

Αρχιτεκτονική Υπολογιστών

(Τμήμα Μ-Ω)

Παναγιώτης Τσανάκας, Καθηγητής ΕΜΠ

panag@cslab.ece.ntua.gr

210 7722541

Βοηθός διδασκαλίας:

Γιώργος Ρασσιάς

grassias@cslab.ece.ntua.gr

210 7724395

Σύγγραμμα

Οργάνωση και Σχεδίαση Υπολογιστών (η διασύνδεση υλικού και λογισμικού), 4^η έκδοση, David Patterson and John Hennessy, μετάφραση, εκδόσεις Κλειδάριθμος, 2010. Διαθέσιμο μέσω www.eudoxus.gr

Ιστοσελίδα μαθήματος

<http://www.cslab.ece.ntua.gr/courses/comparch>

Περιεχόμενα 1/2

- Γενικές έννοιες και τεχνολογία υπολογιστών.
- Αλγόριθμοι αριθμητικών πράξεων.
- Αρχιτεκτονικές Συνόλου Εντολών (ISA)-αναπαράσταση εντολών, το σύνολο εντολών της αρχιτεκτονικής MIPS (RISC).
- Σχεδίαση επεξεργαστή: δίοδος δεδομένων (datapath) και μονάδα ελέγχου (καλωδιωμένη λογική).

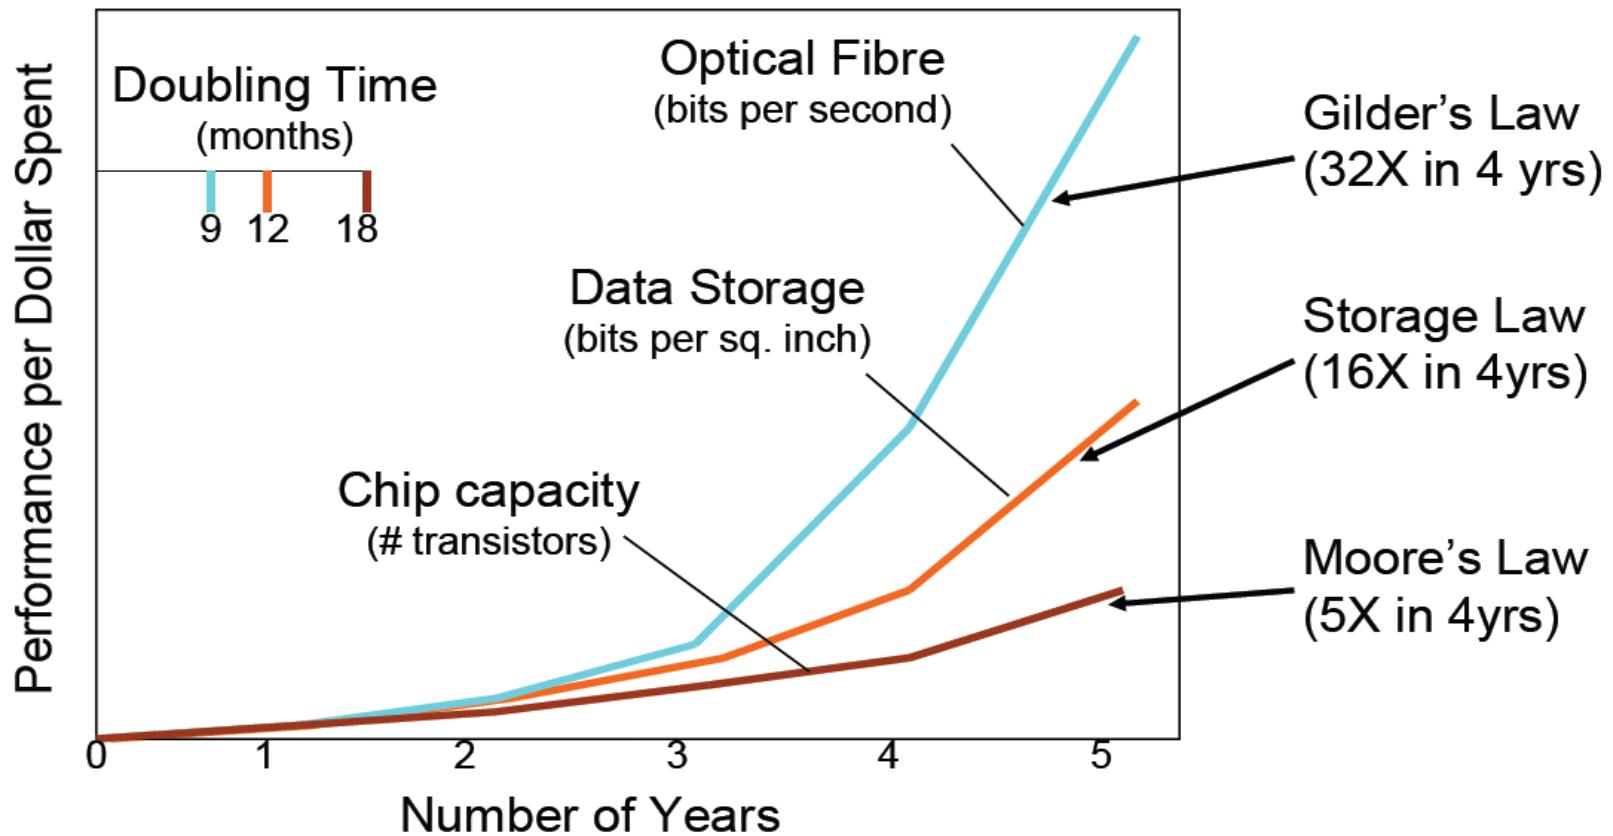
Περιεχόμενα 2/2

- Αύξηση της επίδοσης με χρήση διοχέτευσης (αρχιτεκτονική αγωγού-pipelining).
- Σύστημα μνήμης (Οργάνωση, Ιεραρχία, Κρυφές μνήμες).
- Μονάδες Εισόδου/Εξόδου (I/O).

