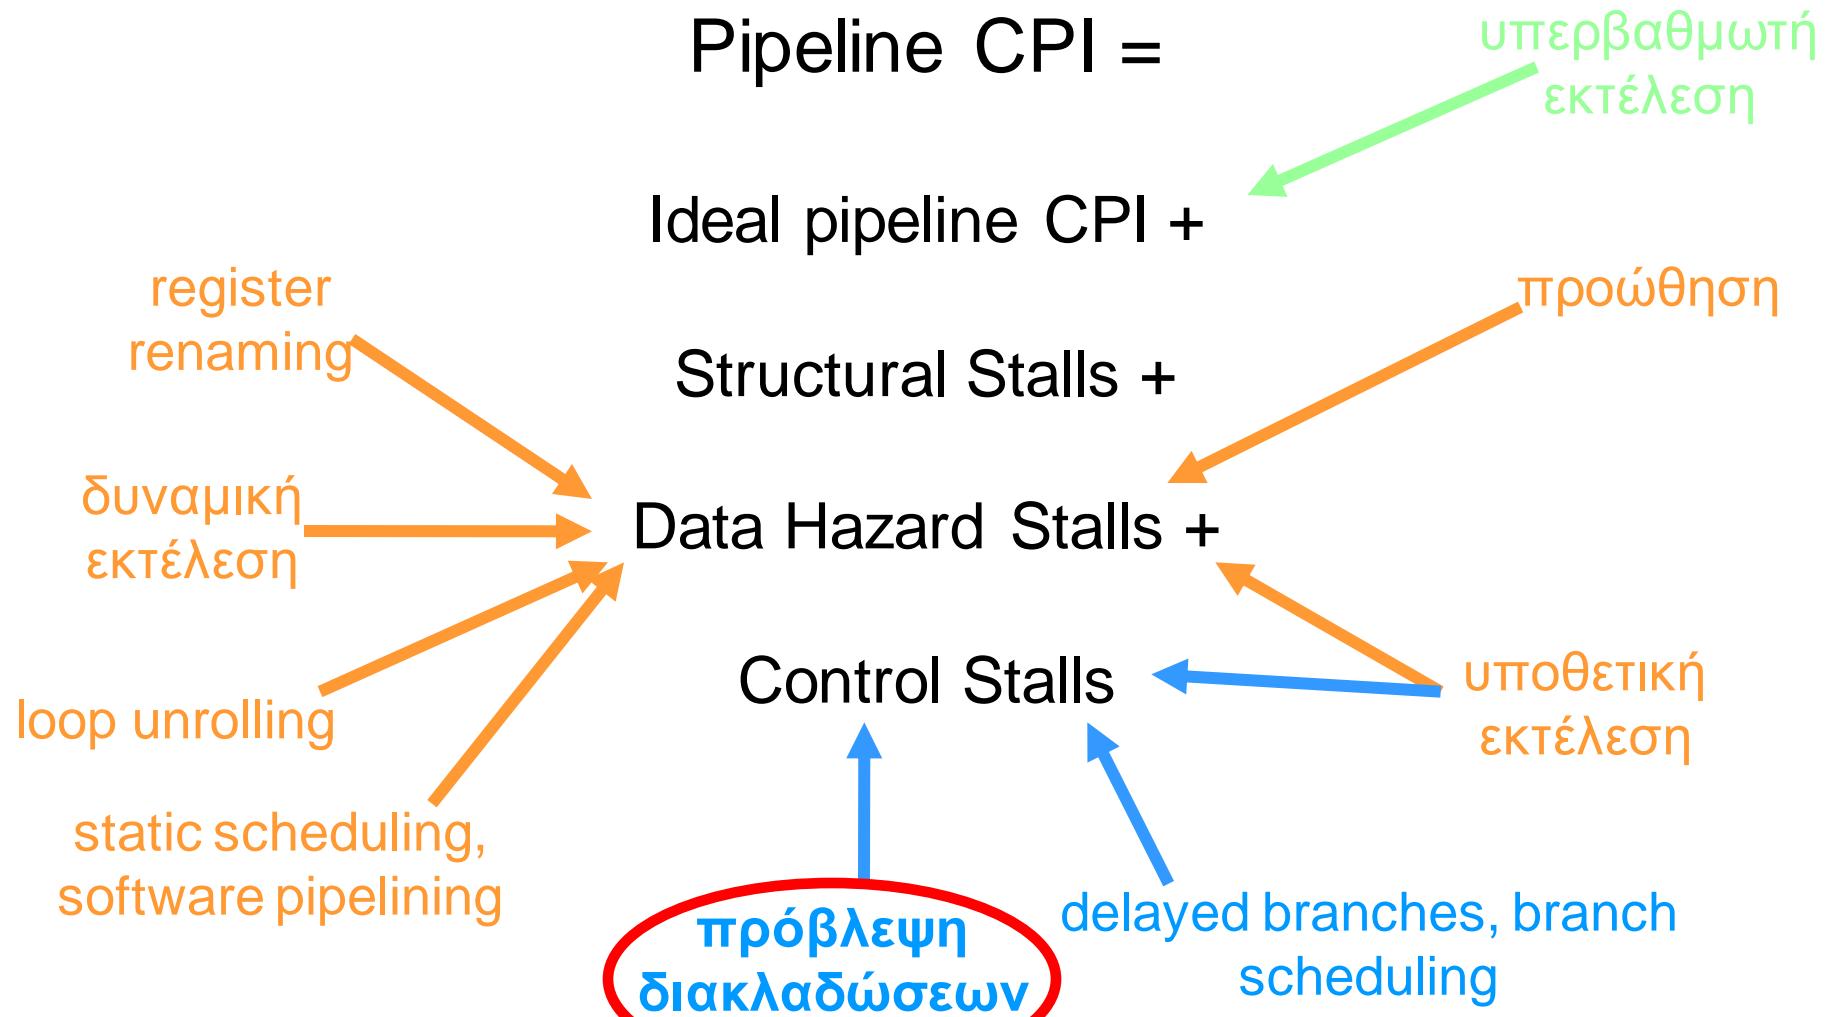
# Εντολές Διακλάδωσης

- Περίπου 20% των εντολών είναι εντολές διακλάδωσης
- Πολλά στάδια μεταξύ υπολογισμού του επόμενου PC και εκτέλεσης του branch (για σύγχρονους επεξεργαστές μπορεί και >10!)
- Εισαγωγή stalls και επομένως μείωση του ρυθμού ανάγνωσης και εκτέλεσης εντολών

#bubbles  $\sim=$  pipeline depth X loop length



# Τεχνικές βελτίωσης του CPI



# Τεχνικές Μείωσης Control Stalls

- Software
  - Μείωση των εντολών άλματος (loop unrolling)
  - Υπολογισμός της συνθήκης εκτέλεσης διακλάδωσης όσο πιο νωρίς
- Hardware
  - Αντικατάσταση των bubbles με χρήσιμη δουλειά
  - Παράλληλη εκτέλεση και των 2 ροών προγράμματος μέχρι να αποσαφηνιστεί ποιο κομμάτι της διακλάδωσης θα εκτελεστεί
  - Πρόβλεψη

# Εντολές Άλματος

- Χρειαζόμαστε 2 πληροφορίες
  - Αν θα εκτελεστεί το άλμα ή όχι (taken or not taken)
  - Αν εκτελεστεί ποιος είναι ο προορισμός (target PC)

Είδος Άλματος	Απόφαση	Προορισμός
Direct Jumps Function Calls	Always Taken	Υπολογίζεται εύκολα
Conditional Branches	???	Υπολογίζεται εύκολα
Indirect Jumps Function returns	Always Taken	Υπολογίζεται δύσκολα

# Πρόβλεψη Απόφασης

- Απαιτείται για εντολές διακλάδωσης υπό συνθήκη
  - Η πλειοψηφία των εντολών διακλάδωσης είναι υπό συνθήκη
- 2 είδη τεχνικών πρόβλεψης
  - Στατικές
  - Δυναμικές
- Απαιτείται extra hardware
  - Αποθήκευση χρήσιμων πληροφοριών για βελτίωση της ακρίβειας των προβλέψεων (branch history tables, branch target buffers, etc)
  - Μηχανισμός ανάνηψης σε περίπτωση λανθασμένης πρόβλεψης

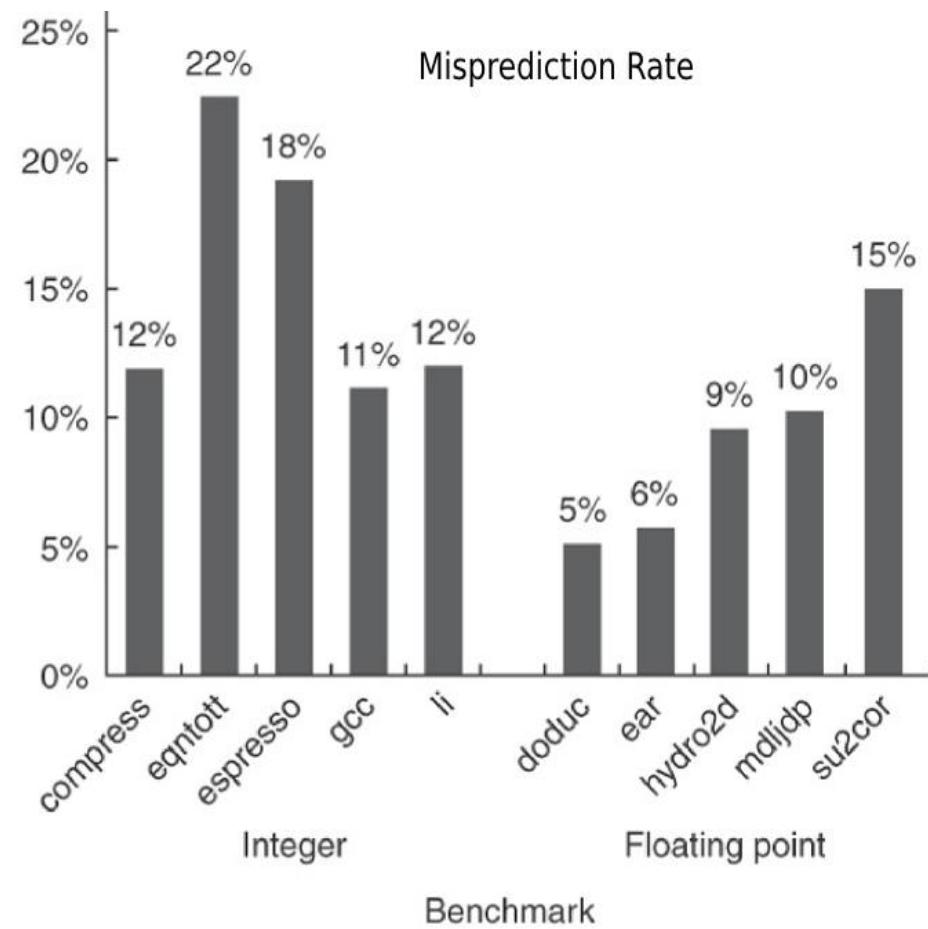
# Στατικές Τεχνικές Πρόβλεψης

- Branch not taken (NT)
  - Εύκολη υλοποίηση
  - Σε ένα loop **σωστή** πρόβλεψη μόνο στην τελευταία εκτέλεση
  - Misprediction rate ~60%-70%
- Branch taken (T)
  - Πιο πολύπλοκο hardware
  - Σε ένα loop **λάθος** πρόβλεψη μόνο στην τελευταία εκτέλεση
  - Average misprediction rate 34% (SPEC benchmarks)
- BTFNT
  - Άλματα προς τα πίσω (αρνητικό offset ως προς το PC) προβλέπεται ότι θα εκτελεστούν (Backwards taken)
  - Άλματα προς τα εμπρός (θετικό offset ως προς το PC) προβλέπεται ότι δε θα εκτελεστούν (Forwards not taken)
  - π.χ. χρησιμοποιείται στον Intel Pentium 4 σε περίπτωση που αποτύχει ο μηχανισμός δυναμικής πρόβλεψης

