

- Θέμα 1**
- i. (1 μονάδα) Περιγράψτε συνοπτικά τις write-thought και write-back πολιτικές εγγραφής σε caches. Ησαν τα πλεονεκτήματα/μειονεκτήματα σε κάθε περίπτωση;
 - ii. (0.5 μονάδες) Έστω ότι έχετε δύο επεξεργαστές, ο πρώτος με 5 στάδια pipeline και ο δεύτερος με 12 στάδια pipeline. Και στους δύο υπολογιστές υπάρχει ένας branch predictor με σχετικά χαμηλή ακρίβεια. Σε ποιον από τους δύο υπολογιστές θεωρείτε ότι είναι περισσότερο απαραίτητο να βελτιωθεί ο branch predictor και γιατί;
 - iii. (1 μονάδα) Περιγράψτε εν συντομίᾳ ποια είδη pipeline hazards γνωρίζετε? Αναφέρεται τι είναι τα dependencies και ποια είδη dependencies γνωρίζετε?
 - iv. (1 μονάδα) Τι επίδραση έχει η αύξηση του block size της cache σε κάθε μία από τις 3 κατηγορίες των cache misses και γιατί? Μπορείτε να σκεφτείτε μία επιπλέον κατηγορία από cache misses?
 - v. (1.5 μονάδα) Τι σημαίνει pipeline, superpipeline & superscalar αρχιτεκτονικές? Δώστε σχηματικά τα διαγράμματα σε κάθε περίπτωση.
 - vi. (0.5 μονάδες) Ποια η διαφορά του ILP από το IPC?
 - vii. (bonus 0.5 μονάδες) Αναφέρετε εάν έχει νόημα (από την άποψη της αρχιτεκτονικής του συστήματος) να κατασκευαστεί μία cache με associativity ίσο με 3 (associativity που δεν είναι δύναμη του 2)?
 - viii. (bonus 1 μονάδα) Οι σύγχρονες κάρτες γραφικών (π.χ. CUDA GPU) μπορούν να υποστηρίξουν ταυτόχρονα πολλά threads (εκατοντάδες χιλιάδες). Σε αυτό το χαρακτηριστικό βασίζεται η επιτυχία τους. Μπορείτε να εξηγήσετε γιατί?

- Θέμα 2**
- (1.5 μονάδα) Θέλουμε νέα συγκρίνουμε 2 επεξεργαστές με τα εξής χαρακτηριστικά: Ο πρώτος επεξεργαστής έχει 5 στάδια pipeline (IF, ID, EX, MEM, WB) ενώ ο δεύτερος έχει 4 (IF, ID, EX+MEM, WB) ενοποιώντας την φάση EX+MEM. Επίσης ο δεύτερος επεξεργαστής έχει 50% εκτέλεσης με την φάση προσπέλασης στην μνήμη σε ένα στάδιο. Επίσης ο δεύτερος επεξεργαστής έχει 50% μεγαλύτερο κύκλο ρολογιού. Το ποσοστό εντολών που παρεμποδίζονται από stalls είναι 5% λόγω branch stalls και 4% λόγω load stalls. Βοηθείτε ποιος επεξεργαστής είναι πιο γρούγορος και πόσο, εάν υποθέσουμε ότι στον δεύτερο επεξεργαστή εξαλείφονται τα load stalls.

Θέμα 3

(2 μονάδες) Δίνονται οι παρακάτω εντολές διακλάδωσης:

B1 : T, N, T, T, T, N, N, N, T, N, T, N, T, T, N, T, N

B2 : N, T, N, N, N, T, T, T, N, T, N, T, N, N, T, N, T

Επιπλέον έχετε στην διάθεση σας έναν $m \times n$ global history predictor, όπου $m, n = \{1, 2\}$.

Πρόβλεψης θα προτείνετε για τη διακλάδωση B2 και γιατί (τι branches του B2 εκτελούνται πάντα μετά από τα αντίστοιχα branches του B1)?

Τριπλή Κλάδωση (μεγάλα πορτφό)

Θέμα 4

Εξετάζουμε την εκτέλεση του ακόλουθου βρόχου ο οποίος αντιμετωπίζεται έναν 256x256 πίνακα a και αποθηκεύει το αποτέλεσμα σε έναν πίνακα b.

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

Οι πίνακες περιέχουν στοιχεία κινητής υποδιαστολής διπλής ακρίβειας, μεγέθους 8 bytes το καθένα. 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 πλήρως συσχετιστική (fully associative), έχει μέγεθος 16 KB, και έχει LRU πολιτική αντικατάστασης. Το μέγεθος του block είναι 64 bytes.
- Οι πίνακες είναι αποθηκευμένοι στην κύρια μνήμη κατά γραμμές. Επιπλέον, είναι "ευθυγραμμισμένοι" ώστε το πρώτο στοιχείο του καθενός να απεικονίζεται στην αρχή μιας γραμμής της κρυφής μνήμης.

i. (2 μονάδες) Βρείτε το συνολικό miss rate για τις αναφορές που γίνονται στην μνήμη στον παραπάνω κώδικα.

ii. (bonus 1 μονάδα) Εφαρμόστε την τεχνική του blocking στον παραπάνω κώδικα παρουσιάζοντας τον βελτιστοποιημένο κώδικα. Ποιο block size θα επιλέγετε ως καταλληλότερο και γιατί;

Καλή επιτυχία