Βασικές Έννοιες

- Τεχνολογικές τάσεις
- Τοπικότητα της αναφοράς
- Αφαίρεση
- Προτυποποίηση

Τεχνολογικές Εξελίξεις



Triumph of Light – *Scientific American*. George Stix, January 2001

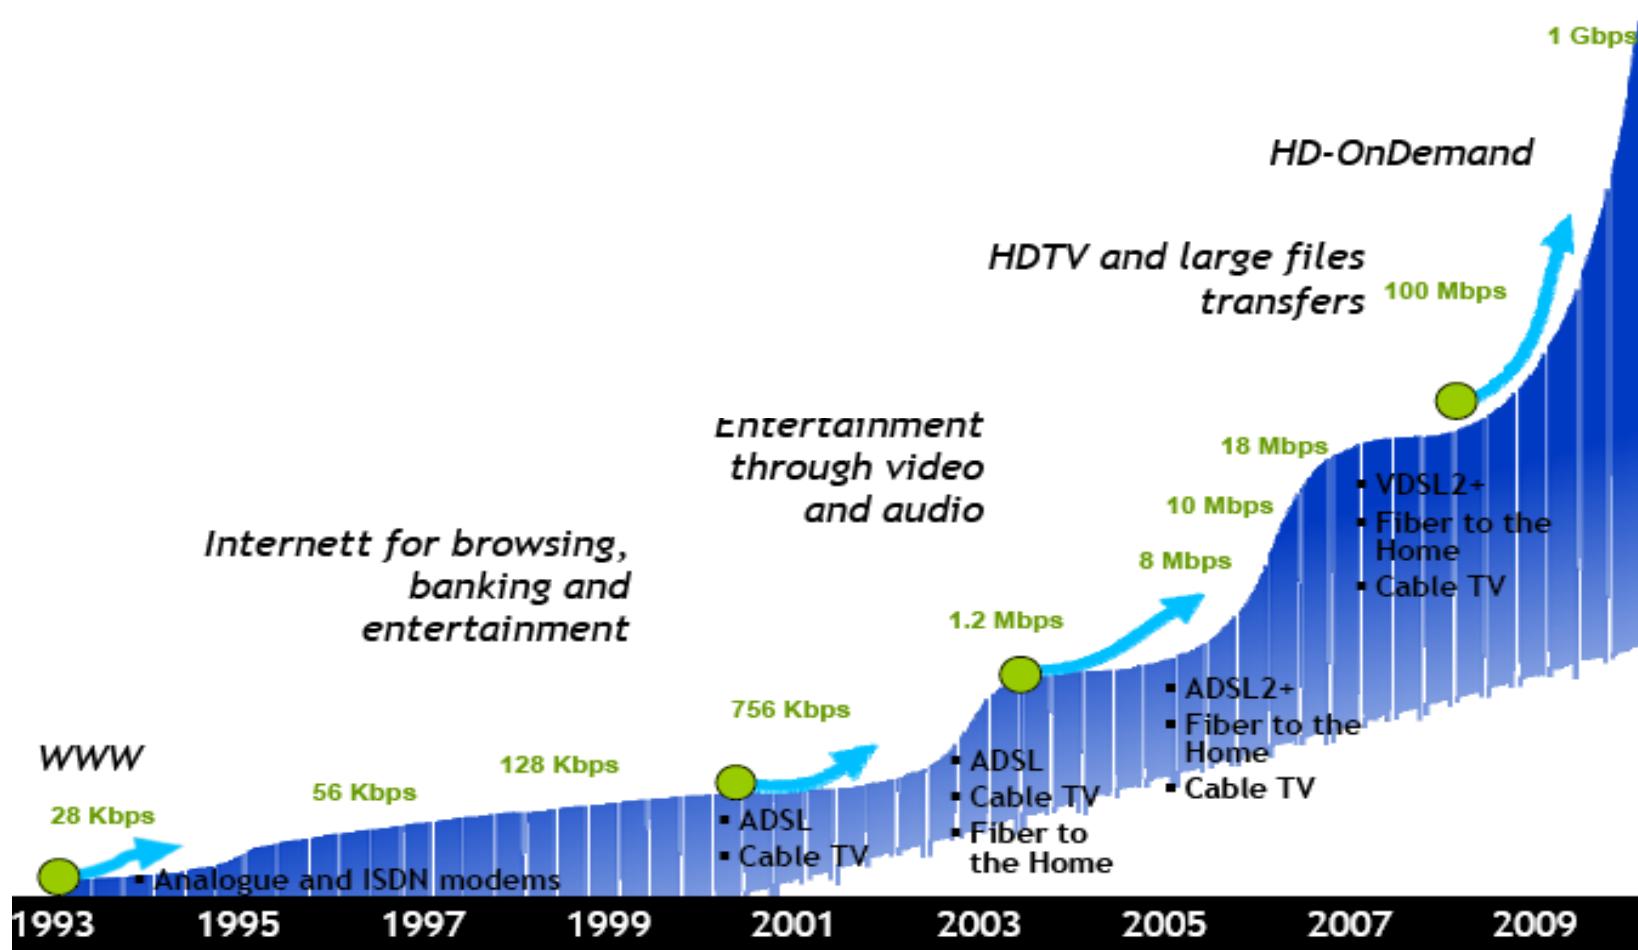
Σύγχρονα Εμπόδια

- Τείχος Ισχύος +
- Τείχος Μνήμης +
- Τείχος ILP

Πριν: Uniprocessor performance 2X / 1.5 yrs

Τώρα: Uniprocessor performance only 2X / 5 yrs?

