Ασκήσεις Caches

Άσκηση 1η

Θεωρήστε ένα σύστημα μνήμης με μία cache:

- 4-way set associative
- μεγέθους 256KB,
- με cache line 8 λέξεων.

Χαρακτηριστικά συστήματος μνήμης:

- μέγεθος της λέξης είναι 32 bits.
- 1 byte η μικρότερη μονάδα δεδομένων που μπορεί να διευθυνσιοδοτηθεί
- 64 bit εύρος διευθύνσεων μνήμης

Ζητούμενο

Για τα **επιμέρους πεδία** στα οποία χωρίζεται μία **διεύθυνση μνήμης** σε μία τέτοια οργάνωση cache, **υπολογίστε τον αριθμό των bits του καθενός**.

Παρουσιάστε ένα διάγραμμα που να δείχνει πώς διαχωρίζεται η διεύθυνση στα πεδία αυτά, και **εξηγείστε τη σημασία του καθενός**.

Σκεπτικό

Μία διεύθυνση

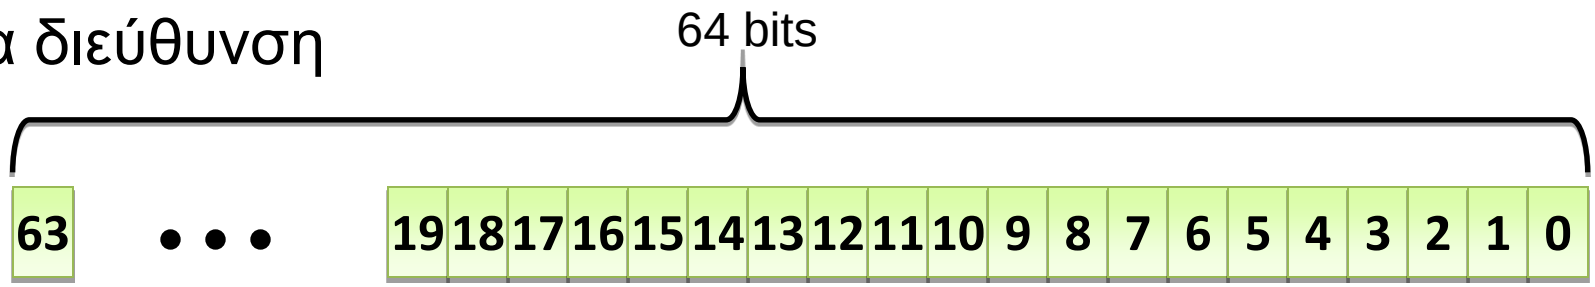

χωρίζεται στα πεδία

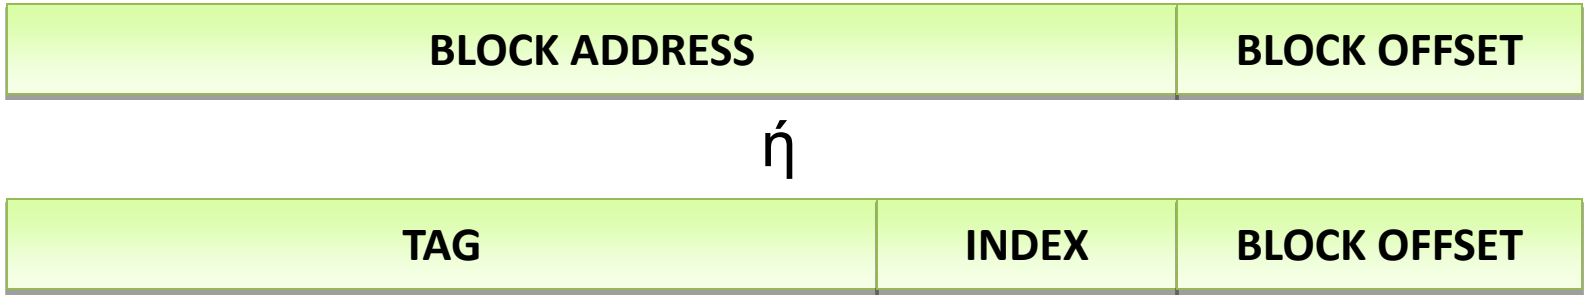

Πόσα bits είναι το εύρος κάθε πεδίου;