# Στατικές Τεχνικές Πρόβλεψης

- Profiling

- Εκτέλεση προγράμματος και καταγραφή στατιστικών
- Ο compiler τα χρησιμοποιεί για να βοηθήσει το hardware να κάνει σωστή πρόβλεψη (π.χ. αν μια εντολή διακλάδωσης εκτελείται πάνω από τις μισές φορές κατά τη διάρκεια του profiling τότε η πρόβλεψη είναι T)
- Εύκολη υλοποίηση
- Τα δεδομένα του profiling και της κανονικής εκτέλεσης μπορεί να είναι πολύ διαφορετικά. Επομένως λάθος προβλέψεις

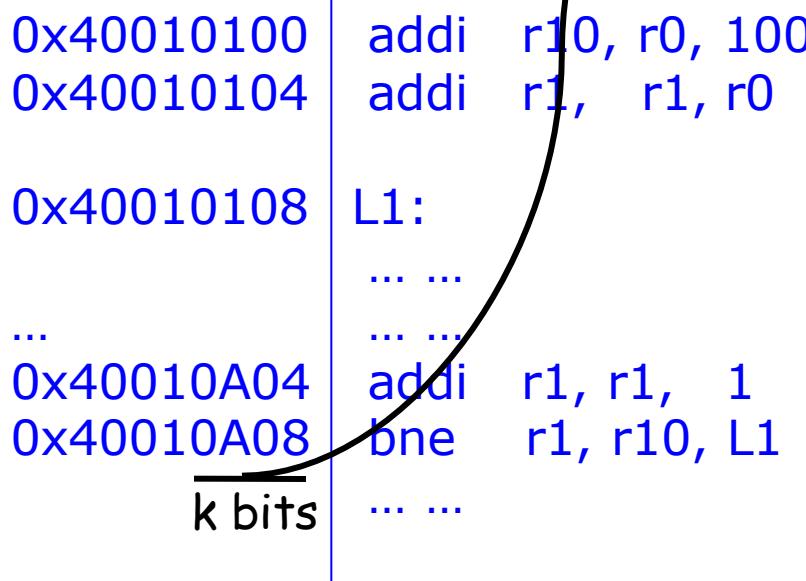


© 2007 Elsevier, Inc. All rights reserved.

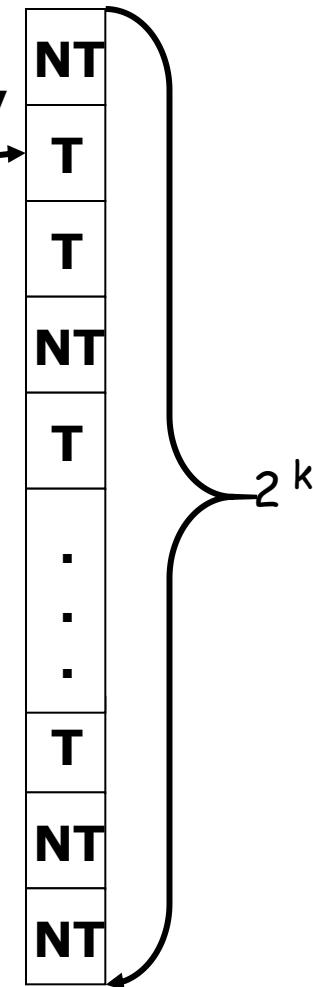
# Δυναμικές Τεχνικές Πρόβλεψης

- 1-bit predictor

- Η πρόβλεψη βασίζεται στο τι έγινε την προηγούμενη φορά που εκτελέστηκε αυτή η εντολή διακλάδωσης
- Χρήση πίνακα για την αποθήκευση της απόφασης
- Προσπέλαση του πίνακα χρησιμοποιώντας k bits του PC
  - » Aliasing



**1-bit  
Branch  
History  
Table**



# Παράδειγμα 1-bit predictor

0x108: **for(i=0; i < 100000; i++) {**

.....

0x144:   **if( ( i % 100) == 0 )**  
             **callA( );**

0x150:   **if( (i & 1) == 1)**  
             **callB( );**

}

**Πρόβλεψη (108):**

(0)

💀

**Απόφαση (108):**

(T)

# Παράδειγμα 1-bit predictor

0x108: `for(i=0; i < 100000; i++) {`

.....

0x144: `if( ( i % 100) == 0 )`

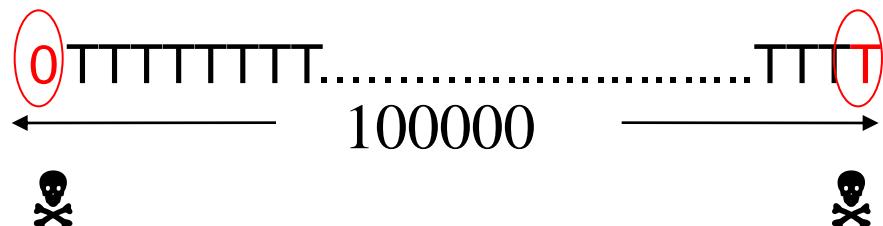
`callA();`

0x150: `if( (i & 1) == 1)`

`callB();`

}

Πρόβλεψη (108):



Απόφαση (108):



# Παράδειγμα 1-bit predictor

0x108: `for(i=0; i < 100000; i++) {`

.....

0x144: `if( ( i % 100) == 0 )`

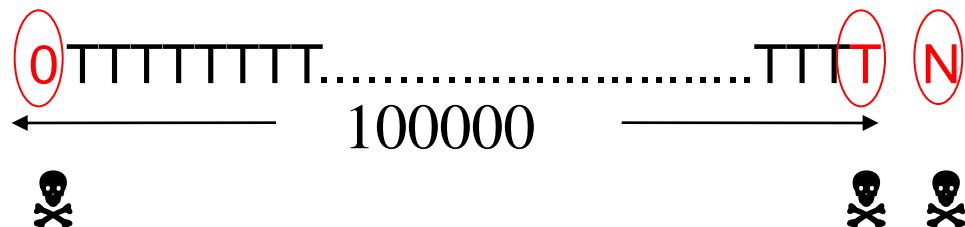
`callA();`

0x150: `if( (i & 1) == 1)`

`callB();`

}

Πρόβλεψη (108):



Απόφαση (108):



# Παράδειγμα 1-bit predictor

0x108: for(i=0; i < 100000; i++) {

.....

0x144: if( ( i % 100) == 0 )  
          callA();

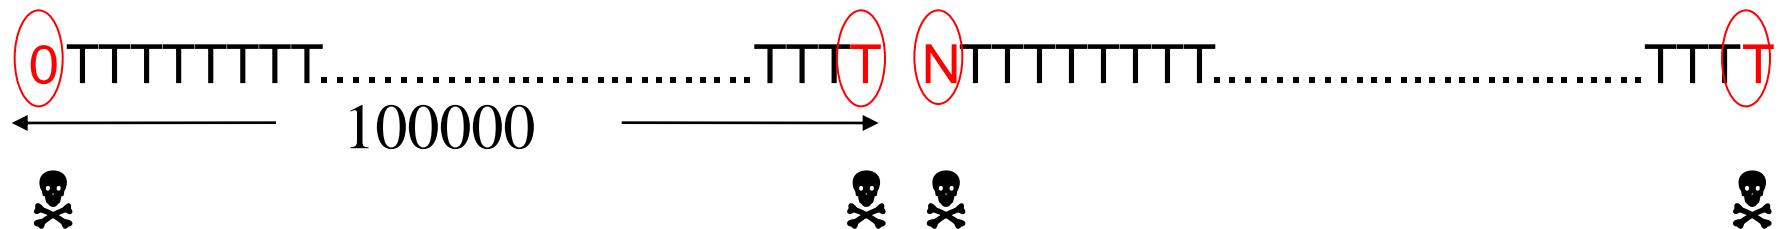
0x150: if( (i & 1) == 1)  
          callB();

}

Misprediction = 2/100000

Prediction Rate = 99.998%

Πρόβλεψη (108):



Απόφαση (108):



# Παράδειγμα 1-bit predictor

0x108: for(i=0; i < 100000; i++) {

.....  
0x144: if( ( i % 100) == 0 )  
        callA();

0x150: if( (i & 1) == 1)  
        callB();

}



DIV	R2 , #100
MFHI	R1
BNEZ	R1 , 0x150
JMP	FUNA

Πρόβλεψη (144):

0



Απόφαση (144):

N

# Παράδειγμα 1-bit predictor

0x108: for(i=0; i < 100000; i++) {

.....  
0x144: if( ( i % 100) == 0 )  
        callA();

0x150: if( (i & 1) == 1)  
        callB();

}



```
DIV    R2 , #100  
MFHI   R1  
BNEZ   R1 , 0x150  
JMP    FUNA
```

Πρόβλεψη (144):



Απόφαση (144):



# Παράδειγμα 1-bit predictor

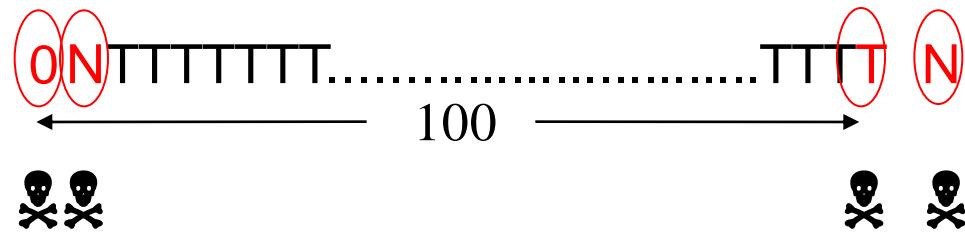
0x108: for(i=0; i < 100000; i++) {

0x144: if( ( i % 100) == 0 )  
callA( );

0x150: if( (i & 1) == 1)  
callB( );

}

## Πρόβλεψη (144):



## Απόφαση (144):



cslab@ntua 2013-2014

# Παράδειγμα 1-bit predictor

0x108: for(i=0; i < 100000; i++) {

.....