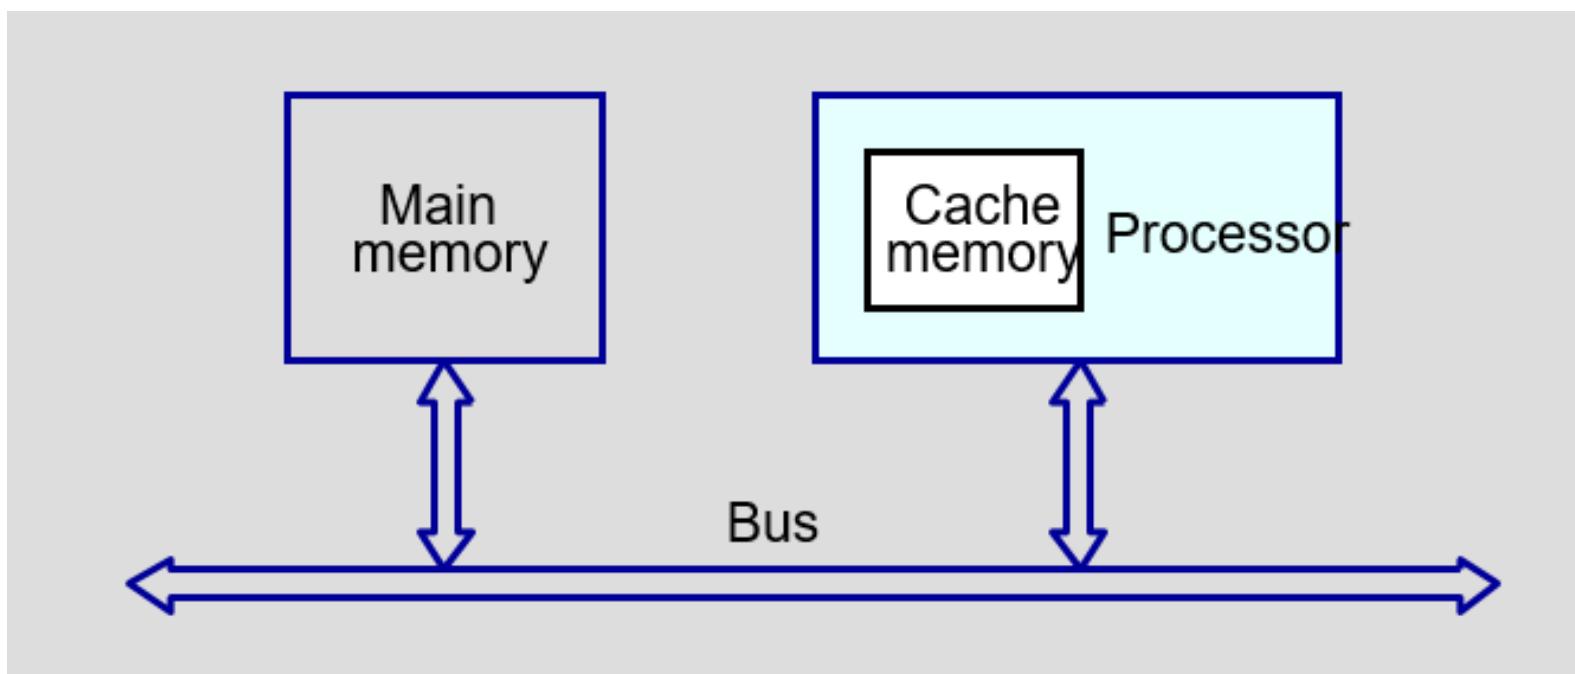
Εξέλιξη Εφαρμογών



Τοπικότητα της Αναφοράς

■ Χρονική Τοπικότητα

■ Χωρική Τοπικότητα



Προτυποποίηση

- Έρευνα
- Εκλογίκευση
- Εκμετάλλευση

Κριτήρια Επιτυχίας: SPUR

■ Παράδοση: Απόδοση/Κόστος

Security Ασφάλεια

Privacy Ιδιωτικότητα

Usability (συνολικό κόστος κτήσης)

Reliability Αξιοπιστία

Εισαγωγή

**Αφηρημένες έννοιες και
τεχνολογία υπολογιστών**

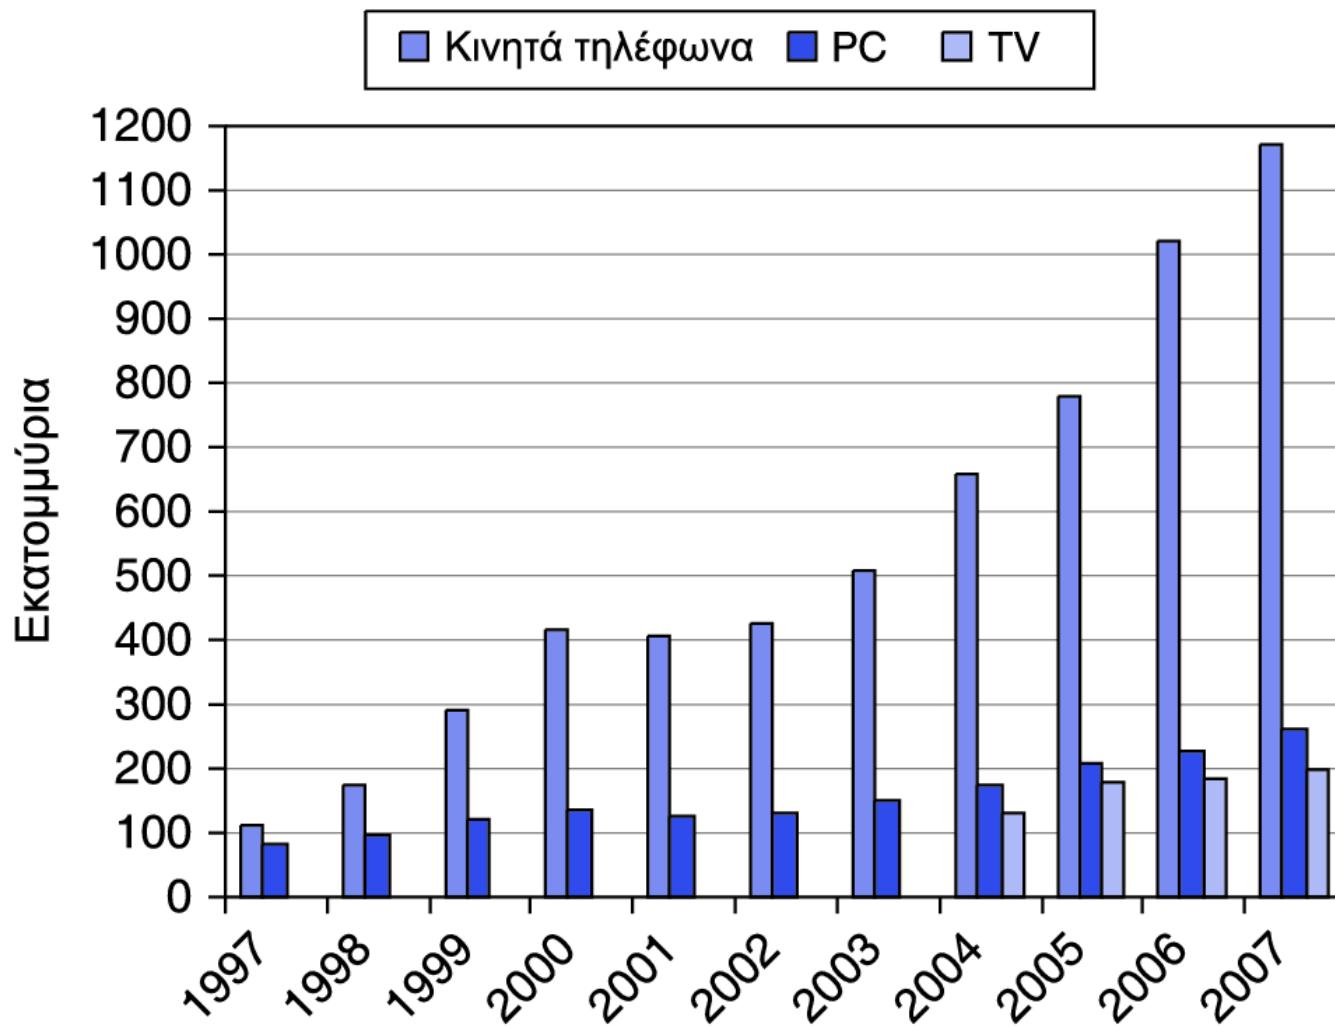
Επανάσταση υπολογιστών

- Πρόοδος της τεχνολογίας υπολογιστών
 - Θεμελιώνεται από το νόμο του Moore
- Καινοτόμες εφαρμογές γίνονται εφικτές
 - Υπολογιστές σε αυτοκίνητα
 - Κινητά τηλέφωνα
 - Ερευνητικό πρόγραμμα ανθρώπινου γονιδιώματος (human genome)
 - Παγκόσμιος Ιστός (World Wide Web)
 - Μηχανές αναζήτησης
 - Υπολογιστικό Νέφος
- Οι υπολογιστές βρίσκονται παντού

Κατηγορίες υπολογιστών

- Επιτραπέζιοι (desktop) υπολογιστές
 - Γενικού σκοπού, ποικιλία λογισμικού
 - Συμβιβασμοί (tradeoffs) κόστους/απόδοσης
- Διακομιστές (servers)
 - Βασίζονται σε δίκτυο
 - Μεγάλη χωρητικότητα, απόδοση, αξιοπιστία
 - Εύρος: μικροί διακομιστές μέχρι μέγεθος κτηρίου
- Ενσωματωμένοι (embedded) υπολογιστές
 - «Κρυμμένοι» ως συστατικά άλλων συστημάτων
 - Αυστηροί περιορισμοί ισχύος/απόδοσης/κόστους