Το μέγεθος της λέξης είναι 32 bits

32bits = 4Bytes
32b = 4B

Το μέγεθος της λέξης είναι 32 bits

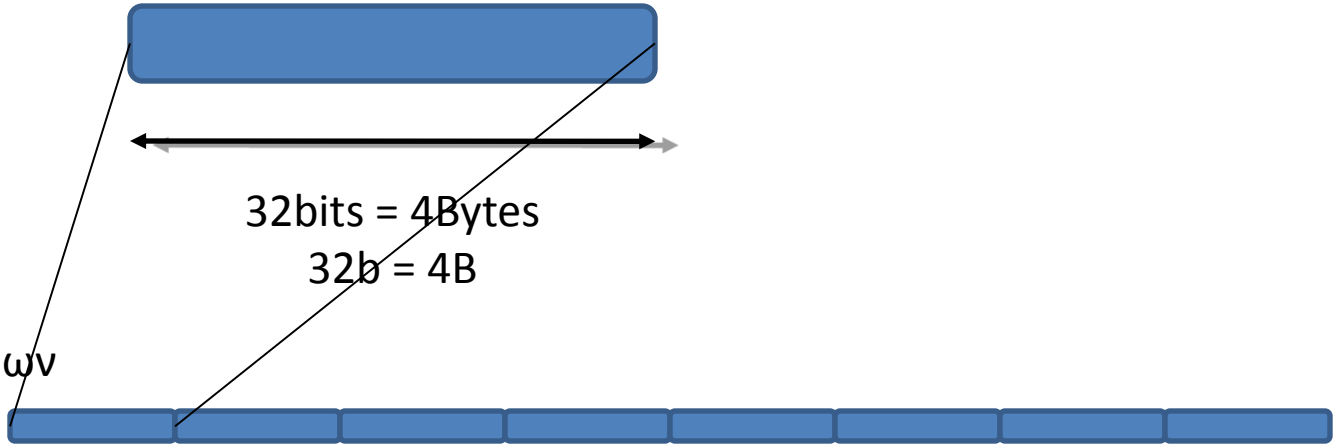

... cache block 8 λέξεων

ένα cache block αποτελείται από 8 words

Μία διεύθυνση

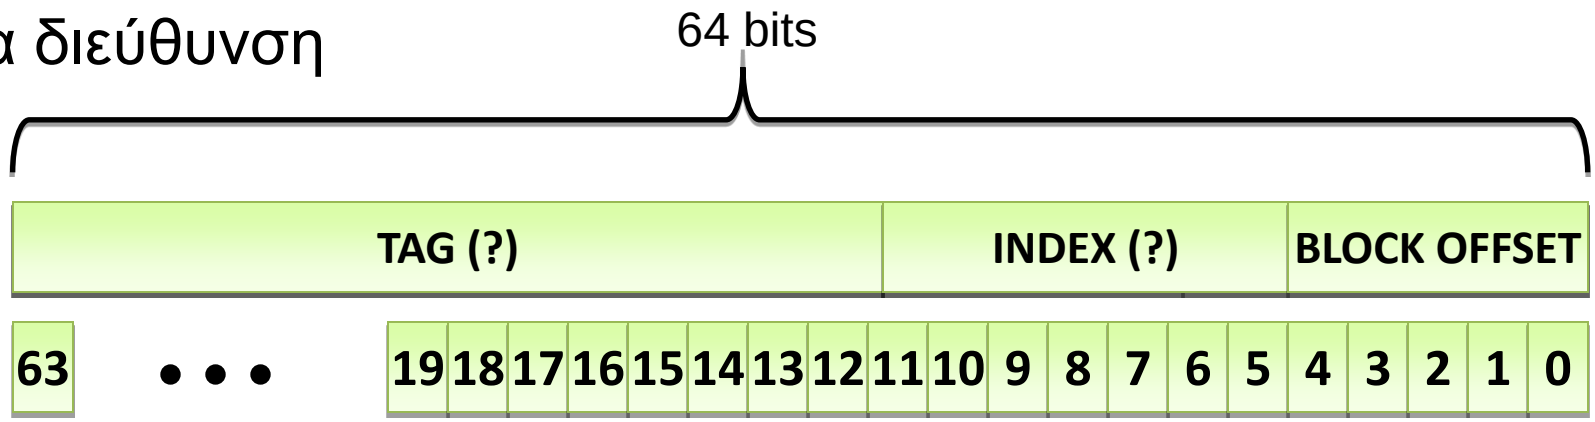

8 words 4 words 2 words 1 word 2 bytes

32 bytes 16 bytes 8 bytes 4 bytes

ένα cache block αποτελείται από 8 words

BLOCK OFFSET = 5 bits

ή

$\log_2 32$ = 5 bits

Το μέγεθος της λέξης είναι 32 bits

32bits = 4Bytes
32b = 4B

ένα cache block αποτελείται από 8 words

Το μέγεθος της λέξης είναι 32 bits

32bits = 4Bytes
32b = 4B

... 4-way set associative

... 4-way set associative

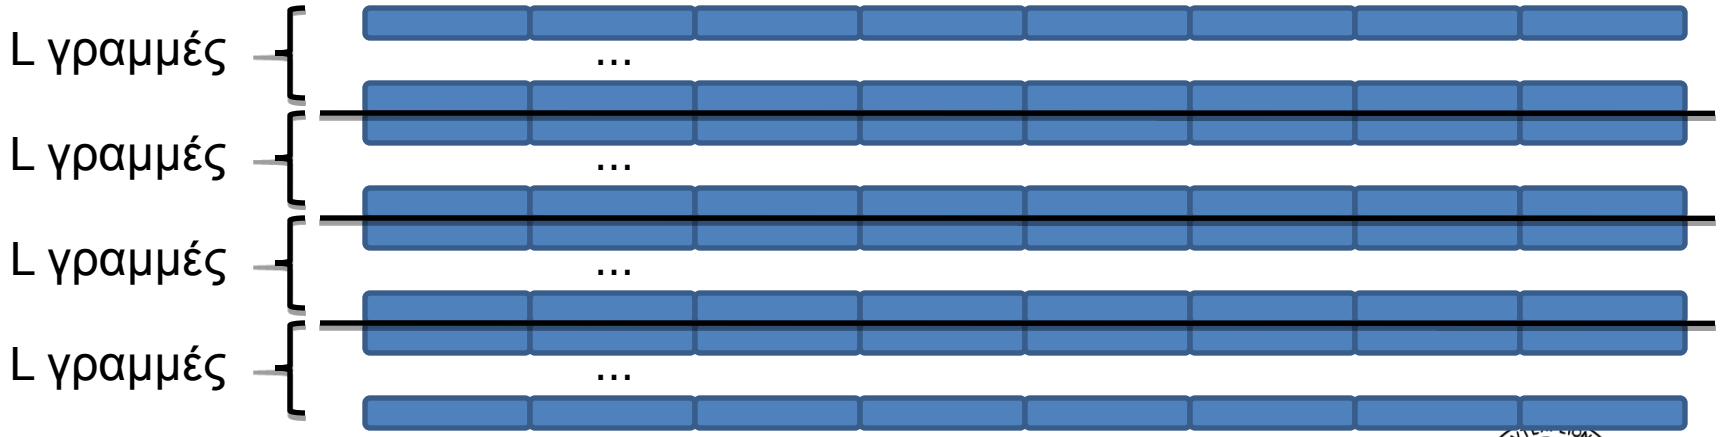

... μεγέθους 256KBytes

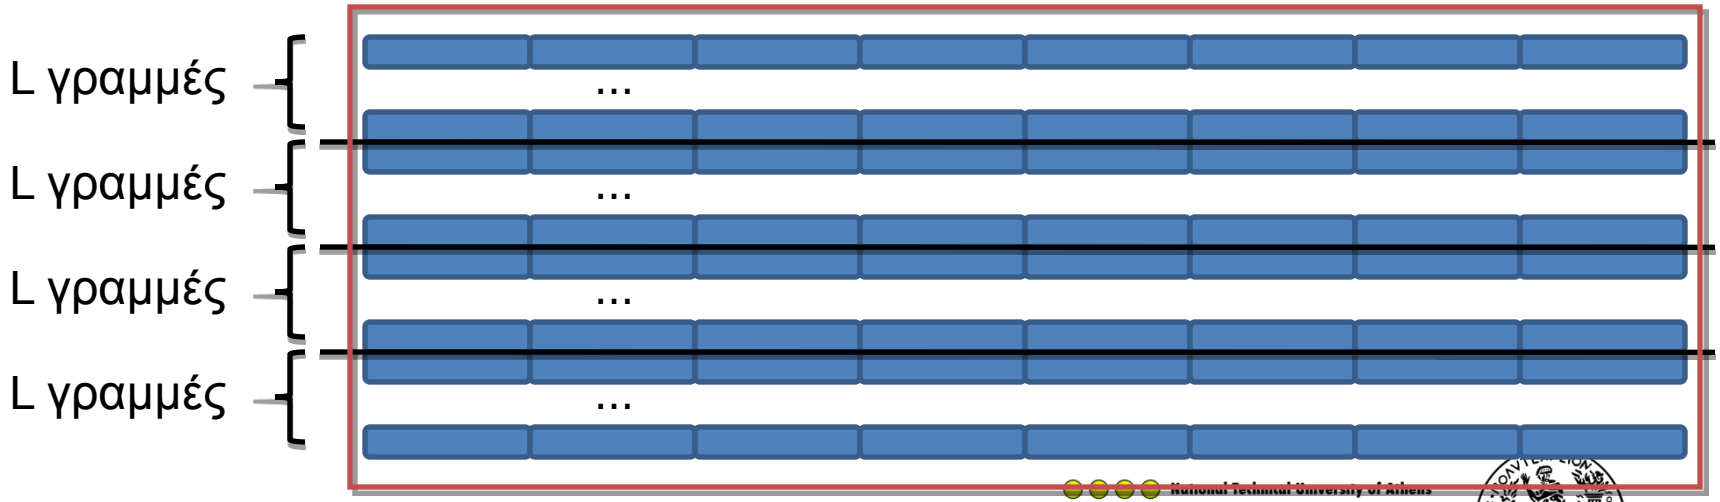

... μεγέθους 256KBytes

Δηλ. $4 \times L \times 8 \times 4\text{Bytes} = 256\text{KBytes}$