0x144: if( ( i % 100) == 0 )  
          callA();

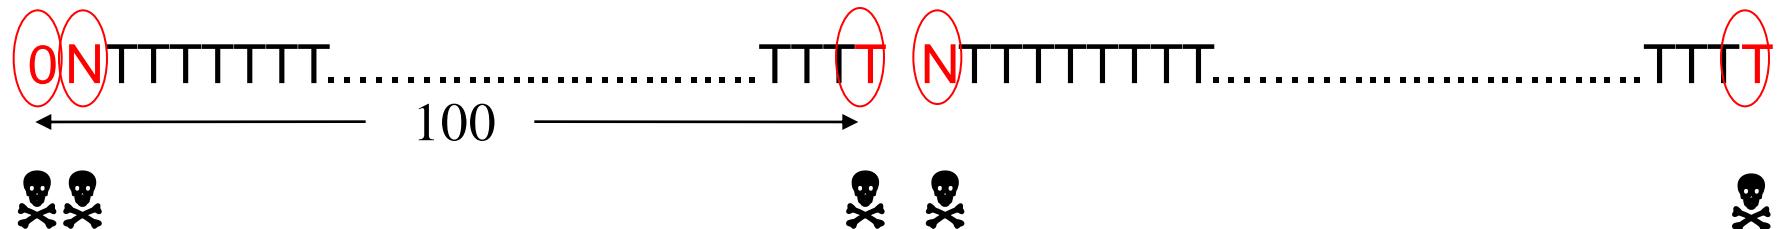
0x150: if( (i & 1) == 1)  
          callB();

}

Misprediction = 2/100

Prediction Rate = 98%

Πρόβλεψη (144):



Απόφαση (144):



# Παράδειγμα 1-bit predictor

0x108: for(i=0; i < 100000; i++) {

.....

0x144: if( ( i % 100) == 0 )

    callA();

0x150: if( (i & 1) == 1)

    callB();

}



AND	R1,R2,#1
SUB	R1,#1
BNEZ	R1,ENDLOOP
JMP	FUNB

Πρόβλεψη (150):

0

💀

Απόφαση (150):

T

# Παράδειγμα 1-bit predictor

0x108: for(i=0; i < 100000; i++) {

.....

0x144: if( ( i % 100) == 0 )

    callA();

0x150: if( (i & 1) == 1)

    callB();

}



AND	R1,R2,#1
SUB	R1,#1
BNEZ	R1,ENDLOOP
JMP	FUNB

Πρόβλεψη (150):

(O)(T)

💀 💀

Απόφαση (150):

(T)(N)

# Παράδειγμα 1-bit predictor

0x108: for(i=0; i < 100000; i++) {

.....

0x144: if( ( i % 100) == 0 )

    callA();

0x150: if( (i & 1) == 1)

    callB();

}



AND	R1,R2,#1
SUB	R1,#1
BNEZ	R1,ENDLOOP
JMP	FUNB

Πρόβλεψη (150):

(O)(T)(N)

💀 💀 💀

Απόφαση (150):

(T)(N)(T)

# Παράδειγμα 1-bit predictor

0x108: for(i=0; i < 100000; i++) {

```
0x144:    if( ( i % 100) == 0 )
                    callA( );
0x150:    if( (i & 1) == 1)
                    callB( );
}
```

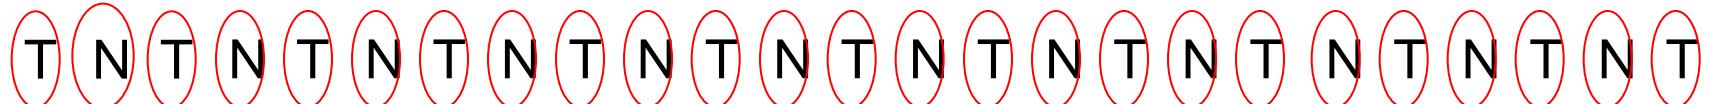
## Misprediction = 1/1

## Prediction Rate = 0%

## Πρόβλεψη (150):

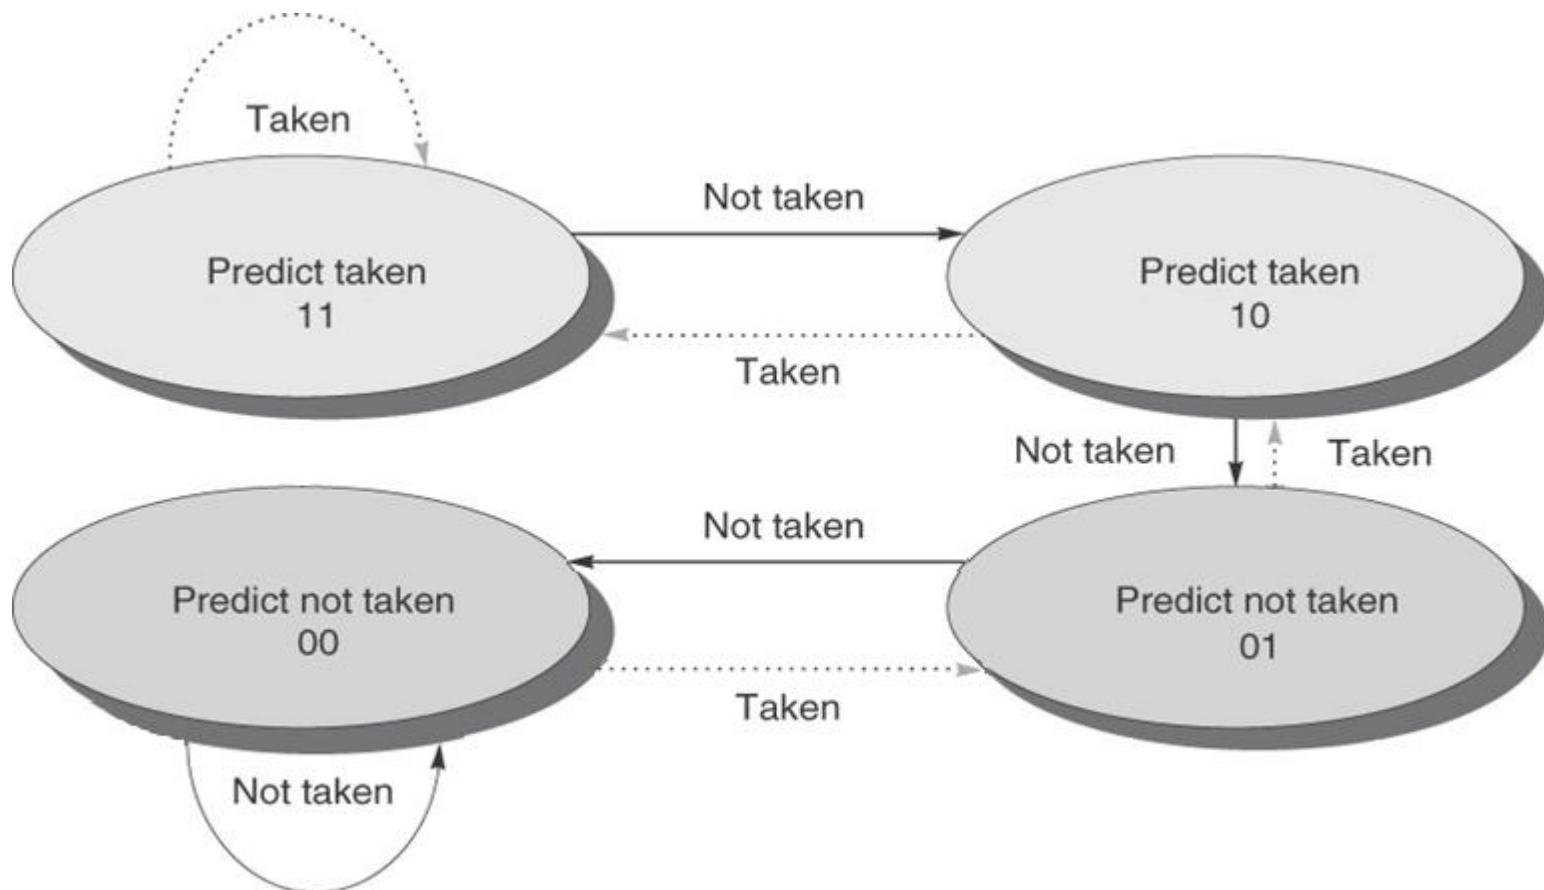


## Απόφαση (150):



# Δυναμικές Τεχνικές Πρόβλεψης

- 2-bit predictor



## Παράδειγμα 2-bit predictor

0x108: for(i=0; i < 100000; i++) {

0x144: if( ( i % 100) == 0 )  
callA( );

**0x150:**      if( (i & 1) == 1)  
                  callB();

}

0,1 :Predict Not Taken

## 2,3:Predict Taken

## Πρόβλεψη (108):

1



## **Απόφαση (108):**

T

# Παράδειγμα 2-bit predictor

0x108: for(i=0; i < 100000; i++) {

.....

0x144: if( ( i % 100) == 0 )  
          callA();

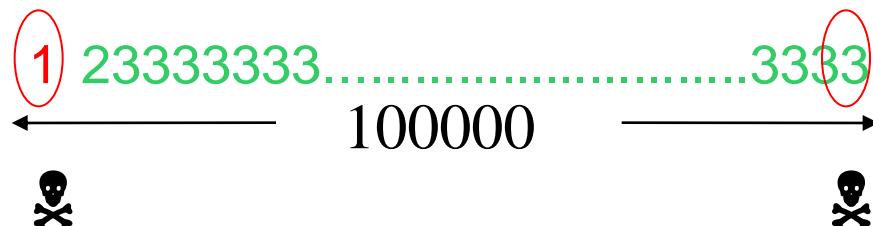
0x150: if( (i & 1) == 1)  
          callB();

}

0,1 :Predict Not Taken

2,3 :Predict Taken

Πρόβλεψη (108):



Απόφαση (108):



# Παράδειγμα 2-bit predictor

0x108: for(i=0; i < 100000; i++) {

.....