Η αγορά των επεξεργαστών



Τι θα μάθουμε

- Πώς μεταφράζονται τα προγράμματα στη γλώσσα της μηχανής
 - Και πώς τα εκτελεί το υλικό
- Τη διασύνδεση υλικού και λογισμικού
- Τι καθορίζει την απόδοση των προγραμμάτων
 - Και πώς αυτή μπορεί να βελτιωθεί
- Πώς βελτιώνουν την απόδοση οι σχεδιαστές του υλικού
- Τι είναι η παράλληλη επεξεργασία

Κατανόηση της απόδοσης

- Αλγόριθμος
 - Καθορίζει τον αριθμό λειτουργιών που εκτελούνται
- Γλώσσα προγραμματισμού, μεταγλωττιστής, αρχιτεκτονική
 - Καθορίζουν τον αριθμό των εντολών μηχανής που εκτελούνται ανά λειτουργία
- Επεξεργαστής και σύστημα μνήμης
 - Καθορίζουν την ταχύτητα εκτέλεσης των εντολών
- Σύστημα Εισόδου/Εξόδου (περιλαμβάνει και το Λειτουργικό Σύστημα)
 - Καθορίζει την ταχύτητα εκτέλεσης των λειτουργιών εισόδου/εξόδου

Κάτω από το πρόγραμμά μας



- Λογισμικό εφαρμογών
 - Γραμμένο σε γλώσσα υψηλού επιπέδου (high-level language)
- Λογισμικό συστημάτων
 - Μεταγλωττιστής (compiler): μεταφράζει κώδικα HLL σε κώδικα μηχανής
 - Λειτουργικό σύστημα: κώδικας υπηρεσιών
 - Χειρισμός εισόδου/εξόδου
 - Διαχείριση μνήμης και αποθήκευσης
 - Χρονοπρογραμματισμός εργασιών & κοινή χρήση πόρων

Υλικό

- Επεξεργαστής, μνήμη, ελεγκτές εισόδου/εξόδου

Επίπεδα κώδικα προγράμματος

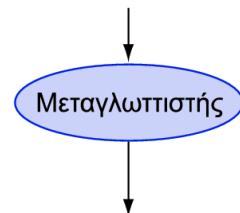
- Γλώσσα υψηλού επιπέδου
 - Επίπεδο αφαίρεσης πιο κοντά στο πρόβλημα
 - Παρέχει παραγωγικότητα και φορητότητα
 - Συμβολική γλώσσα (assembly language)
 - Αναπαράσταση εντολών μηχανής με κείμενο
 - Αναπαράσταση υλικού
 - Δυαδικά ψηφία (bit)
 - Κωδικοποιημένες εντολές και δεδομένα

Πρόγραμμα
γλώσσας
υψηλού
επιπέδου
(σε γλώσσα C)

```

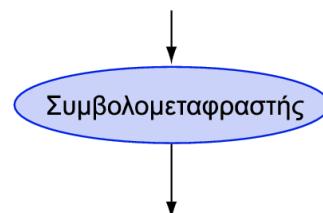
swap(int v[], int k)
{int temp;
    temp = v[k];
    v[k] = v[k+1];
    v[k+1] = temp;
}

```



Πρόγραμμα
συμβολικής
γλώσσας
(για επεξεργαστή MIPS)

```
swap:  
    multi $2, $5, 4  
    add   $2, $4, $2  
    lw    $15, 0($2)  
    lw    $16, 4($2)  
    sw    $16, 0($2)  
    sw    $15, 4($2)  
    jr    $31
```

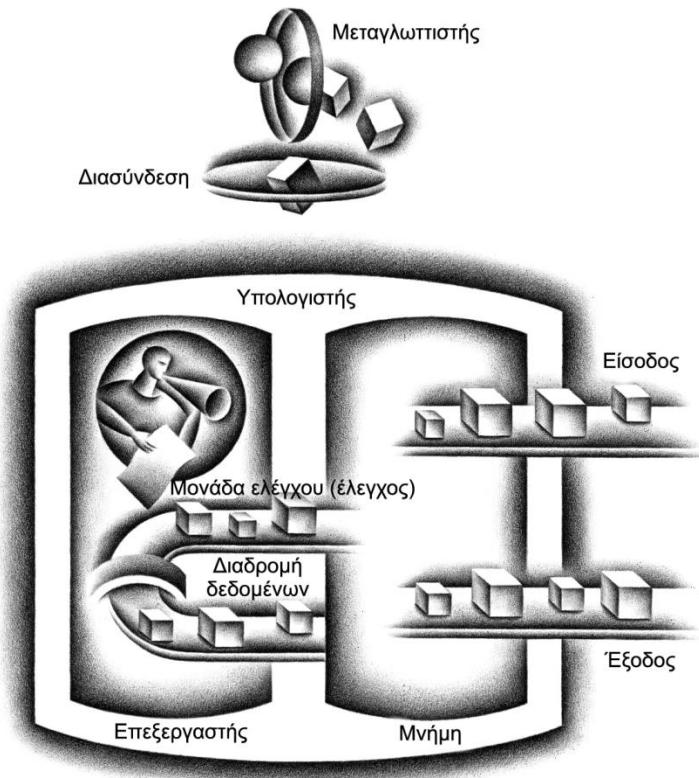


Πρόγραμμα
δυαδικής
γλώσσας
μηχανής
(για επεξεργαστή
MIPS)

```
00000000101000100000000100011000  
00000000100000100001000000100000  
100011011110001000000000000000000  
1000111000010010000000000000000100  
10101110000100100000000000000000000  
1010110111100010000000000000000100  
00000011111000000000000000000000001000
```

Συστατικά ενός υπολογιστή

ΓΕΝΙΚΗ ΣΙΚΟΝΑ



- Τα ίδια συστατικά για όλα τα είδη υπολογιστών
 - Επιτραπέζιοι, διακομιστές, ενσωματωμένοι
- Η είσοδος/έξοδος περιλαμβάνει
 - Συσκευές διασύνδεσης χρήστη (user-interface)
 - Οθόνη, πληκτρολόγιο, ποντίκι
 - Συσκευές αποθήκευσης
 - Σκληρός δίσκος, CD/DVD, flash
 - Προσαρμογές δικτύου (network adapters)
 - Επικοινωνία με άλλους υπολογιστές