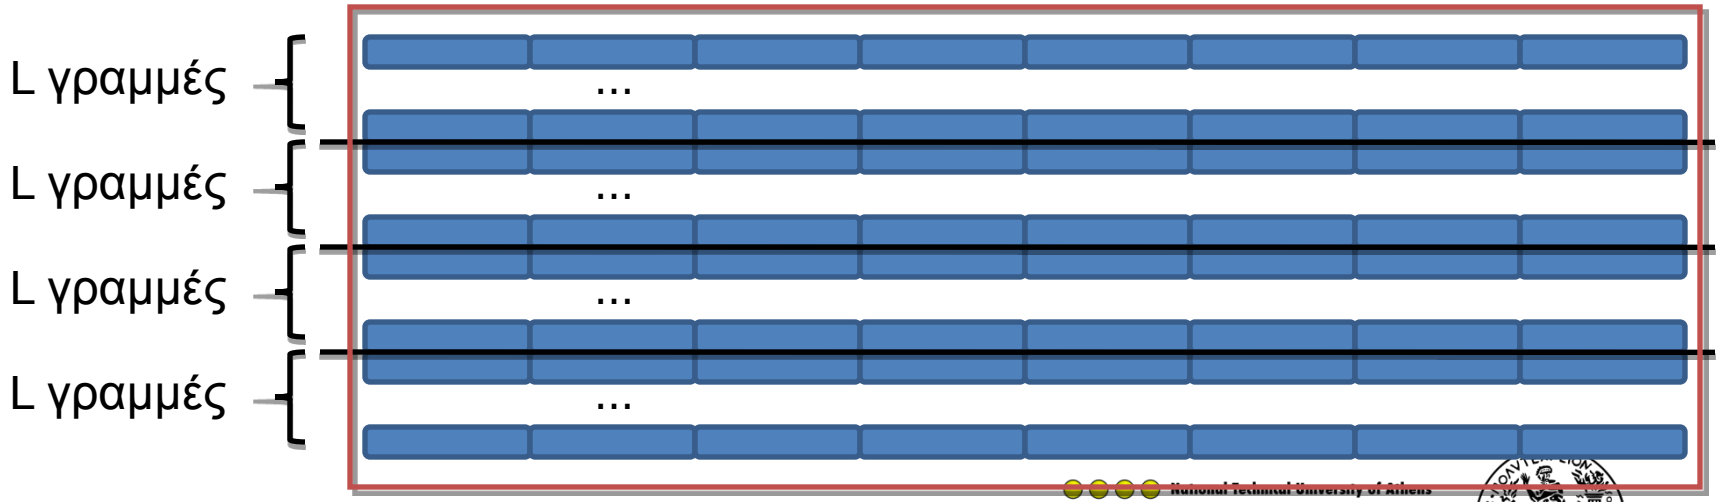

... μεγέθους 256KBytes

Δηλ. $4 \times L \times 8 \times 4\text{Bytes} = 256\text{KBytes}$

Άρα, L = 2K = 2048, δηλ. κάθε way έχει 2048 γραμμές (blocks).
Συνεπώς χρειάζονται **11 bits για το index**.

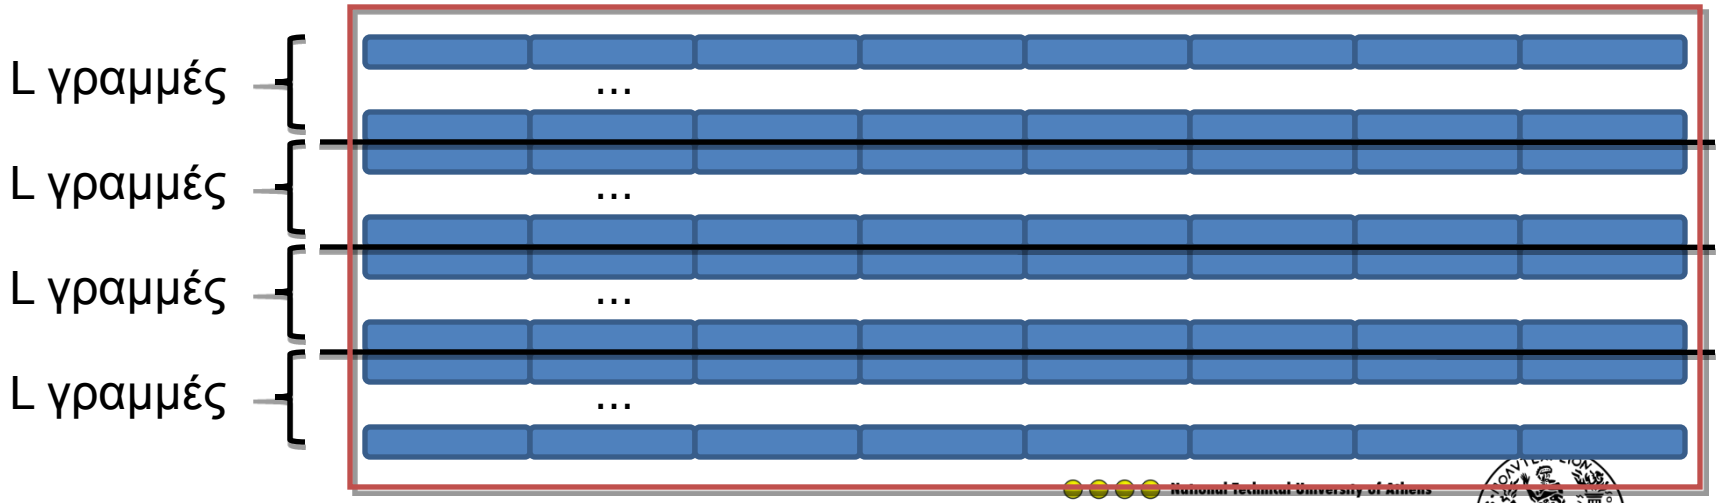

Δηλ.

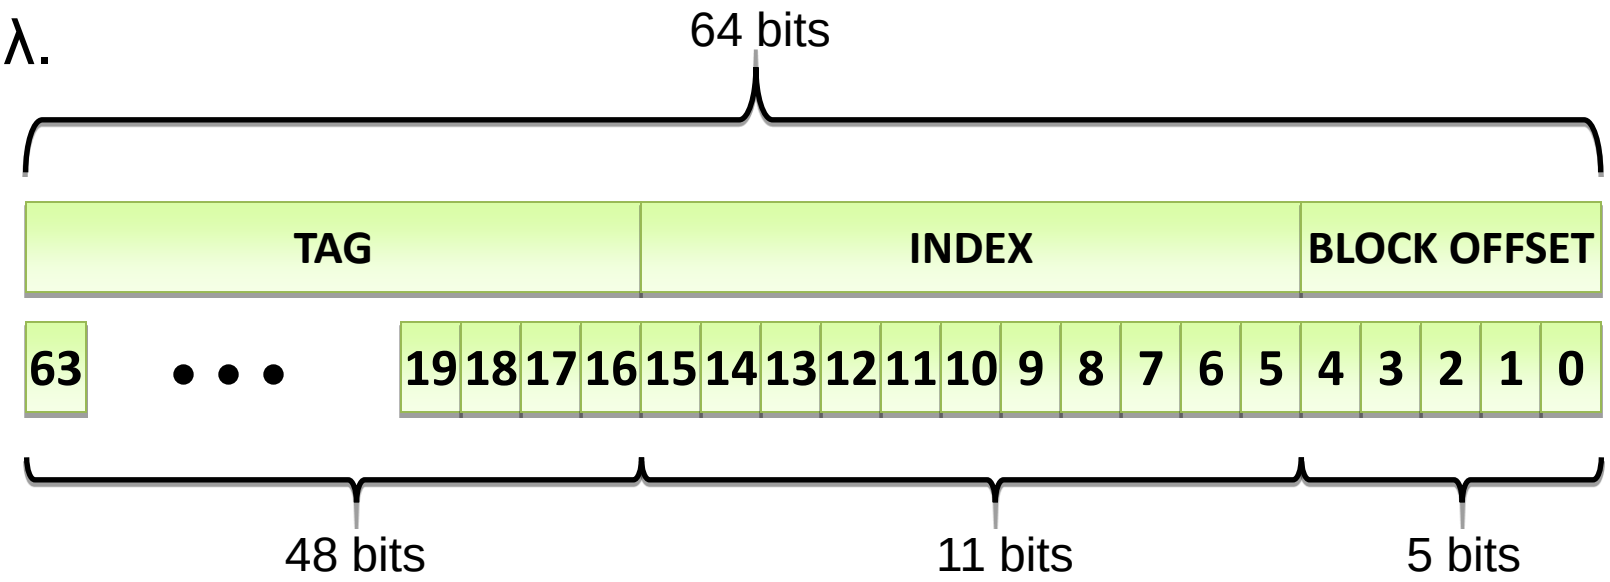
64 bits
TAG
INDEX
BLOCK OFFSET
63
• • •
19 18 17 16 15 14 13 12 11 10 9 8 7 6 5 4 3 2 1 0
48 bits
11 bits
5 bits

Ζητούμενο (2)

Σε ποιες θέσεις της cache μπορεί να απεικονιστεί το byte στη διεύθυνση μνήμης 5000_{10} ;

5000_{10} = 1001110001000_2 η οποία διασπάται στα επιμέρους πεδία:

TAG	INDEX	BLOCK OFFSET
0...00000000000000000000	00010011100	01000
48 bits	11 bits	5 bits

TAG	INDEX	BLOCK OFFSET
0...00000000000000000000	00010011100	01000
48 bits	11 bits	5 bits

Το byte θα βρίσκεται στην 8η (01000_2) θέση του block.