0x144: if( ( i % 100) == 0 )  
          callA();

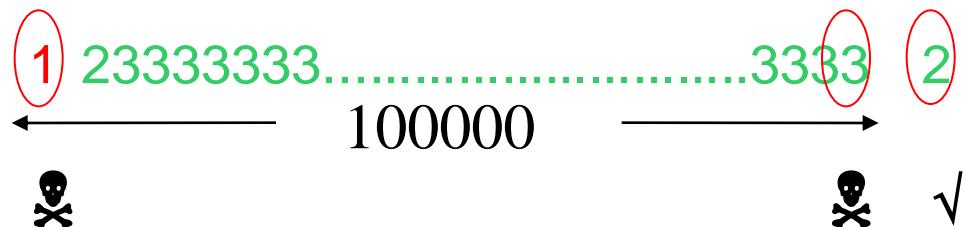
0x150: if( (i & 1) == 1)  
          callB();

}

0,1 :Predict Not Taken

2,3 :Predict Taken

Πρόβλεψη (108):



Απόφαση (108):



# Παράδειγμα 2-bit predictor

```
0x108: for(i=0; i < 100000; i++) {  
    .....  
0x144: if( ( i % 100) == 0 )  
        callA();  
0x150: if( (i & 1) == 1)  
        callB();  
}
```

Misprediction  $\sim= 1$  per N branches

0x108 Prediction Rate = 99.999%

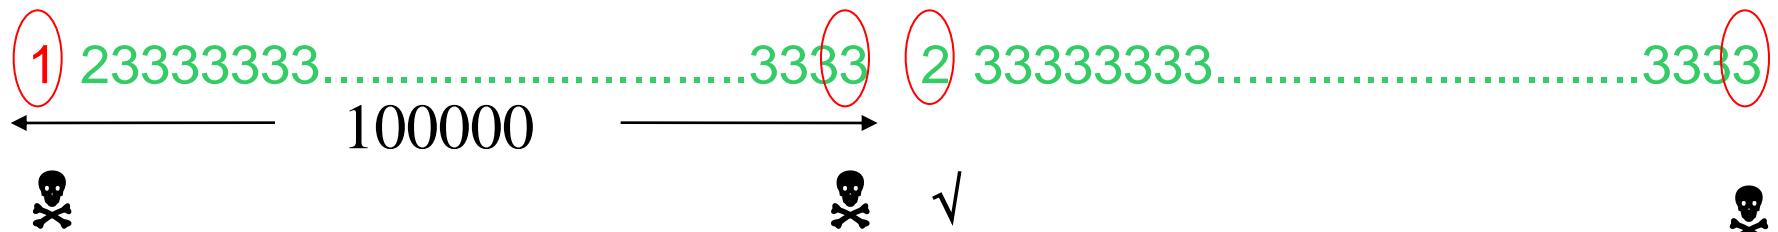
0x144 Prediction Rate = 99%

0x150 Prediction Rate = 50%

0,1 :Predict Not Taken

2,3 :Predict Taken

Πρόβλεψη (108):

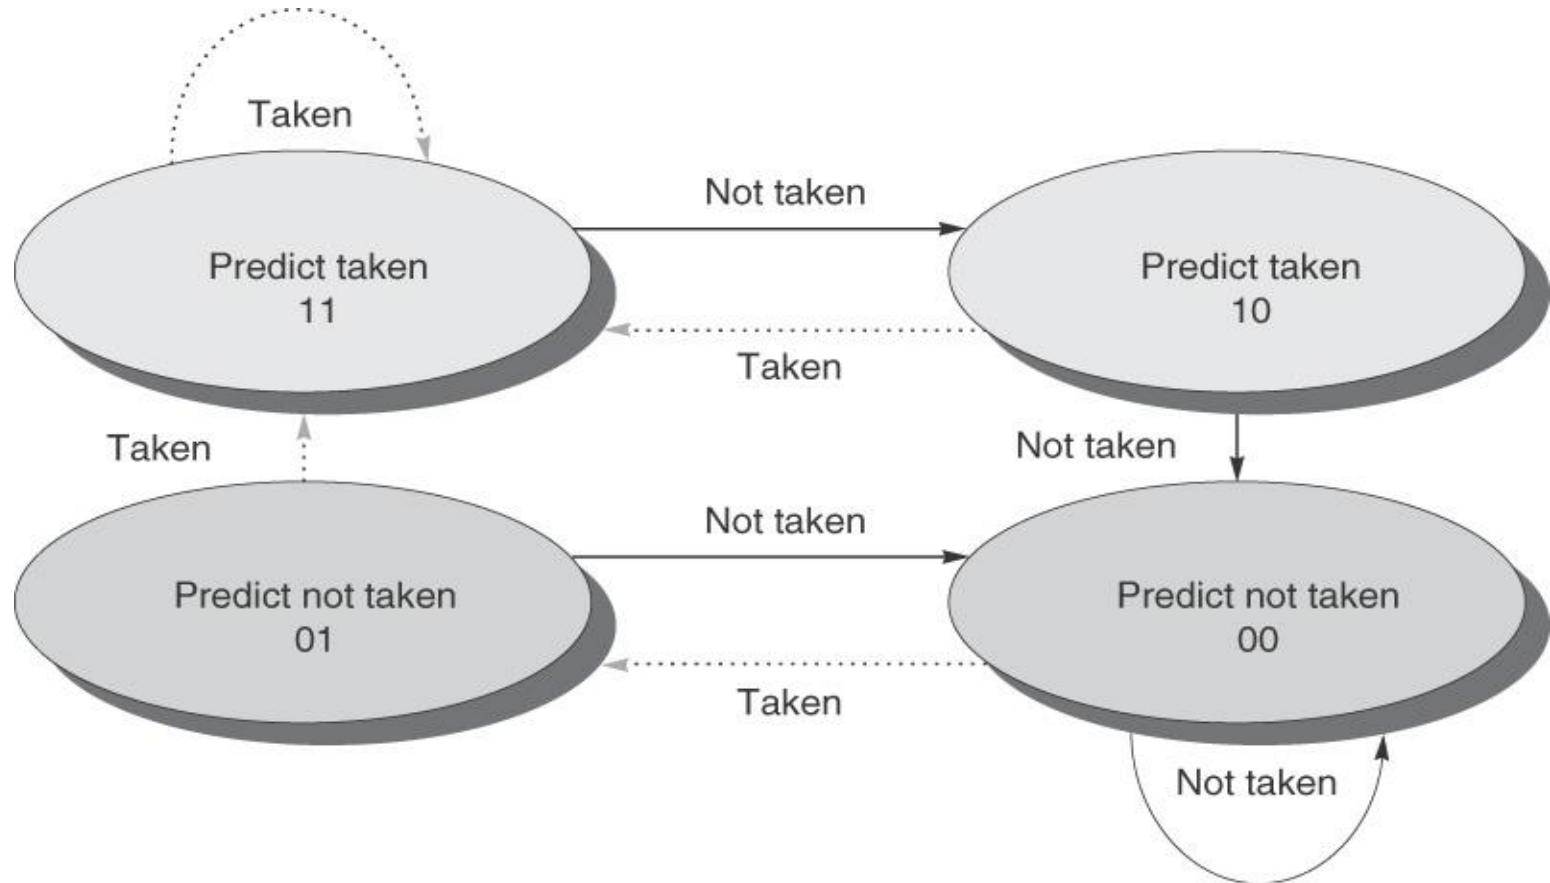


Απόφαση (108):