Ανατομία ενός υπολογιστή

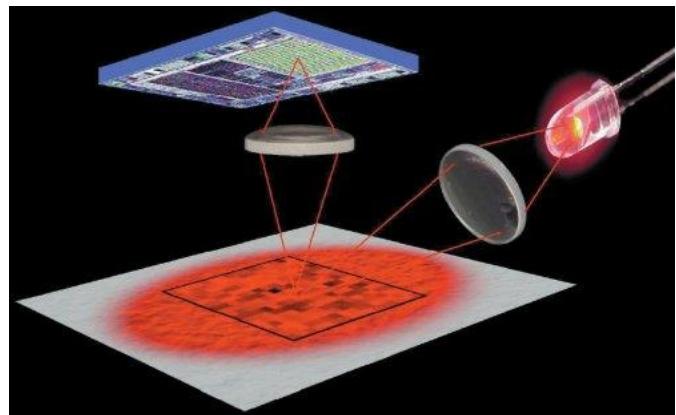


Ανατομία ενός ποντικού

■ Οπτικό ποντίκι

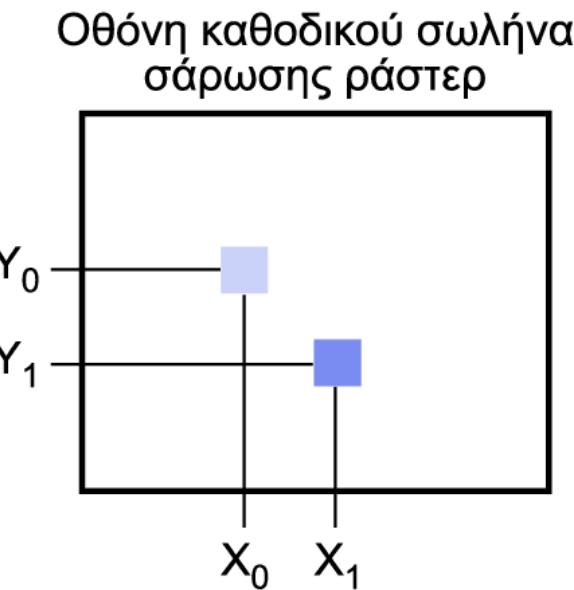
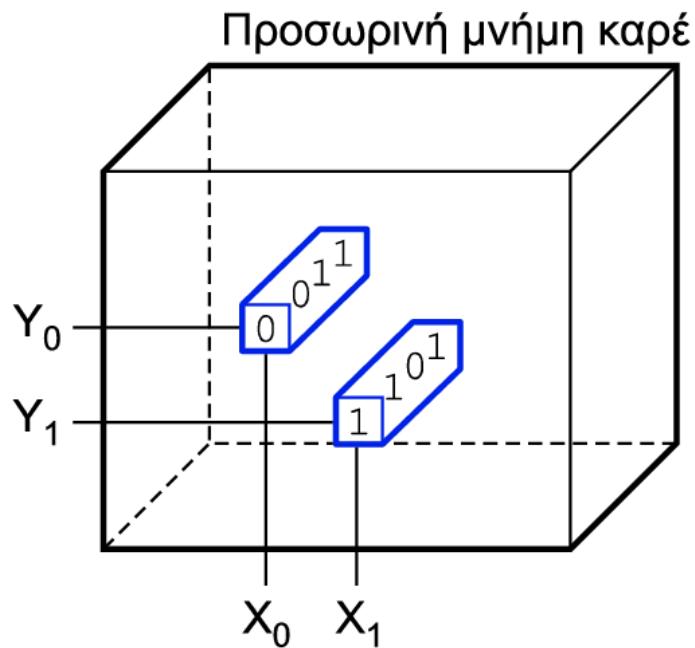
- Μια LED φωτίζει την επιφάνεια γραφείου
- Μικρή κάμερα χαμηλής ανάλυσης
- Βασικός οπτικός επεξεργαστής
 - Παρατηρεί μετακινήσεις στους άξονες x, y
- Πλήκτρα & τροχός

■ Αντικαθιστά το μηχανικό ποντίκι με την μπίλια

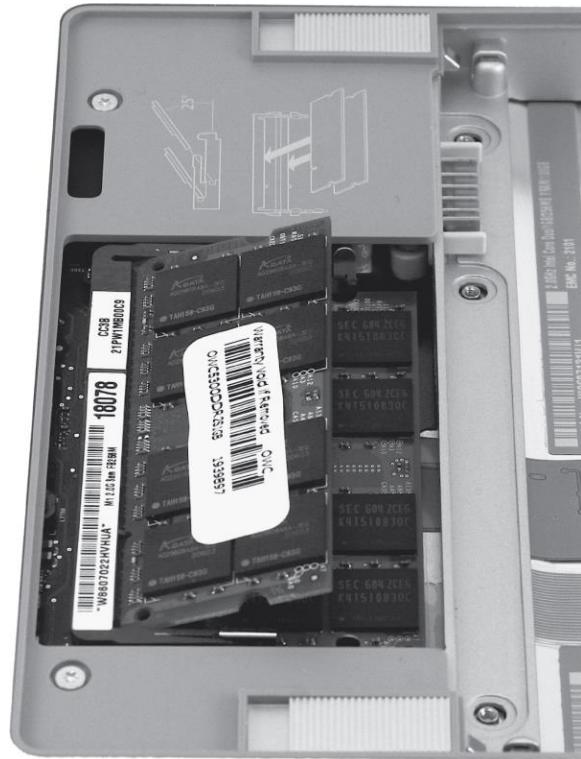
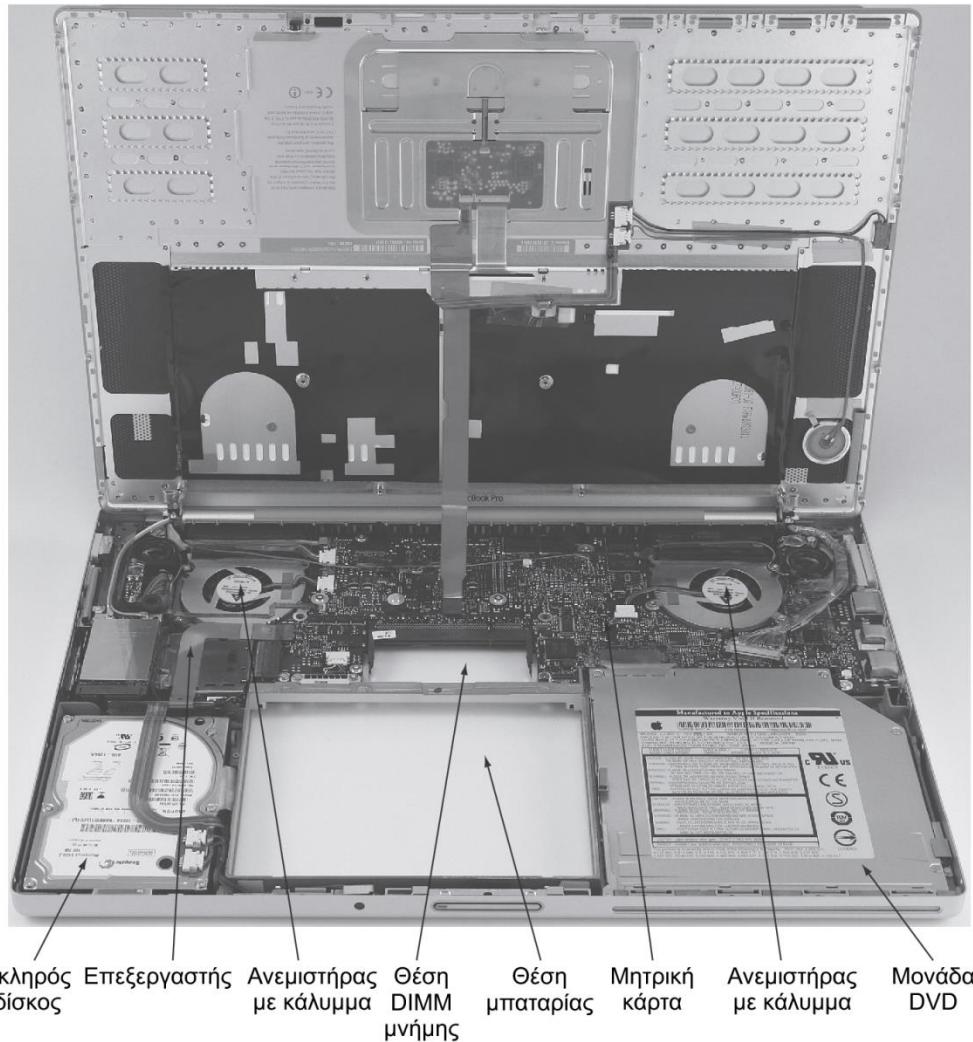