Το block αυτό, μπορεί να απεικονιστεί σε οποιαδήποτε από τις 4 θέσεις (4 way-set associative) με τιμή 156 (10011100_2) της cache.

«Το block αυτό, μπορεί να απεικονιστεί σε οποιαδήποτε από τις 4 θέσεις (4 way-set associative) με τιμή 156 (10011100_2) της cache.»

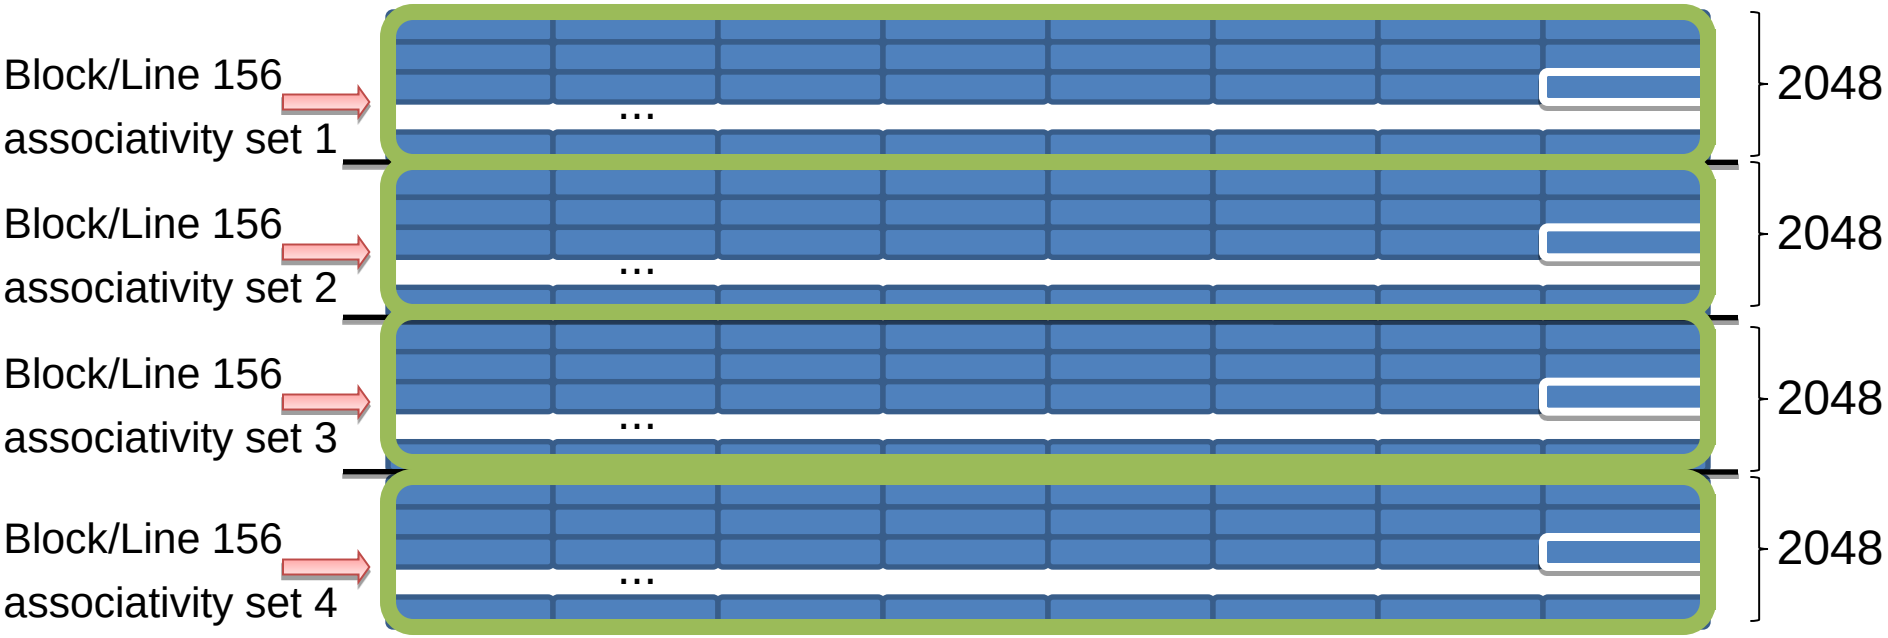

Ζητούμενο (3)

Ποιες θέσεις μνήμης μπορούν να απεικονιστούν στο σύνολο 244 της cache;

Απάντηση

TAG	INDEX	BLOCK OFFSET
x…xxxxxxxxxxxxxxxxxxxxxxxx	00011110100	xxxxx
48 bits	11 bits	5 bits

Όλες οι διευθύνσεις μνήμης που τα index bits είναι 244 (00011110100_2)

Ζητούμενο (4)

Τι ποσοστό του συνολικού μεγέθους της cache αφιερώνεται για τα bits του tag;

Απάντηση

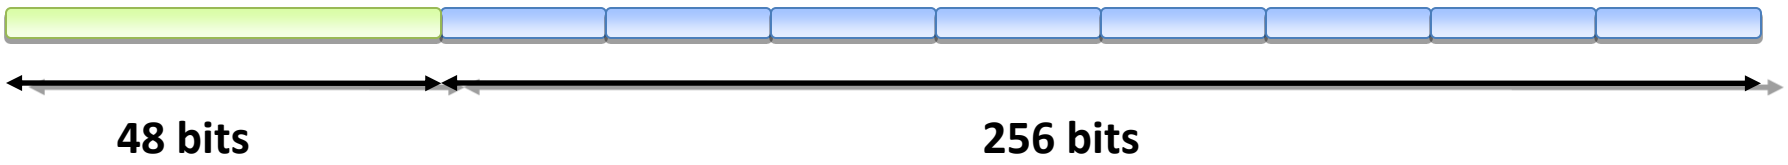

Ένα cache block (cache line) αποτελείται από 256 bits δεδομένων, και του αντιστοιχεί 1 tag.

Επομένως (έστω ότι δε λαμβάνουμε υπόψη το valid bit), το ποσοστό του μεγέθους της cache που αφιερώνεται για τα bits του tag είναι 48/(48+256) = 15.78%.