# Δυναμικές Τεχνικές Πρόβλεψης

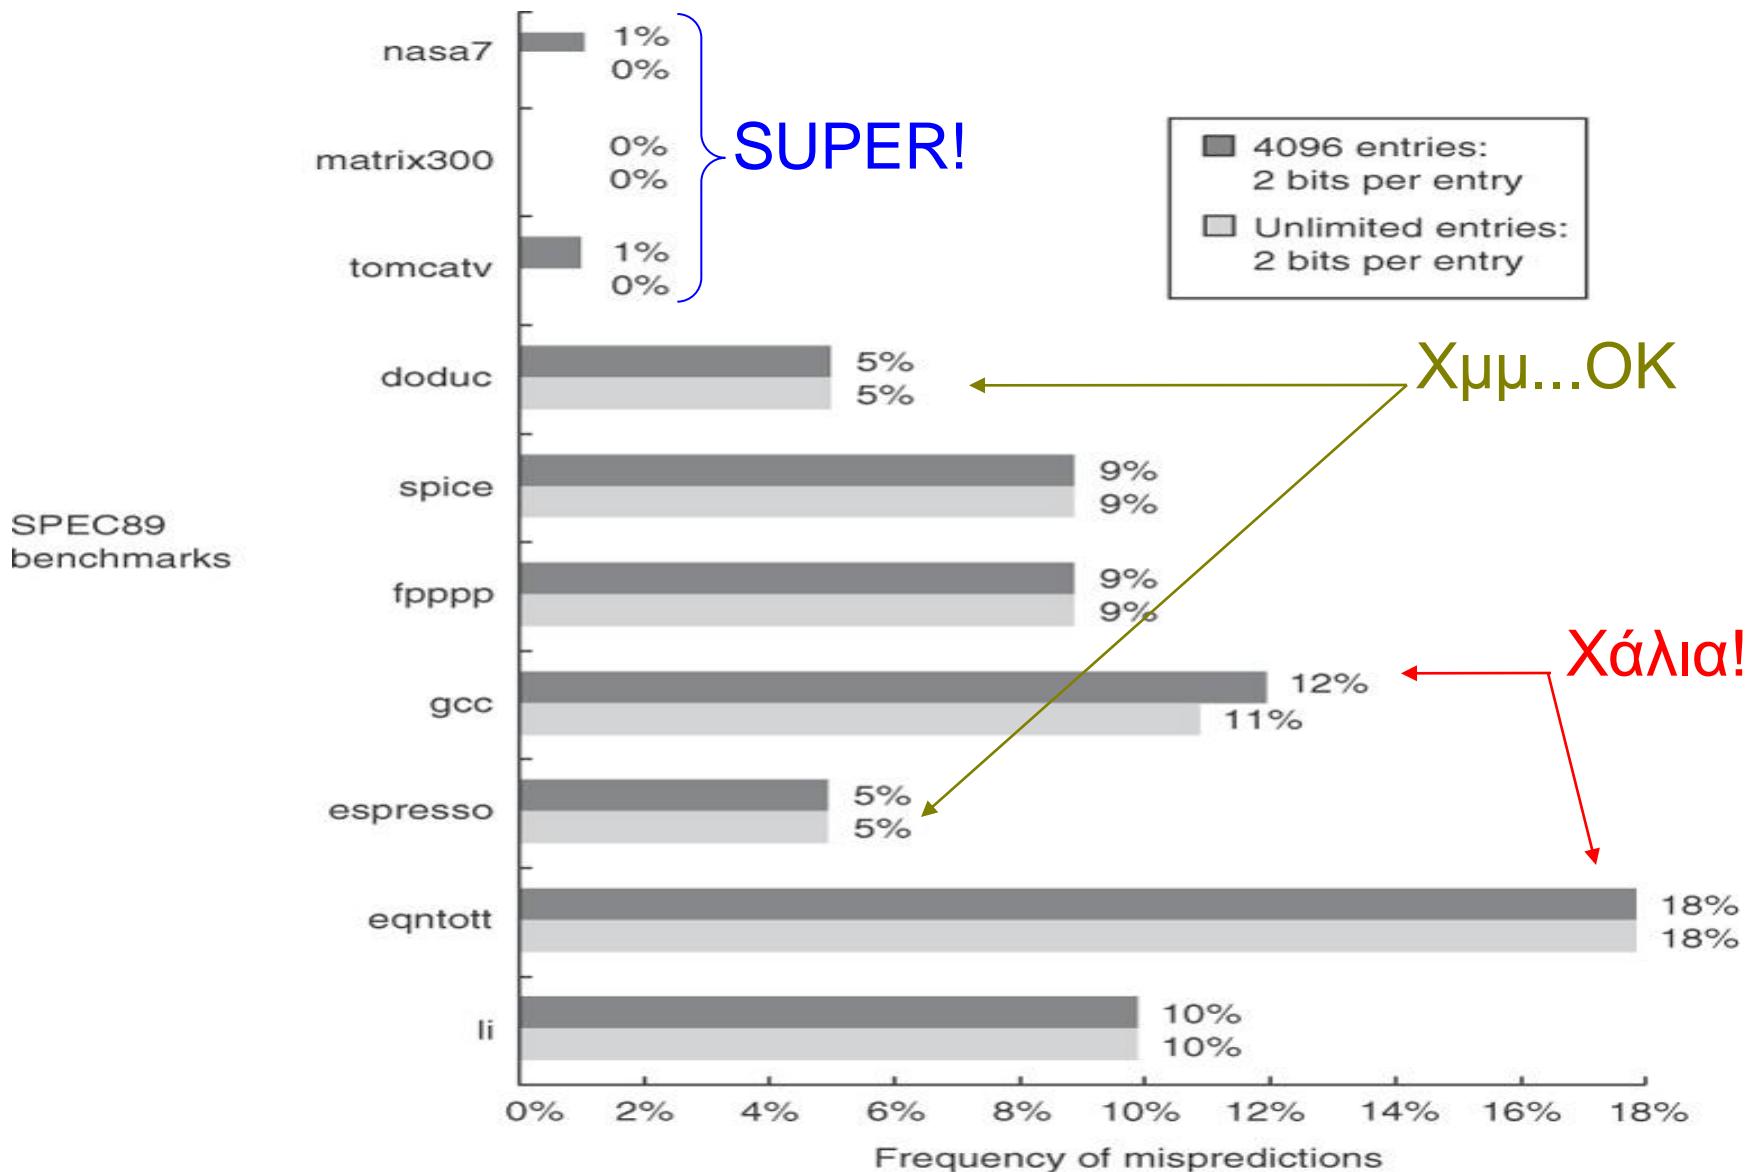
- Άλλος 2-bit predictor



© 2007 Elsevier, Inc. All rights reserved.

- $2^{20}$  δυνατά FSMs  $\rightarrow$  5248 “ενδιαφέροντα” [Nair, 1992]

# Ακρίβεια Πρόβλεψης για 2-bits predictor



# Δυναμικές Τεχνικές Πρόβλεψης

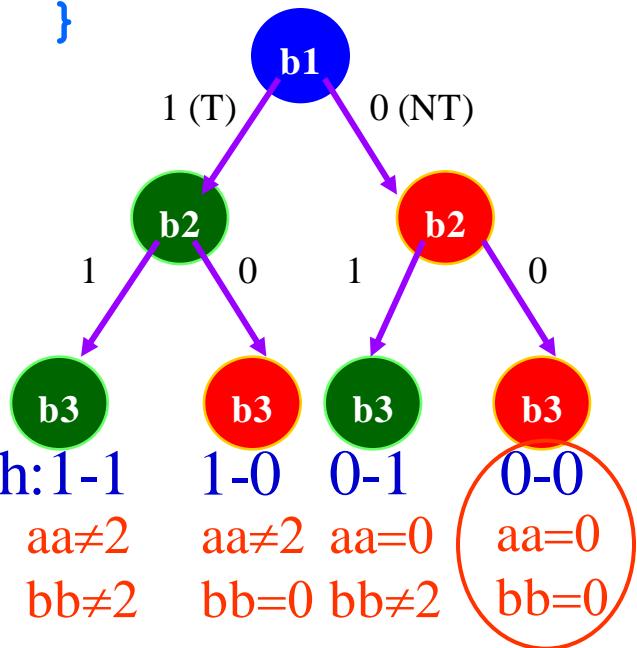
- **Χρονική Συσχέτιση** (Temporal Correlation)
  - Όλες οι προηγούμενες τεχνικές προβλέπουν το αποτέλεσμα μιας εντολής διακλάδωσης με βάση τις αποφάσεις που πάρθηκαν σε προηγούμενες εκτελέσεις
- **Τοπική Συσχέτιση** (Spatial Correlation)
  - Πρόβλεψη μιας εντολής διακλάδωσης με βάση τη συμπεριφορά άλλων εντολών διακλάδωσης που προηγούνται στη ροή του προγράμματος

# Παράδειγμα

```

if (aa==2)
    aa = 0;
if (bb == 2)
    bb = 0;
if (aa != bb) {
.....
}

```



DADDIU R3,R1,#-2		
BNEZ R3,L1	;branch b1 (aa!=2)	
DADD R1,R0,R0	;aa=0	
L1:DADDIU R3,R2,#-2		
BNEZ R3,L2	;branch b2 (bb!=2)	
DADD R2,R0,R0	;bb=0	
L2:DSUBU R3,R1,R2 ;R3=aa-bb		
BEQZ R3,L3	;branch b3 (aa==bb)	

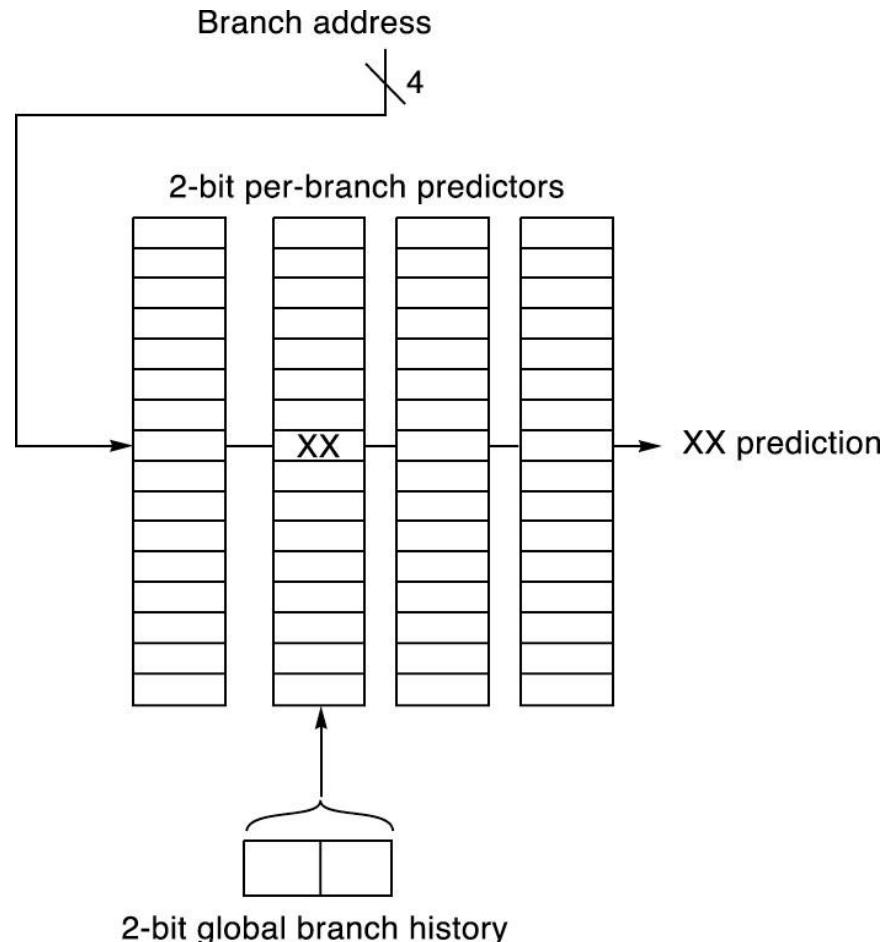
**Av b1 και b2 NT (Not Taken) τότε b3 T (Taken) !**

# Correlating/Two-level Predictors

- Γενική περίπτωση : (m,n) predictor
  - m τελευταίες εντολές διακλάδωσης
  - επιλογή ενός από  $2^m$  predictors
  - Κάθε predictor είναι n-bits
- Ο **2-bit predictor** είναι ένας (0,2) predictor αφού δεν χρησιμοποιεί την ιστορία των άλλων εντολών διακλάδωσης
- Απλή υλοποίηση
  - Branch History Register (BHR) : m-bit shift register για να καταγράφει τη συμπεριφορά των τελευταίων m εντολών διακλάδωσης
  - Pattern History Table (PHT) : Ο πίνακας που αποθηκεύονται οι predictors