Μέσα από τον καθρέφτη

- Οθόνη LCD (liquid crystal display): πίξελ (pixels), ή εικονοστοιχεία
 - Αντικατοπτρίζει τα περιεχόμενα της προσωρινής μνήμης καρέ (frame buffer)



Το άνοιγμα του κουτιού

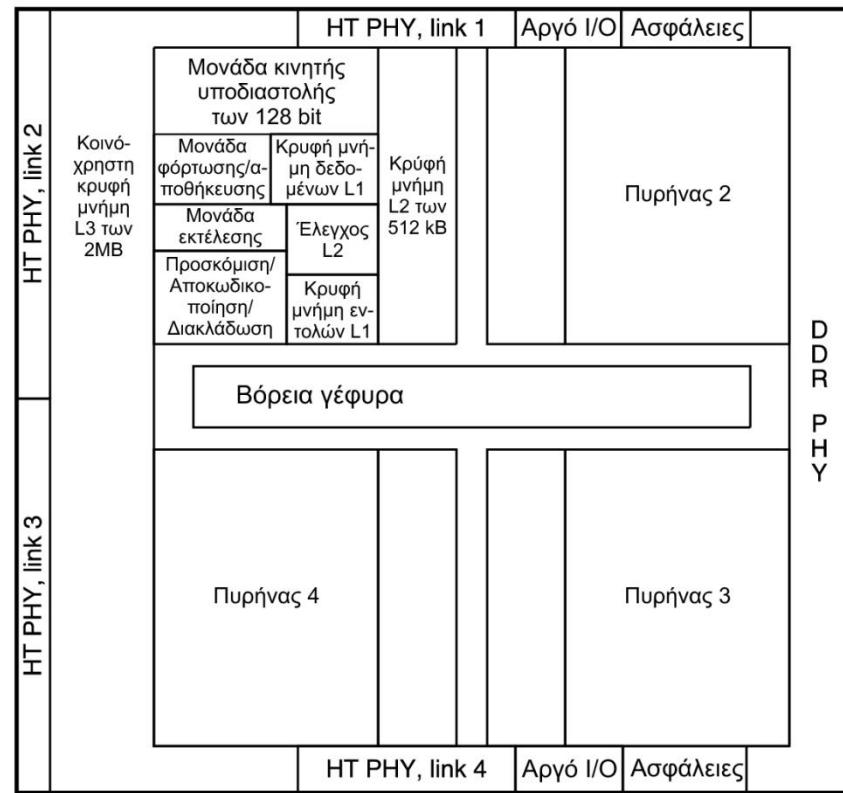
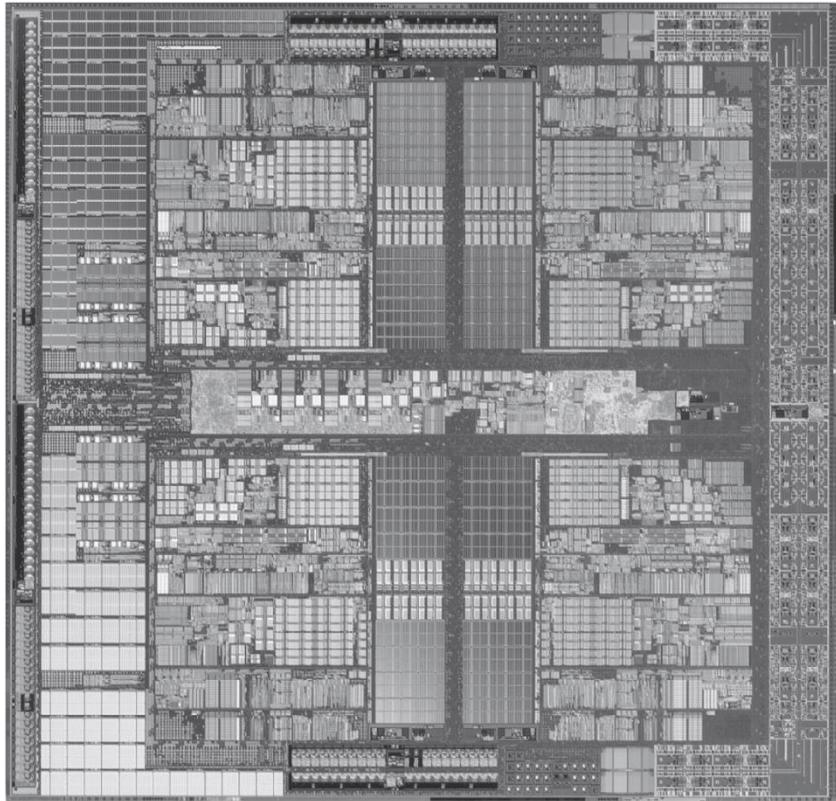