Άσκηση 2η

Θεωρούμε το ακόλουθο κομμάτι κώδικα

```
#define N 4
#define M 8
double c[N], a[N][M], b[M];
int i,j;

for(i = 0; i < N; i++)
    for(j = 0; j < M; j++)
        c[i] = c[i] + a[i][j] * b[j];
```

- Κάθε στοιχείο του πίνακα έχει μέγεθος 8 bytes
- Υπάρχει 1 επίπεδο κρυφής μνήμης, πλήρως συσχετιστικής, με LRU πολιτική αντικατάστασης, αποτελούμενη από 4 blocks δεδομένων μεγέθους 16 bytes
- Όλες οι μεταβλητές αποθηκεύονται σε καταχωρητές εκτός από τα στοιχεία των πινάκων
- Οι πίνακες αποθηκεύονται κατά γραμμές
- Η σειρά με την οποία γίνονται οι αναφορές είναι c, a, b, c.
- Αρχικά η cache είναι άδεια

Βρείτε το συνολικό ποσοστό αστοχίας (miss rate) για τον παραπάνω κώδικα

- 1 block = 16 bytes
- 1 στοιχείο = 8 bytes
- πίνακας αποθηκευμένος κατά γραμμές

→

σε 1 block της cache θα απεικονίζονται 2 διαδοχικά στοιχεία του πίνακα, π.χ. a[i][j], a[i][j+1]

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=0

c[0]

compulsory miss

δηλαδή, αναφερόμαστε για 1η φορά στα αντίστοιχα blocks…

c[0]	c[1]

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=0

c[0] compulsory miss

a[0][0] compulsory miss

c[0]	c[1]
a[0][0]	a[0][1]

LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=0

c[0]	compulsory miss
a[0][0]	compulsory miss
b[0]	compulsory miss

c[0]	c[1]
a[0][0]	a[0][1]
b[0]	b[1]

LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=0

c[0] compulsory miss

a[0][0] compulsory miss

b[0] compulsory miss

c[0] hit

c[0]	c[1]
a[0][0]	a[0][1]
b[0]	b[1]

LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=1

c[0] hit

c[0]	c[1]
a[0][0]	a[0][1]
b[0]	b[1]

LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=1

c[0] hit

a[0][1] hit

c[0]	c[1]
a[0][0]	**a[0][1]**
b[0]	b[1]

LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=1

c[0]	hit
a[0][1]	hit
b[1]	hit

c[0]	c[1]
a[0][0]	a[0][1]
b[0]	**b[1]**

LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=1

c[0] hit

a[0][1] hit

b[1] hit

c[0] hit

c[0]	c[1]
a[0][0]	a[0][1]
b[0]	b[1]

LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=2

c[0] hit

c[0]	c[1]
a[0][0]	a[0][1]
b[0]	b[1]

LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=2

c[0] hit

a[0][2] compulsory miss

c[0]	c[1]
a[0][0]	a[0][1]
b[0]	b[1]
a[0][2]	a[0][3]

← LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=2

c[0]	hit
a[0][2]	compulsory miss
b[2]	compulsory miss

c[0]	c[1]
b[2]	b[3]
b[0]	b[1]
a[0][2]	a[0][3]

← LRU

αναφορά στη μνήμη		περιεχόμενα cache

i=0,j=2

c[0]	hit
a[0][2]	compulsory miss
b[2]	compulsory miss

c[0]	hit

c[0]	c[1]
b[2]	b[3]
b[0]	b[1]
a[0][2]	a[0][3]

← LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=3

c[0] hit

c[0]	c[1]
b[2]	b[3]
b[0]	b[1]
a[0][2]	a[0][3]

← LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=3

c[0] hit

a[0][3] hit

c[0]	c[1]
b[2]	b[3]
b[0]	b[1]
a[0][2]	**a[0][3]**

← LRU

αναφορά στη μνήμη

i=0,j=3

c[0]	hit
a[0][3]	hit
b[3]	hit

περιεχόμενα cache

c[0]	c[1]
b[2]	**b[3]**
b[0]	b[1]
a[0][2]	a[0][3]

← LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=3

c[0] hit

a[0][3] hit

b[3] hit

c[0] hit

c[0]	c[1]
b[2]	b[3]
b[0]	b[1]
a[0][2]	a[0][3]

LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=4

c[0] hit

c[0]	c[1]
b[2]	b[3]
b[0]	b[1]
a[0][2]	a[0][3]

← LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=4

c[0] hit

a[0][4] compulsory miss

c[0]	c[1]
b[2]	b[3]
a[0][4]	a[0][5]
a[0][2]	a[0][3]

← LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=4

c[0]	hit
a[0][4]	compulsory miss
b[4]	compulsory miss

c[0]	c[1]
b[2]	b[3]
a[0][4]	a[0][5]
b[4]	b[5]

LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=4

c[0]	hit
a[0][4]	compulsory miss
b[4]	compulsory miss

c[0]	hit

c[0]	c[1]
b[2]	b[3]
a[0][4]	a[0][5]
b[4]	b[5]

LRU

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=5

c[0] hit

a[0][5] hit

b[5] hit

c[0] hit

c[0]	c[1]
b[2]	b[3]
a[0][4]	a[0][5]
b[4]	b[5]

LRU

αναφορά στη μνήμη	αποτέλεσμα
c0 a00 b0 c0	m m m h
c0 a01 b1 c0	h h h h
c0 a02 b2 c0	h m m h
c0 a03 b3 c0	h h h h
c0 a04 b4 c0	h m m h
c0 a05 b5 c0	h h h h
c0 a06 b6 c0	h m m h
c0 a07 b7 c0	h h h h
c1 a10 b0 c1	h m m h
c1 a11 b1 c1	h h h h
c1 a12 b2 c1	h m m h
c1 a13 b3 c1	h h h h
c1 a14 b4 c1	h m m h
c1 a15 b5 c1	h h h h
c1 a16 b6 c1	h m m h
c1 a17 b7 c1	h h h h

9 misses
23 hits

8 misses
24 hits

αναφορά στη μνήμη	αποτέλεσμα
c2 a20 b0 c2	m m m h
c2 a21 b1 c2	h h h h
c2 a22 b2 c2	h m m h
c2 a23 b3 c2	h h h h
c2 a24 b4 c2	h m m h
c2 a25 b5 c2	h h h h
c2 a26 b6 c2	h m m h
c2 a27 b7 c2	h h h h
c3 a30 b0 c3	h m m h
c3 a31 b1 c3	h h h h
c3 a32 b2 c3	h m m h
c3 a33 b3 c3	h h h h
c3 a34 b4 c3	h m m h
c3 a35 b5 c3	h h h h
c3 a36 b6 c3	h m m h
c3 a37 b7 c3	h h h h

9 misses
23 hits

8 misses
24 hits

Συνολικά

Accesses : 128
Misses : 34

→ Miss rate = 0.266

Άσκηση 3η

Θεωρούμε το ακόλουθο κομμάτι κώδικα

```
int i,j;
double result, a[110][4];

for(i=0; i<4; i++)
for(j=0; j<100; j++)
   result += a[j][i]*a[j+1][i] + 0.5;
```

Υποθέσεις:

- *κάθε στοιχείο του πίνακα έχει μέγεθος 8 bytes*
- *υπάρχει 1 επίπεδο κρυφής μνήμης, πλήρως συσχετιστικής, με LRU πολιτική αντικατάστασης, αποτελούμενη από 100 blocks δεδομένων*
- *το μέγεθος του block είναι 32 bytes*
- *ο πίνακας είναι αποθηκευμένος στην κύρια μνήμη κατά γραμμές, και είναι «ευθυγραμμισμένος» ώστε το 1ο στοιχείο του να απεικονίζεται στην αρχή μιας γραμμής της cache*
- *αρχικά η cache είναι άδεια*

- *Βρείτε ποιες από τις αναφορές στα στοιχεία του πίνακα a για όλη την εκτέλεση του παραπάνω κώδικα καταλήγουν σε misses στην cache.*

- *Υποδείξτε ποια είναι compulsory, ποια είναι capacity, και ποια conflict.*

- *Δώστε τον συνολικό αριθμό των misses.*

- 1 block = 32 bytes
- 1 στοιχείο = 8 bytes
- πίνακας αποθηκευμένος κατά γραμμές

→ σε 1 block της cache θα απεικονίζονται 4 διαδοχικά στοιχεία του πίνακα, π.χ.

a[i][j], a[i][j+1], a[i][j+2], a[i][j+3]

επιπλέον

- πίνακας ευθυγραμμισμένος

→ <u>σε 1 block της cache θα απεικονίζεται 1 ολόκληρη γραμμή του πίνακα</u>, δηλαδή

a[i][j], a[i][j+1], a[i][j+2], a[i][j+3]