# Global-History Two-Level Predictor

- (2,2) predictor
- 64 entries
- 4 low order bits PC
- 2 bits global history



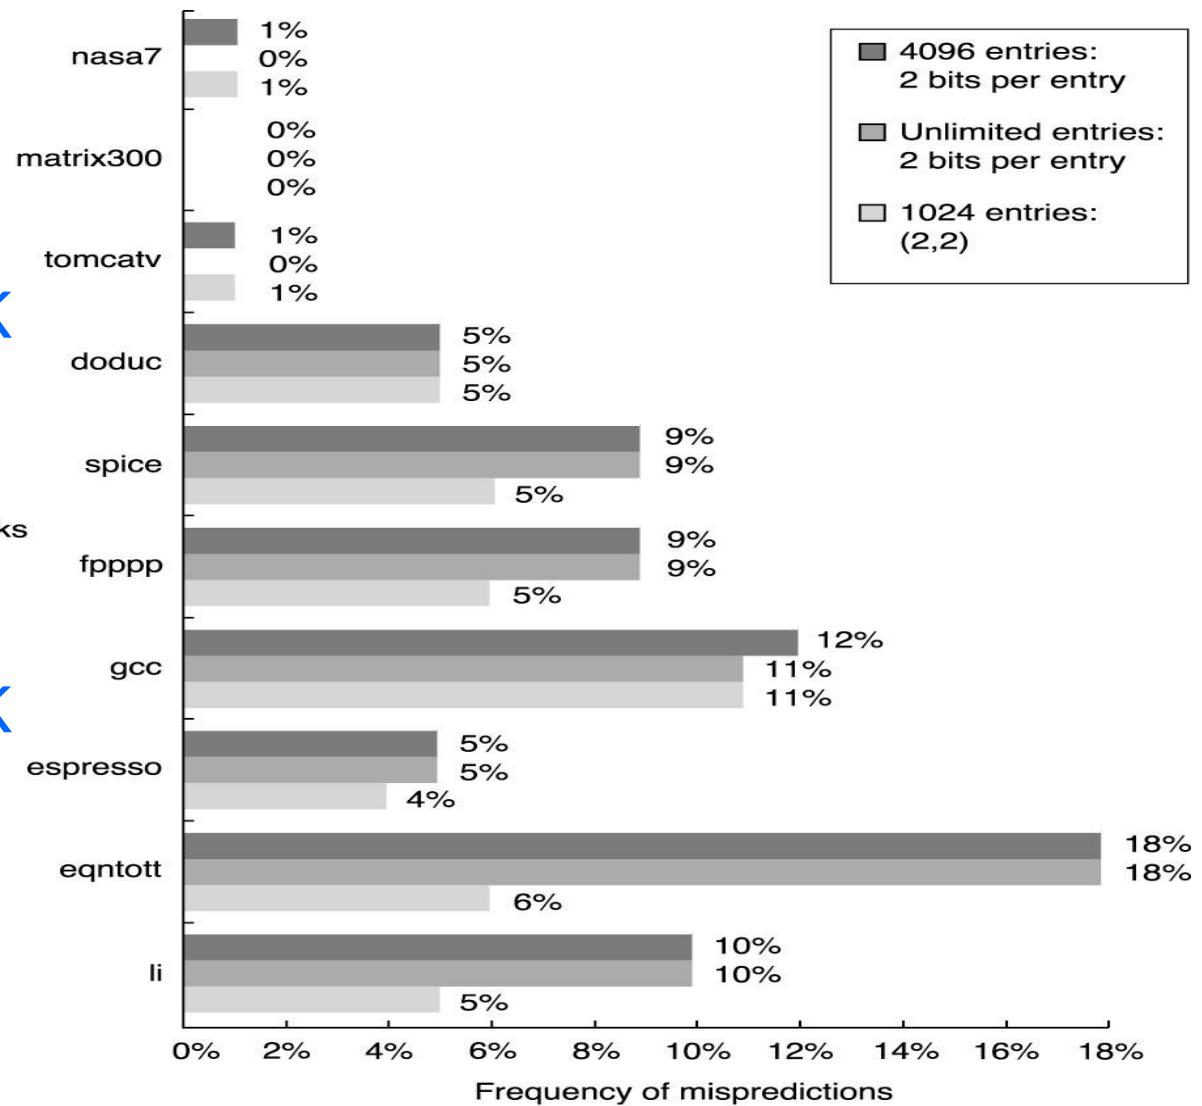
# Σύγκριση

- (0,2) predictor με 4096 εγγραφές (8K bits)

VS

SPEC89 benchmarks

- (2,2) predictor με 1024 εγγραφές (8K bits)



# Local-History Two-Level Predictor

- Αντί για τις τελευταίες εντολές διακλάδωσης, παρακολουθούμε τις τελευταίες εκτελέσεις της συγκεκριμένης εντολής
- Ο BHR αντικαθίσταται από τον BHT (Branch History Table)
  - 1 BHR ανά εντολή διακλάδωσης
- Ο global-history predictor αποτελεί ουσιαστικά υποπερίπτωση, όπου ο BHT έχει μόνο μια εγγραφή