Μέσα στον επεξεργαστή, CPU

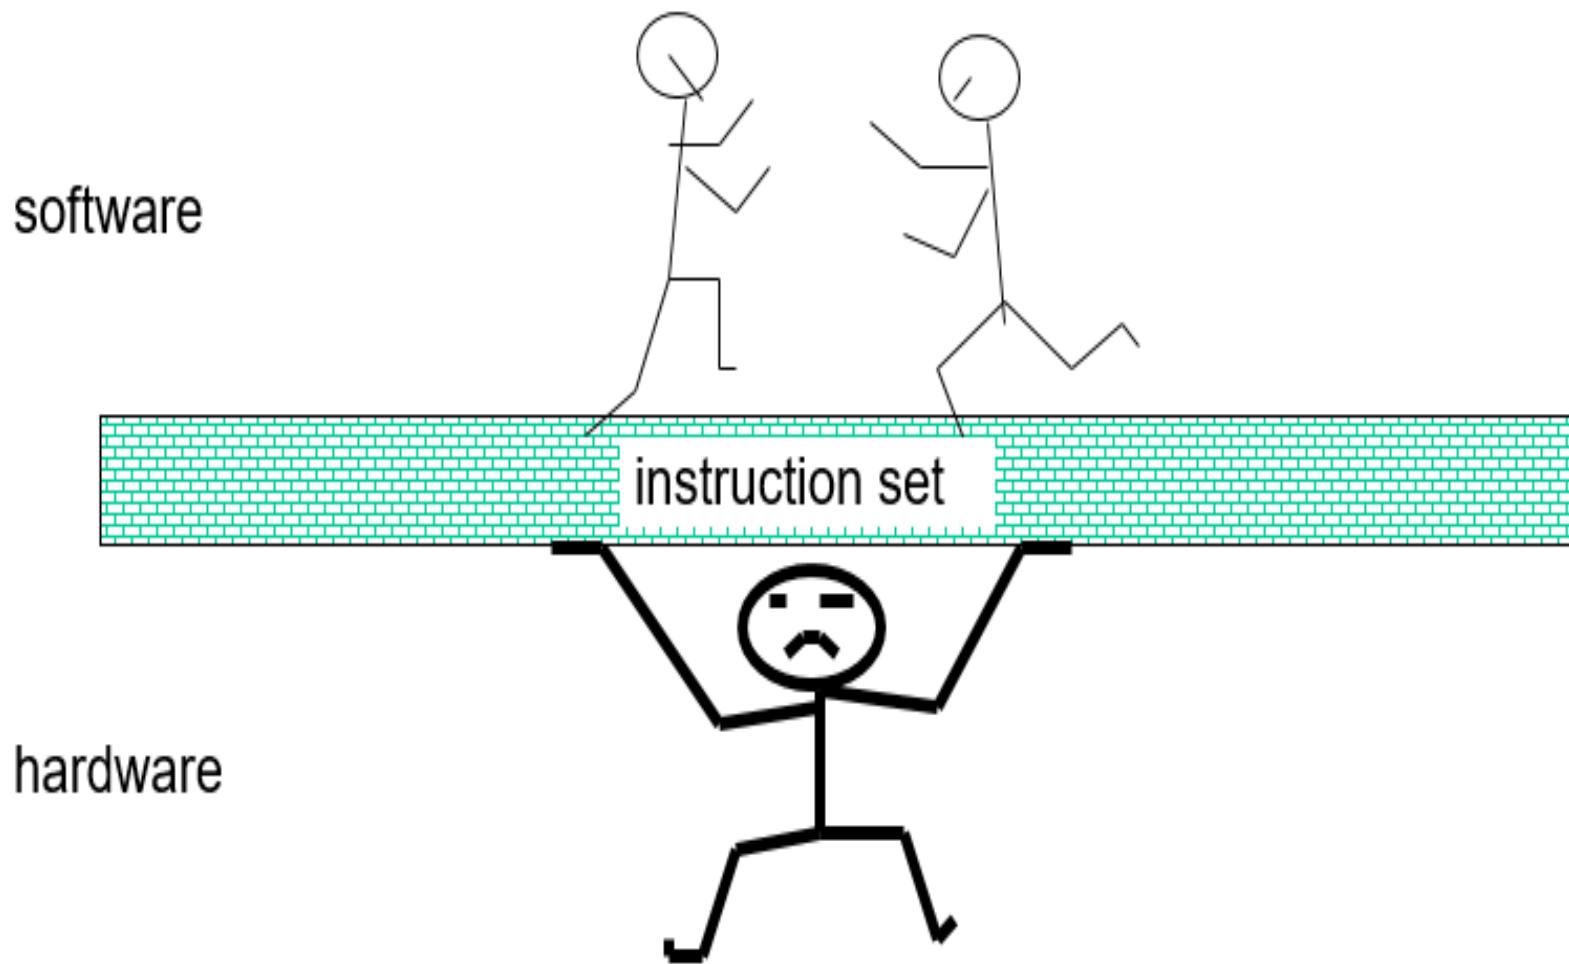
- Διαδρομή δεδομένων (datapath): εκτελεί λειτουργίες στα δεδομένα
- Έλεγχος: ορίζει την ακολουθία λειτουργιών στη διαδρομή δεδομένων, τη μνήμη, ...
- Κρυφή μνήμη (cache memory)
 - Μικρή γρήγορη μνήμη SRAM για άμεση προσπέλαση δεδομένων

Μέσα στον Επεξεργαστή

- AMD Barcelona: 4 πυρήνες (cores) επεξεργαστή



Υλικό-Λογισμικό



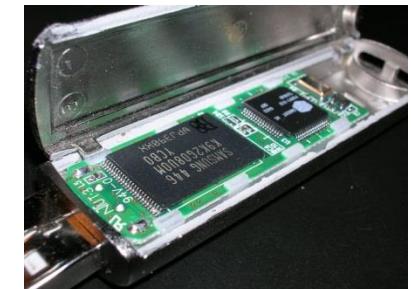
Αφαιρέσεις (Abstractions)

ΓΕΝΙΚΗ ΕΙΚΟΝΑ

- Οι αφαιρέσεις μάς βοηθούν να χειριστούμε την πολυπλοκότητα
 - Κρύβουν λεπτομέρειες χαμηλού επιπέδου
- Αρχιτεκτονική συνόλου εντολών (Instruction set architecture – ISA)
 - Η διασύνδεση υλικού και λογισμικού
- Δυαδική διασύνδεση εφαρμογής (application binary interface)
 - Η ISA και επιπλέον η διασύνδεση του λογισμικού συστημάτων
- Υλοποίηση
 - Οι λεπτομέρειες κάτω από μια διασύνδεση

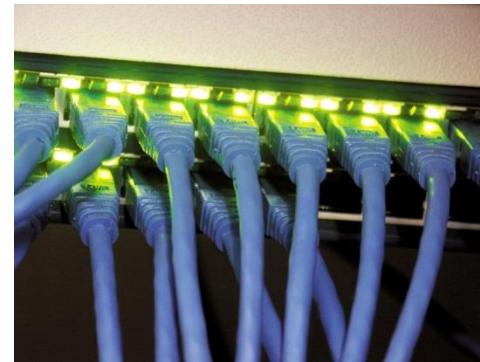
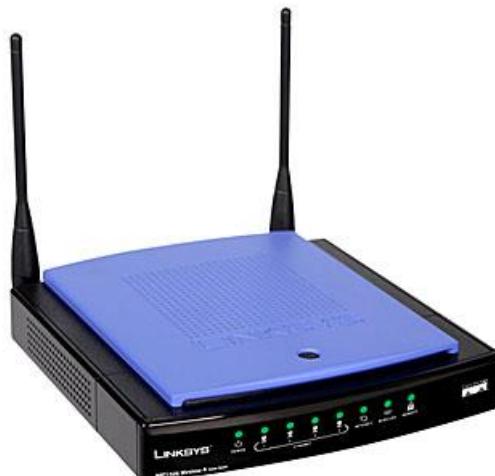
Ασφαλές μέρος για δεδομένα

- Πτητική (volatile) κύρια μνήμη
 - Χάνει τις εντολές και δεδομένα όταν δεν έχει ρεύμα
- Μη πτητική (non-volatile) δευτερεύουσα μνήμη
 - Μαγνητικός δίσκος
 - Μνήμη φλας (flash)
 - Οπτικός δίσκος (CDROM, DVD)