όπου j%4=0

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=0

a[0][0]

compulsory miss

δηλαδή, αναφερόμαστε για 1η φορά στα αντίστοιχα blocks…

a[0][0]	a[0][1]	a[0][2]	a[0][3]

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=0

a[0][0] compulsory miss

a[1][0] compulsory miss

a[0][0]	a[0][1]	a[0][2]	a[0][3]
a[1][0]	a[1][1]	a[1][2]	a[1][3]

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=0

a[0][0] compulsory miss

a[1][0] compulsory miss

i=0,j=1

a[1][0] hit

a[0][0]	a[0][1]	a[0][2]	a[0][3]
a[1][0]	a[1][1]	a[1][2]	a[1][3]

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=0

a[0][0] compulsory miss

a[1][0] compulsory miss

i=0,j=1

a[1][0] hit

a[2][0] compulsory miss

a[0][0]	a[0][1]	a[0][2]	a[0][3]
a[1][0]	a[1][1]	a[1][2]	a[1][3]
a[2][0]	a[2][1]	a[2][2]	a[2][3]

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=0

a[0][0] compulsory miss

a[1][0] compulsory miss

i=0,j=1

a[1][0] hit

a[2][0] compulsory miss

Έτσι για i=0, j=1…99 θα έχουμε 1 hit + 1 comp. miss για κάθε επανάληψη του j

a[0][0]	a[0][1]	a[0][2]	a[0][3]
a[1][0]	a[1][1]	a[1][2]	a[1][3]
a[2][0]	a[2][1]	a[2][2]	a[2][3]

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=0

a[0][0] compulsory miss

a[1][0] compulsory miss

i=0,j=1

a[1][0] hit

a[2][0] compulsory miss

Έτσι για i=0, j=1…99 θα έχουμε 1 hit + 1 comp. miss για κάθε επανάληψη του j

↓

για i=0 θα έχουμε 2+99=101 misses, όλα compulsory

a[0][0]	a[0][1]	a[0][2]	a[0][3]
a[1][0]	a[1][1]	a[1][2]	a[1][3]
a[2][0]	a[2][1]	a[2][2]	a[2][3]

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=99

a[99][0] hit

a[0][0]	a[0][1]	a[0][2]	a[0][3]
a[1][0]	a[1][1]	a[1][2]	a[1][3]
a[2][0]	a[2][1]	a[2][2]	a[2][3]
a[3][0]	a[3][1]	a[3][2]	a[3][3]
a[4][0]	a[4][1]	a[4][2]	a[4][3]
…	…	…	…
a[98][0]	a[98][1]	a[98][2]	a[98][3]
a[99][0]	a[99][1]	a[99][2]	a[99][3]

αναφορά στη μνήμη

περιεχόμενα cache

i=0,j=99

a[99][0] hit

a[100][0] compulsory miss

αντικατέστησε το LRU block που υπήρχε στην cache

a[100][0]	a[100][1]	a[100][2]	a[100][3]
a[1][0]	a[1][1]	a[1][2]	a[1][3]
a[2][0]	a[2][1]	a[2][2]	a[2][3]
a[3][0]	a[3][1]	a[3][2]	a[3][3]
a[4][0]	a[4][1]	a[4][2]	a[4][3]
…	…	…	…
a[98][0]	a[98][1]	a[98][2]	a[98][3]
a[99][0]	a[99][1]	a[99][2]	a[99][3]

αναφορά στη μνήμη

περιεχόμενα cache

i=1,j=0

a[0][1]

capacity miss

διότι αντικαταστάθηκε λόγω έλλειψης χώρου το block που είχε έρθει στην cache κατά το παρελθόν και το περιείχε

a[100][0]	a[100][1]	a[100][2]	a[100][3]
a[0][0]	**a[0][1]**	a[0][2]	a[0][3]
a[2][0]	a[2][1]	a[2][2]	a[2][3]
a[3][0]	a[3][1]	a[3][2]	a[3][3]
a[4][0]	a[4][1]	a[4][2]	a[4][3]
…	…	…	…
a[98][0]	a[98][1]	a[98][2]	a[98][3]
a[99][0]	a[99][1]	a[99][2]	a[99][3]

αναφορά στη μνήμη

περιεχόμενα cache

i=1,j=0

a[0][1] capacity miss

a[1][1] capacity miss

a[100][0]	a[100][1]	a[100][2]	a[100][3]
a[0][0]	a[0][1]	a[0][2]	a[0][3]
a[1][0]	**a[1][1]**	a[1][2]	a[1][3]
a[3][0]	a[3][1]	a[3][2]	a[3][3]
a[4][0]	a[4][1]	a[4][2]	a[4][3]
…	…	…	…
a[98][0]	a[98][1]	a[98][2]	a[98][3]
a[99][0]	a[99][1]	a[99][2]	a[99][3]

αναφορά στη μνήμη

i=1,j=0

a[0][1] capacity miss

a[1][1] capacity miss

i=1,j=1

a[1][1] hit

περιεχόμενα cache

a[100][0]	a[100][1]	a[100][2]	a[100][3]
a[0][0]	a[0][1]	a[0][2]	a[0][3]
a[1][0]	**a[1][1]**	a[1][2]	a[1][3]
a[3][0]	a[3][1]	a[3][2]	a[3][3]
a[4][0]	a[4][1]	a[4][2]	a[4][3]
…	…	…	…
a[98][0]	a[98][1]	a[98][2]	a[98][3]
a[99][0]	a[99][1]	a[99][2]	a[99][3]

αναφορά στη μνήμη

i=1,j=0

a[0][1] capacity miss

a[1][1] capacity miss

i=1,j=1

a[1][1] hit

a[2][1] capacity miss

περιεχόμενα cache

a[100][0]	a[100][1]	a[100][2]	a[100][3]
a[0][0]	a[0][1]	a[0][2]	a[0][3]
a[1][0]	a[1][1]	a[1][2]	a[1][3]
a[2][0]	**a[2][1]**	a[2][2]	a[2][3]
a[4][0]	a[4][1]	a[4][2]	a[4][3]
…	…	…	…
a[98][0]	a[98][1]	a[98][2]	a[98][3]
a[99][0]	a[99][1]	a[99][2]	a[99][3]

αναφορά στη μνήμη

περιεχόμενα cache

i=1,j=0

a[0][1] capacity miss

a[1][1] capacity miss

i=1,j=1

a[1][1] hit

a[2][1] capacity miss

a[100][0]	a[100][1]	a[100][2]	a[100][3]
a[0][0]	a[0][1]	a[0][2]	a[0][3]
a[1][0]	a[1][1]	a[1][2]	a[1][3]
a[2][0]	**a[2][1]**	a[2][2]	a[2][3]
a[4][0]	a[4][1]	a[4][2]	a[4][3]
…	…	…	…
a[98][0]	a[98][1]	a[98][2]	a[98][3]
a[99][0]	a[99][1]	a[99][2]	a[99][3]

Στις επόμενες επαναλήψεις θα έχουμε κυκλικές αντικαταστάσεις blocks, οπότε τα misses και τα hits θα ακολουθούν το ίδιο μοτίβο όπως και για i=0.

αναφορά στη μνήμη

περιεχόμενα cache

i=1,j=0

a[0][1] capacity miss

a[1][1] capacity miss

i=1,j=1

a[1][1] hit

a[2][1] capacity miss

a[100][0]	a[100][1]	a[100][2]	a[100][3]
a[0][0]	a[0][1]	a[0][2]	a[0][3]
a[1][0]	a[1][1]	a[1][2]	a[1][3]
a[2][0]	**a[2][1]**	a[2][2]	a[2][3]
a[4][0]	a[4][1]	a[4][2]	a[4][3]
…	…	…	…
a[98][0]	a[98][1]	a[98][2]	a[98][3]
a[99][0]	a[99][1]	a[99][2]	a[99][3]

Στις επόμενες επαναλήψεις θα έχουμε κυκλικές αντικαταστάσεις blocks, οπότε τα misses και τα hits θα ακολουθούν το ίδιο μοτίβο όπως και για i=0.