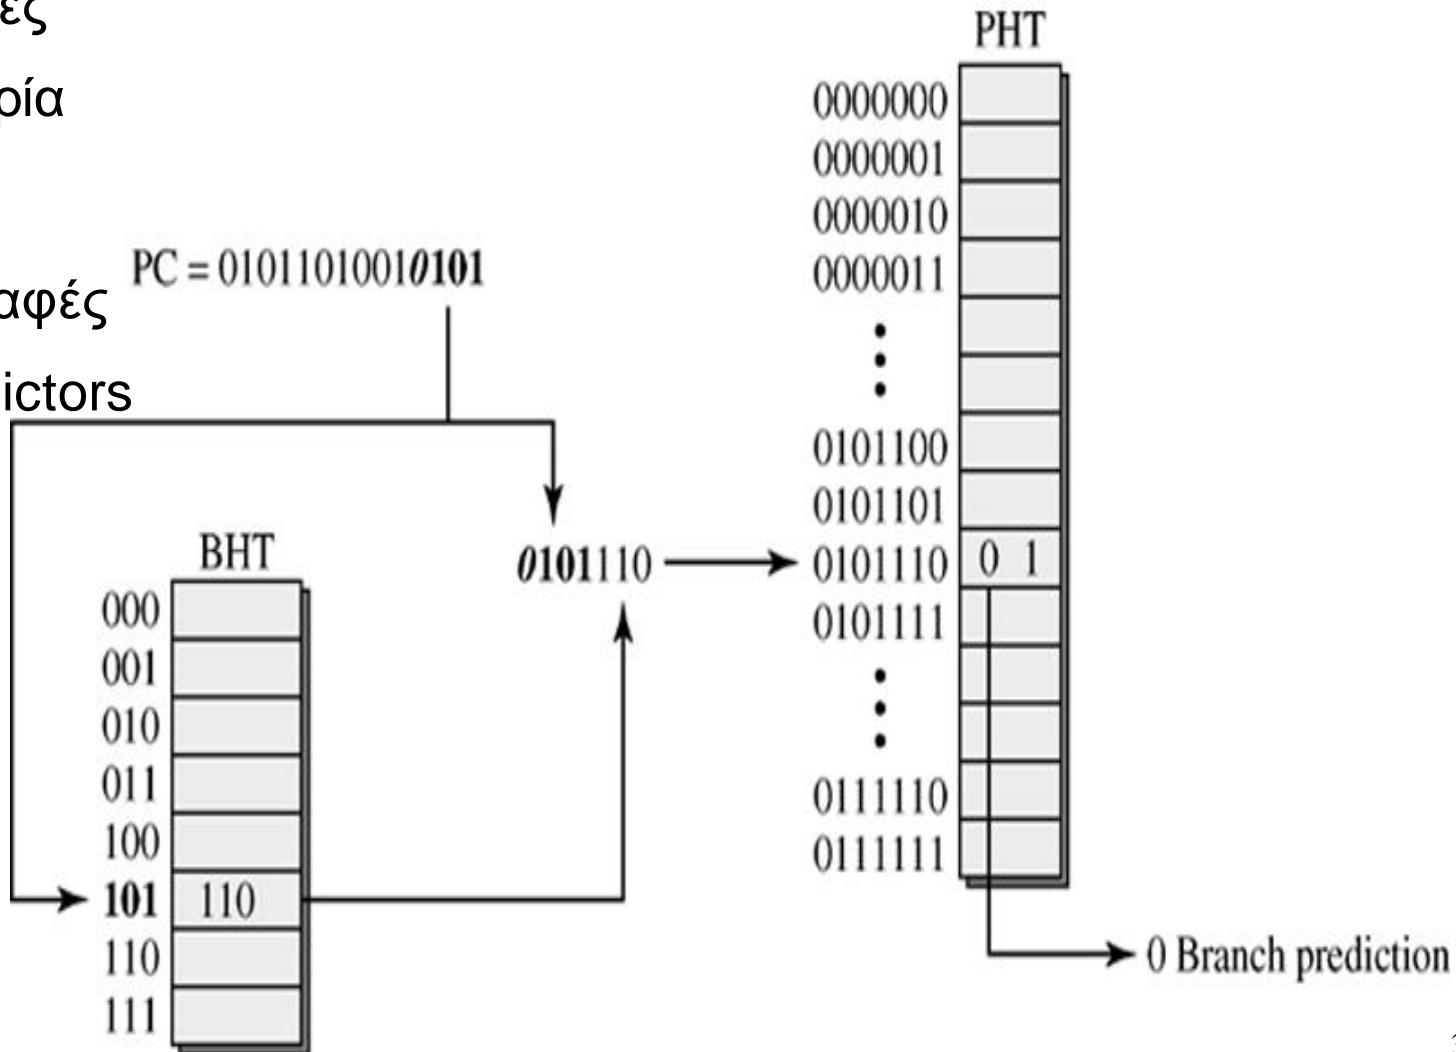
# Local-History Two-Level Predictor

- BHT

- 8 εγγραφές
- 3-bit ιστορία

- PHT

- 128 εγγραφές
- 2-bit predictors



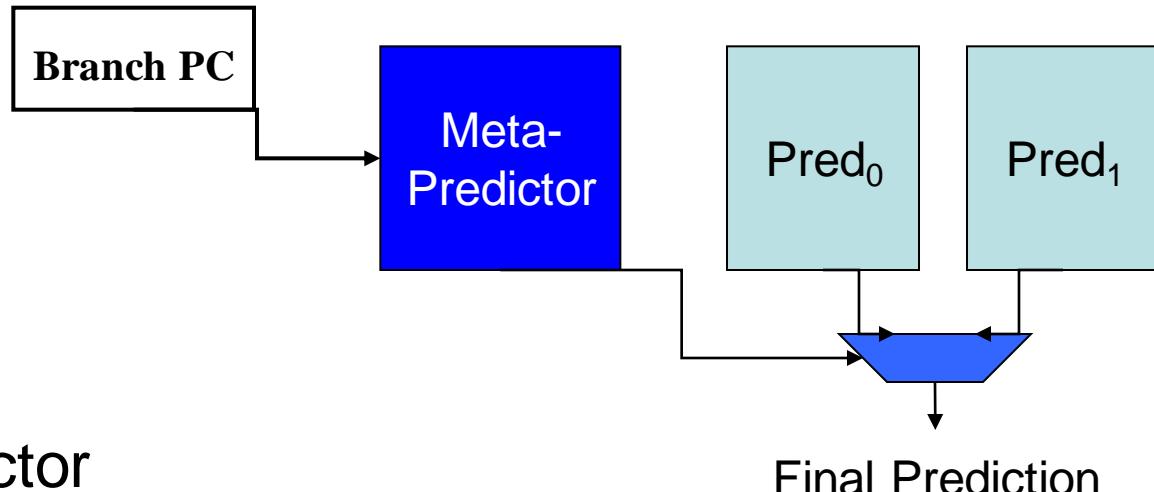
# Tournament Predictors

- Δεν υπάρχει τέλειος predictor
  - Διαφορετικές εντολές άλματος παρουσιάζουν διαφορετική συμπεριφορά
- ΙΔΕΑ ??????
- Να κατασκευάσουμε ένα predictor που θα μαντεύει ποιος predictor μπορεί να μαντέψει ακριβέστερα το αποτέλεσμα ενός άλματος!

# Tournament Hybrid Predictor

- meta-predictor

- 2-bit μετρητές
- 0,1 χρησιμοποιείται ο  $P_0$
- 2,3 χρησιμοποιείται ο  $P_1$



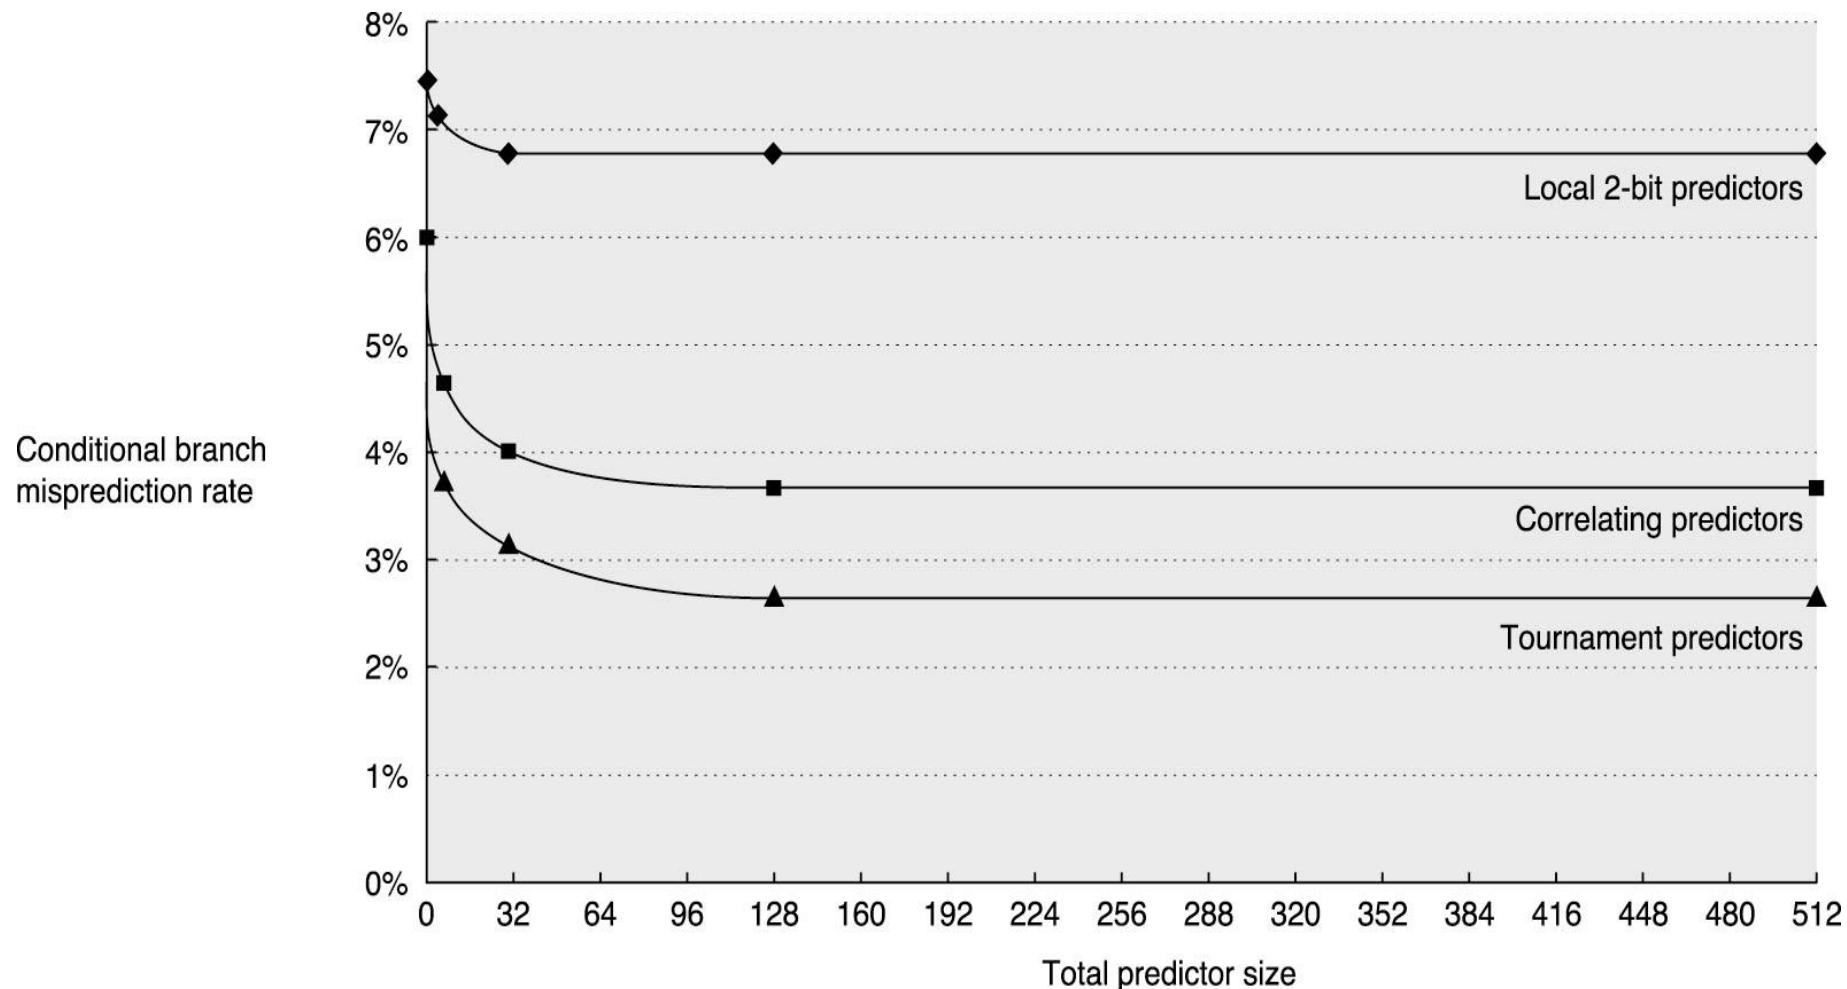
- Η τιμή του meta-predictor ενημερώνεται μόνο όταν οι δύο predictors κάνουν διαφορετική πρόβλεψη
- $Pred_0$ ,  $Pred_1$ 
  - Συνδυασμοί των προηγουμένων συστημάτων

$Pred_0$	$Pred_1$	Meta Update
Λάθος	Λάθος	---
Λάθος	Σωστή	+1
Σωστή	Λάθος	-1
Σωστή	Σωστή	---

# Παράδειγμα: Alpha 21264

- Meta-predictor
  - 4K εγγραφές
  - κάθε εγγραφή είναι ένας 2-bit predictor
  - προσπέλαση με βάση το PC της εντολής διακλάδωσης
- $\text{Pred}_0$  : Local-history two-level predictor
  - BHT: 1K 10-bit εγγραφές
  - PHT: 1K 3-bit predictors
- $\text{Pred}_1$  : Global-history two-level predictor
  - PHT: 4K 2-bit predictors
- Σύνολο : 29K bits
- SPECfp95 : misprediction = 1 / 1000 instructions
- SPECint95: misprediction = 11.5/1000 instructions