↓

συνολικά θα έχουμε 4*101=404 misses

αναφορά στη μνήμη

περιεχόμενα cache

i=1,j=0

a[0][1] capacity miss

a[1][1] capacity miss

i=1,j=1

a[1][1] hit

a[2][1] capacity miss

a[100][0]	a[100][1]	a[100][2]	a[100][3]
a[0][0]	a[0][1]	a[0][2]	a[0][3]
a[1][0]	a[1][1]	a[1][2]	a[1][3]
a[2][0]	**a[2][1]**	a[2][2]	a[2][3]
a[4][0]	a[4][1]	a[4][2]	a[4][3]
…	…	…	…
a[98][0]	a[98][1]	a[98][2]	a[98][3]
a[99][0]	a[99][1]	a[99][2]	a[99][3]

Conflict misses δεν έχουμε διότι η cache είναι fully associative → τα blocks δεδομένων μπορούν να απεικονιστούν οπουδήποτε στην cache

Θεωρείστε πάλι τον αρχικό κώδικα. Ποια γνωστή τεχνική βελτιστοποίησης θα εφαρμόζατε στον κώδικα ώστε να μειωθούν τα misses;

```
for(i=0; i<4; i++)
for(j=0; j<100; j++)
    result += a[j][i]*a[j+1][i] + 0.5;
```

στο σώμα του loop δεν υπάρχουν εξαρτήσεις, επομένως μπορούμε να εφαρμόσουμε *αναδιάταξη βρόχων (loop interchange)*

```
for(j=0; j<100; j++)
for(i=0; i<4; i++)
    result += a[j][i]*a[j+1][i] + 0.5;
```

τώρα ο πίνακας προσπελαύνεται όπως είναι αποθηκευμένος → καλύτερη τοπικότητα αναφορών, αφού γειτονικά στοιχεία προσπελαύνονται σε διαδοχικές επαναλήψεις του εσωτερικού loop

misses συμβαίνουν όταν αναφερόμαστε στο πρώτο στοιχείο κάθε γραμμής (i=0) → συνολικά έχουμε 100 misses

Άσκηση 4η

Θεωρούμε το ακόλουθο κομμάτι κώδικα:

```
#define N 1024
float A[N], B[N];
for(i=0; i<N; i+=1)
B[i] += 2*A[i];
```

Κάνουμε τις εξής υποθέσεις:

- *Το πρόγραμμα εκτελείται σε έναν επεξεργαστή με μόνο ένα επίπεδο κρυφής μνήμης δεδομένων, η οποία αρχικά είναι άδεια. Η κρυφή μνήμη είναι direct mapped, write-allocate, και έχει μέγεθος 2KB. Το μέγεθος του block είναι 16 bytes.*
- *Το μέγεθος ενός float είναι 4 bytes.*
- *Δήλωση διαδοχικών μεταβλητών (βαθμωτών και μη) στο πρόγραμμα συνεπάγεται αποθήκευσή τους σε διαδοχικές θέσεις στη μνήμη.*

Βρείτε το συνολικό ποσοστό αστοχίας (miss rate) για τις αναφορές που γίνονται στην μνήμη στον παραπάνω κώδικα

```
#define N 1024
float A[N], B[N];
for(i=0; i<N; i+=1)
        B[i] += 2*A[i];
```

- #blocks= 2048/16 = 128
- σε κάθε block => 16/4 = 4 στοιχεία ενός πίνακα
- *Πού απεικονίζονται τα A[i], B[i] ;* στο ίδιο block... *γιατί;*
  - Άρα: read B[0] (m), read A[0] (m), write B[0] (m)

    read B[1] (h) *γιατί;*, read A[1] (m), write B[1] (m)

    read B[2] (h), read A[2] (m), write B[2] (m)

    read B[3] (h), read A[3] (m), write B[3] (m)

    read B[4] (m), read A[4] (m), write B[4] (m)

    ...
- Ανά 4 επαναλήψεις: 9 misses, 3 hits => miss rate = 9/12 = 75%

*Ποιες από τις παρακάτω τεχνικές βελτιστοποίησης **επιπέδου λογισμικού** θα ακολουθούσατε προκειμένου να βελτιώσετε την απόδοση του κώδικα;*

- *Loop unrolling*
- *Merging arrays*
- *Loop blocking*
- *Loop distribution*

Loop unrolling

```
for(i=0; i<N; i+=1) {
        B[i] += 2*A[i];
            B[i+1] += 2*A[i+1];
            B[i+2] += 2*A[i+2];
            B[i+3] += 2*A[i+3];
        }
```

- Βοηθάει;
  - *Πού στοχεύει η τεχνική αυτή;*

Loop blocking

```
for(i=0; i<N; i+=bs)
   for(ii=i; ii<min(i+bs,N); ii++)
       B[ii] += 2*A[ii];
```

- Βοηθάει;
  - *Πού στοχεύει η τεχνική αυτή;*
  - *Ποιο το πρόβλημα απόδοσης του αρχικού κώδικα όσον αφορά τα misses;*

Loop distribution

```
for(i=0; i<N; i+=1) {
        B[i] += 2*A[i];          =>    ???
}
```

- *Σε τι στοχεύει η τεχνική αυτή;*
- *Υπό ποιες προϋποθέσεις θα βοηθούσε;*

Merging arrays

```
float A[N], B[N];
for(i=0; i<N; i+=1)
    B[i] += 2*A[i];
```

ο κώδικας γίνεται:

```
struct merge {
    float a;
    float b; };
struct merge merge_array[1024];
for(i=0; i<N; i+=1)
    merge_array[i].b += 2*merge_array[i].a
```

- Σε κάθε block τώρα έχουμε 2 στοιχεία του A και 2 του B
  - Για ζυγά i: 1 miss σε 3 accesses
  - Για μονά i: κανένα miss σε 3 accesses
- Άρα miss rate = 1/6 = 16.67%

*Ποιες από τις παρακάτω τεχνικές βελτιστοποίησης **επιπέδου υλικού** θα ακολουθούσατε προκειμένου να βελτιώσετε την απόδοση του κώδικα;*

- αύξηση block size σε 32 bytes (με διατήρηση της χωρητικότητας)

- αύξηση associativity σε 2-way (με διατήρηση της χωρητικότητας της cache)

- προσθήκη victim cache

- χρήση μηχανισμού hardware prefetching

Ποιο το πρόβλημα απόδοσης του αρχικού κώδικα όσον αφορά τα misses, και πώς μπορεί να βοηθήσει η κάθε τεχνική;

Άσκηση 5η

Εξετάζουμε την εκτέλεση του ακόλουθου βρόχου (αντιμετάθεση πίνακα):

```
for(i=0; i<256; i++)
        for(j=0; j<256; j++)
                b[i][j] = a[j][i];
```

- *στοιχεία κινητής υποδιαστολής διπλής ακρίβειας (8 bytes)*
- *ένα επίπεδο data cache: fully associative, write-allocate, 16 KB, LRU πολιτική αντικατάστασης*
- *block size = 64 bytes*
- *οι πίνακες είναι αποθηκευμένοι κατά γραμμές, και "ευθυγραμμισμένοι" ώστε το πρώτο στοιχείο τους να απεικονίζεται στην αρχή μιας γραμμής της cache*

Βρείτε το συνολικό miss rate.

```
for(i=0; i<256; i++)
        for(j=0; j<256; j++)
                b[i][j] = a[j][i];
```

- cache line 64 bytes => 8 στοιχεία πίνακα σε 1 cache line
- Για την αποθήκευση 1 γραμμής του πίνακα => 8*256=2048 bytes, ή 32 cache lines
- Για την αποθήκευση 1 στήλης => 64*256 bytes (*γιατί;*) = 16KB ή 256 cache lines
  - Τα στοιχεία μιας στήλης δεν μπορούν να επαναχρησιμοποιηθούν

```
for(i=0; i<256; i++)
        for(j=0; j<256; j++)
                b[i][j] = a[j][i];
```

Για την 1η επανάληψη του εξωτερικού loop:

a0,0	b0,0	m	m	
a1,0	b0,1	m	h	
a2,0	b0,2	m	h	
...				
a7,0	b0,7	m	h	
a8,0	b0,8	m	m	(νέα cache line για τον b)
a9,0	b0,9	m	h	
...				
a15,0	b0,15	m	h	
a16,0	b0,16	m	m	
...				