# Σύγκριση Δυναμικών Τεχνικών Πρόβλεψης



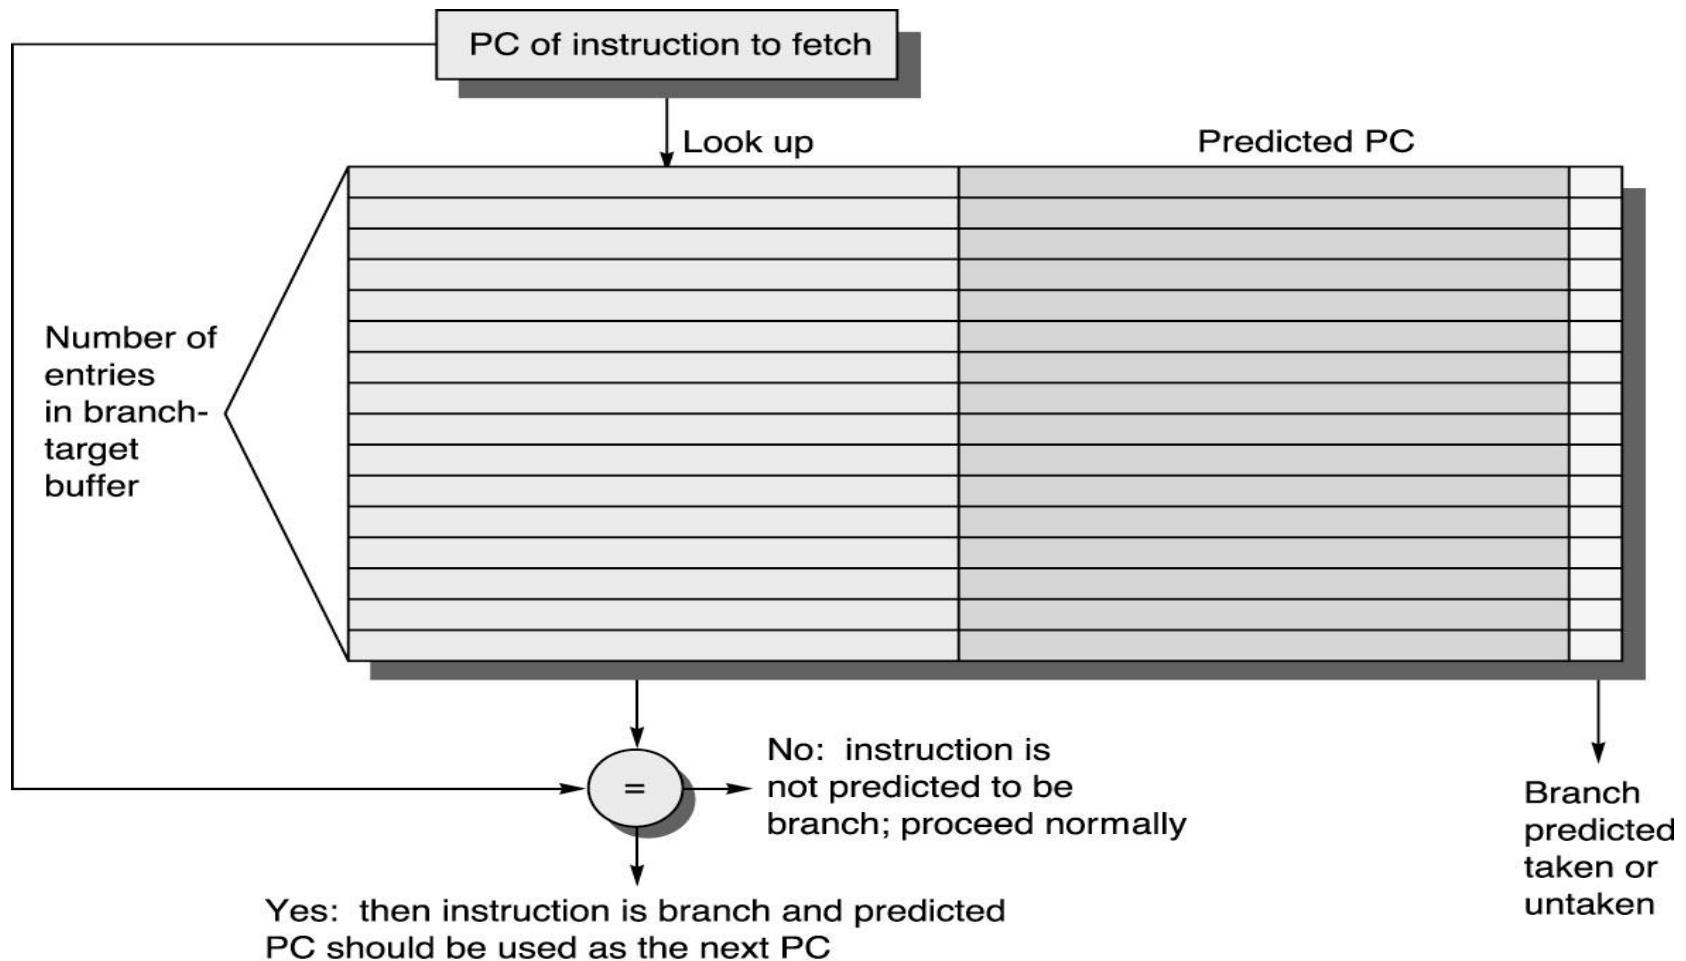
# Πρόβλεψη Προορισμού

- Όλα τα προηγούμενα συστήματα προβλέπουν μόνο το ποιο μονοπάτι μιας εντολής διακλάδωσης θα ακολουθηθεί
- Χρειάζεται όμως και ο προορισμός-στόχος (target)
  - Not taken: Προορισμός = PC + instruct\_word\_size
  - Taken : Προορισμός = ???
    - » Άμεσος : PC + offset
    - » Έμμεσος : register\_value + offset (π.χ. Object-oriented programs, subroutines returns, dynamically linked libraries)
- Για να διατηρήσουμε υψηλό throughput πρέπει στο τέλος κάθε κύκλου να γνωρίζουμε το επόμενο PC
- Για κάποια áλματα με έμμεσο προορισμό, γίνεται γνωστός μετά το EX
- Ακόμα και για τα υπόλοιπα πρέπει να περιμένουμε μέχρι το τέλος του ID

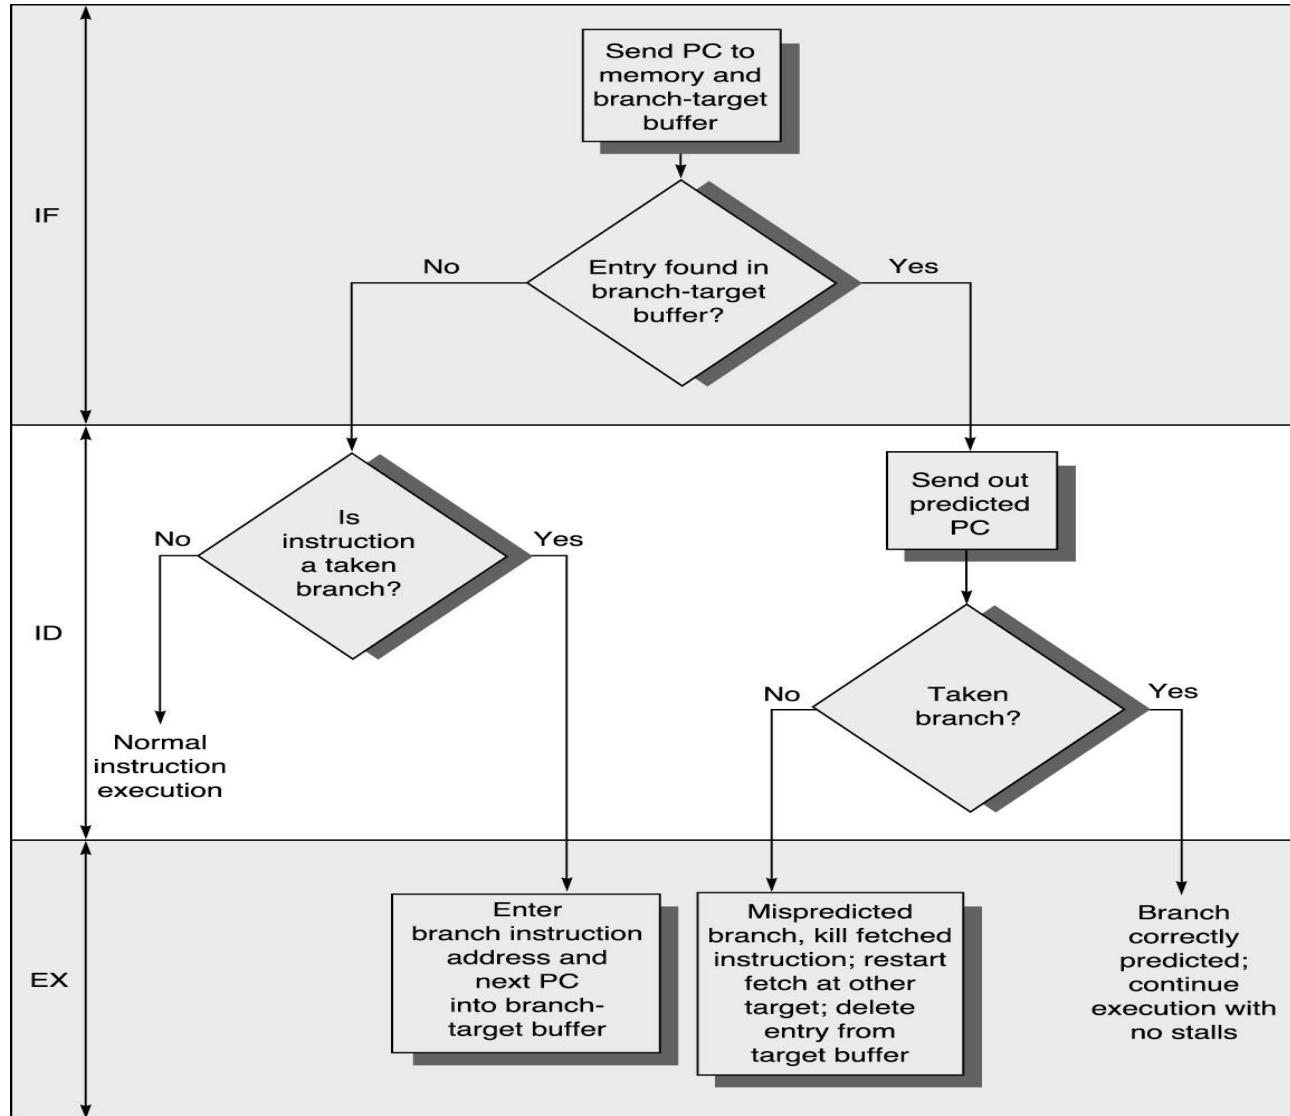
# Branch-Target Buffer (BTB)

- Μια μικρή cache (direct-mapped / associative)
- Αποθηκεύει τον προορισμό (target) της εντολής áλματος
- Προσπέλαση κατά τη διάρκεια του IF, ώστε την ώρα που φέρνουμε μια εντολή ταυτόχρονα προβλέπουμε από που θα χρειαστεί να φέρουμε την επόμενη
- Περιέχει
  - Instruction Address
  - Predicted PC
- Αποθηκεύουμε μόνο áλματα που έχουν εκτελεστεί (taken branches και jumps)

# Branch-Target Buffer



# Χρήση BTB



# Return Address Stack (RAS)

- SPEC89 : 85% των έμμεσων αλμάτων είναι function returns
- Προορισμός
  - Δύσκολος να υπολογιστεί. Γίνεται γνωστός μετά το EX.
  - Δύσκολα μπορεί να προβλεφθεί με τον BTB, μιας και ένα function μπορεί να κληθεί από πολλά διαφορετικά σημεία.

# Return Address Stack (RAS)

- Ο προορισμός ενός return είναι **ΠΑΝΤΑ** η επόμενη διεύθυνση της τελευταίας εντολής call
- Χρήση ενός stack (FILO)
  - Εκτέλεση **call** → push address into RAS
  - Εκτέλεση **return** → pop address into RAS

# Return Address Stack (RAS)