Το miss pattern επαναλαμβάνεται ανά 8 επαναλήψεις του εσωτερικού loop

Άρα συνολικά θα έχουμε 256/8 * 9 misses = 288 για 1 επανάληψη του εξ. loop

```
for(i=0; i<256; i++)
        for(j=0; j<256; j++)
                b[i][j] = a[j][i];
```

Για την 1η επανάληψη του εξωτερικού loop:

a0,0	b0,0	m	m	
a1,0	b0,1	m	h	
a2,0	b0,2	m	h	
	...			
a7,0	b0,7	m	h	
a8,0	b0,8	m	m	(νέα cache line για τον b)
a9,0	b0,9	m	h	
	...			
a15,0	b0,15	m	h	
a16,0	b0,16	m	m	
	...			

Στην επόμενη επανάληψη του εξ. loop δεν υπάρχει επαναχρησιμοποίηση για κανέναν από τους 2 πίνακες:

- ο b διατρέχεται ούτως ή άλλως κατά γραμμές...
- ο a;

```
for(i=0; i<256; i++)
        for(j=0; j<256; j++)
                b[i][j] = a[j][i];
```

Για την 1η επανάληψη του εξωτερικού loop:

a0,0 b0,0 m m

a1,0 b0,1 m h

a2,0 b0,2 m h

...

a7,0 b0,7 m h

a8,0 b0,8 m m (νέα cache line για τον b)

a9,0 b0,9 m h

...

a15,0 b0,15 m h

a16,0 b0,16 m m

Συμπέρασμα:

Το miss pattern είναι το ίδιο για κάθε επανάληψη του εξωτερικού loop

Misses = 256*288 = 73728 , σε σύνολο 2*256*256 αναφορών => miss rate = 56.25%

Εφαρμόστε blocking δίνοντας τον βελτιστοποιημένο κώδικα. Ποιο block size θα επιλέγατε ως καταλληλότερο και γιατί;

```
for(i=0; i<256; i++)
    for(j=0; j<256; j++)
        b[i][j] = a[j][i];
```

=>

```
for(i=0; i<256; i+=bs)
    for(j=0; j<256; j+=bs)
        for(ii=i; ii<i+bs; ii++)
            for(jj=j; jj<j+bs; jj++)
                b[ii][jj] = a[jj][ii];
```

- Ποιο block size;
  - Τα 2 blocks πρέπει να χωράνε στην cache => κάθε block 8KB ή 1024 στοιχεία = 32x32 στοιχεία => bs =32

Ποιο το ποσοστό αστοχίας για τον blocked κώδικα;

```
for(i=0; i<256; i+=32)
    for(j=0; j<256; j+=32)
        for(ii=i; ii<i+32; ii++)
            for(jj=j; jj<j+32; jj++)
                b[ii][jj] = a[jj][ii];
```

Για την 1η επανάληψη του loop “ii”:

a0,0 b0,0	m m	a16,0 b0,16	m m
a1,0 b0,1	m h	a17,0 b0,17	m h
a2,0 b0,2	m h	...	
...		a23,0 b0,23	m h
a7,0 b0,7	m h		
a8,0 b0,8	m m	a24,0 b0,24	m m
a9,0 b0,9	m h	a25,0 b0,25	m h
...		...	
a15,0 b0,15	m h	a31,0 b0,31	m h

- ανά 8 επαναλήψεις του “jj” το miss pattern επαναλαμβάνεται => 4*9 = 36 misses συνολικά

Ποιο το ποσοστό αστοχίας για τον blocked κώδικα;

```
for(i=0; i<256; i+=32)
    for(j=0; j<256; j+=32)
        for(ii=i; ii<i+32; ii++)
            for(jj=j; jj<j+32; jj++)
                b[ii][jj] = a[jj][ii];
```

Στην 2η επανάληψη του loop “ii”, θα έχουμε επαναχρησιμοποίηση στα στοιχεία του a:

a0,1 b1,0	h m	a16,1 b1,16	h m
a1,1 b1,1	h h	a17,1 b1,17	h h
a2,1 b1,2	h h	...	
...		a23,1 b1,23	h h
a7,1 b1,7	h h		
a8,1 b1,8	h m	a24,1 b1,24	h m
a9,1 b1,9	h h	a25,1 b1,25	h h
...		...	
a15,1 b1,15	h h	a31,1 b1,31	h h

- Σε αυτήν την περίπτωση έχουμε συνολικά 4*1=4 misses

Ποιο το ποσοστό αστοχίας για τον blocked κώδικα;

```
for(i=0; i<256; i+=32)
    for(j=0; j<256; j+=32)
        for(ii=i; ii<i+32; ii++)
            for(jj=j; jj<j+32; jj++)
                b[ii][jj] = a[jj][ii];
```

Η επαναχρησιμοποίηση στα στοιχεία του a θα συνεχιστεί για ii=2,3,...7 (*γιατί;*)

a0,1 b1,0	h m	a16,1 b1,16	h m
a1,1 b1,1	h h	a17,1 b1,17	h h
a2,1 b1,2	h h	...	
...		a23,1 b1,23	h h
a7,1 b1,7	h h		
a8,1 b1,8	h m	a24,1 b1,24	h m
a9,1 b1,9	h h	a25,1 b1,25	h h
...		...	
a15,1 b1,15	h h	a31,1 b1,31	h h

- Συνολικά, για ii=0,...,7 θα έχουμε 36+7*4=64 misses
- ...το pattern αυτό θα επαναλαμβάνεται για ii=8...15, ii=16...23, ii=24...31 (όπου αλλάζει η στήλη για τον a ώστε να φορτώνεται καινούρια cache line)

Ποιο το ποσοστό αστοχίας για τον blocked κώδικα;

```
for(i=0; i<256; i+=32)
    for(j=0; j<256; j+=32)
        for(ii=i; ii<i+32; ii++)
            for(jj=j; jj<j+32; jj++)
                b[ii][jj] = a[jj][ii];
```

a0,1 b1,0	h m		a16,1 b1,16	h m	
a1,1 b1,1	h h		a17,1 b1,17	h h	
a2,1 b1,2	h h			...	
...			a23,1 b1,23	h h	
a7,1 b1,7	h h				
a8,1 b1,8	h m		a24,1 b1,24	h m	
a9,1 b1,9	h h		a25,1 b1,25	h h	
...				...	
a15,1 b1,15	h h		a31,1 b1,31	h h	

- *Συνολικά επομένως, για μια πλήρη εκτέλεση των 2 εσωτερικότερων loops (για την εκτέλεση δηλαδή του αλγορίθμου σε επίπεδο block πίνακα), θα έχουμε 4*64 = 256 misses σε σύνολο 2*32*32=2048 αναφορών.*
- *Το miss pattern αυτό επαναλαμβάνεται για όλες τις επαναλήψεις των 2 εξωτερικότερων loops, για όλους δηλαδή τους συνδυασμούς blocks των πινάκων a και b (δεν υπάρχει επαναχρησιμοποίηση σε επίπεδο block, μόνο σε επίπεδο στοιχείων εντός του block).*
- *Επομένως, το miss rate = 256/2048 = 12.5%*