Δίκτυα

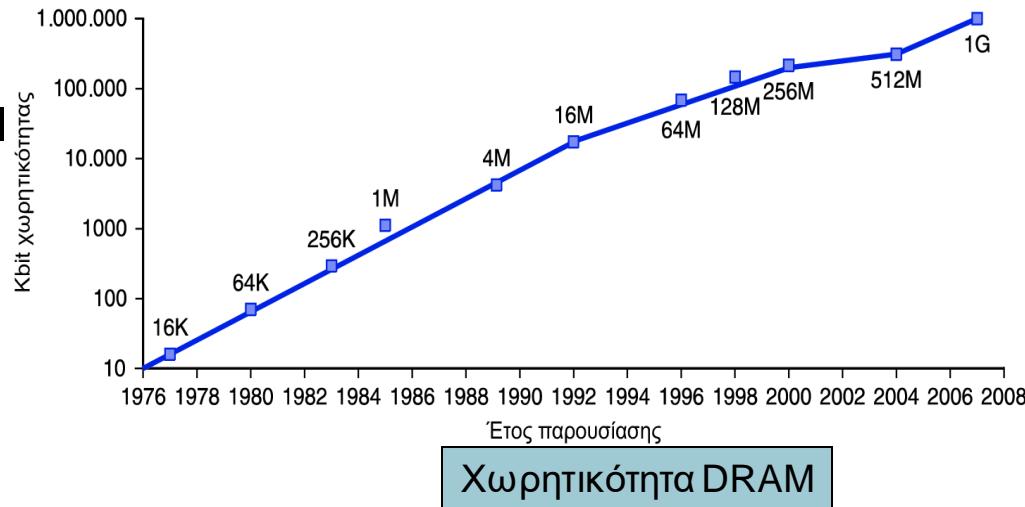
- Επικοινωνία και κοινή χρήση πόρων
- Τοπικό δίκτυο (local area network, LAN): Ethernet
 - Μέσα σε ένα κτήριο
- Δίκτυο ευρείας περιοχής (wide area network, WAN): το Internet
- Ασύρματο δίκτυο: WiFi, BLE, Zigbee



Τάσεις της τεχνολογίας

■ Τεχνολογία ηλεκτρονικών συνεχίζει να εξελίσσεται

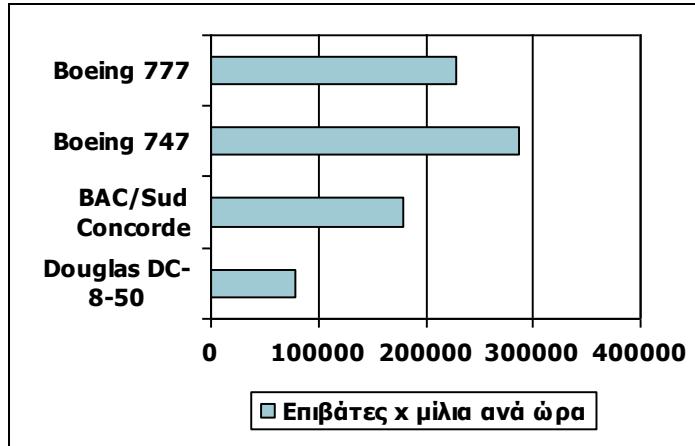
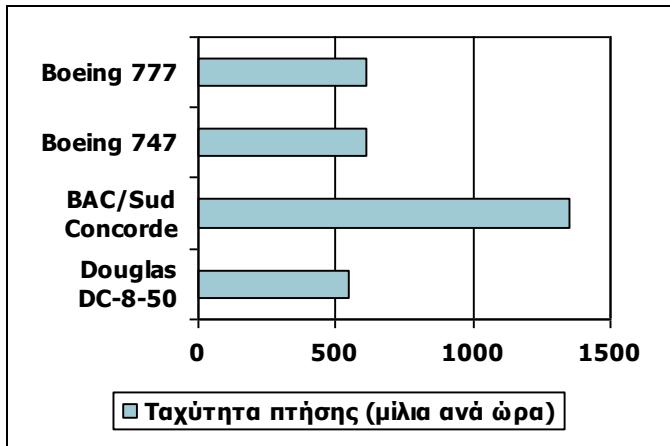
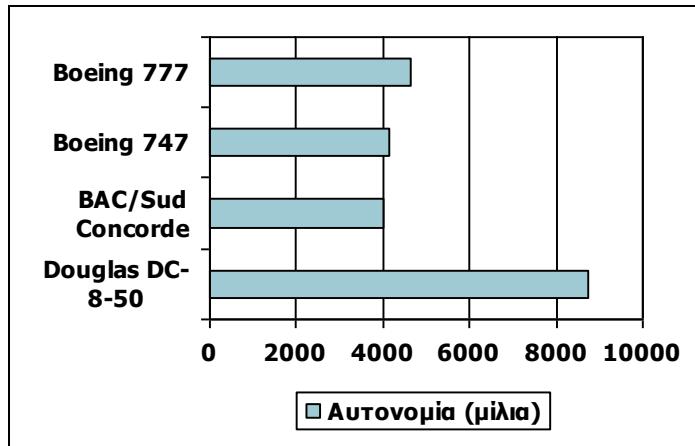
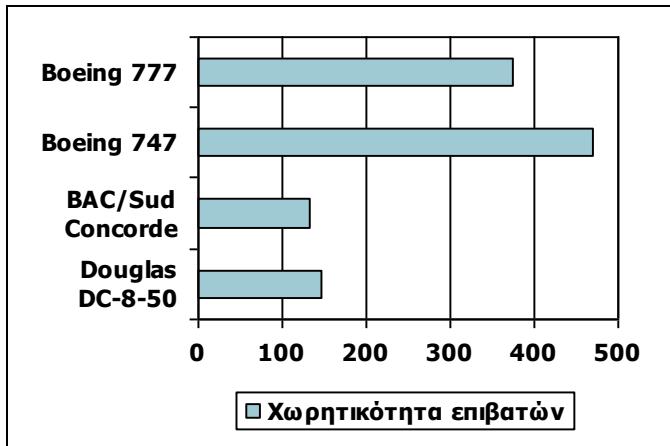
- Μεγαλύτερη χωρητικότητα και απόδοση
- Μειωμένο κόστος



Έτος	Τεχνολογία	Σχετική απόδοση/κόστος
1951	Λυχνία κενού	1
1965	Τρανζίστορ	35
1975	Ολοκληρωμένο κύκλωμα	900
1995	Πολύ μεγάλης κλίμακας ολοκληρωμένο κύκλωμα (VLSI)	2.400.000
2005	Υπερυψηλής κλίμακας ολοκληρωμένο κύκλωμα (ULSI)	6.200.000.000

Ορισμός της απόδοσης

- Ποιο αεροπλάνο έχει την καλύτερη απόδοση;



Response time – Throughput

- Χρόνος απόκρισης (response time)
 - Πόσο διαρκεί η εκτέλεση μιας εργασίας
- Διεκπεραιωτική ικανότητα (throughput)
 - Συνολική δουλειά που γίνεται ανά μονάδα χρόνου
 - π.χ. εργασίες/συναλλαγές/... ανά ώρα
- Πώς επηρεάζονται ο χρόνος απόκρισης και η διεκπεραιωτική ικανότητα από
 - Αντικατάσταση του επεξεργαστή με ταχύτερη έκδοση;
 - Προσθήκη νέων επεξεργαστών;
- Εστιάζουμε στο χρόνο απόκρισης προς το παρόν...

Σχετική απόδοση

- Ορισμός Απόδοση = $1/\text{Χρόνος εκτέλεσης}$
- “ο X είναι n φορές ταχύτερος από τον Y”

Απόδοση_X/Απόδοση_Y

$$= \text{Χρονος εκτέλεσης}_Y / \text{Χρόνος εκτέλεσης}_X = n$$

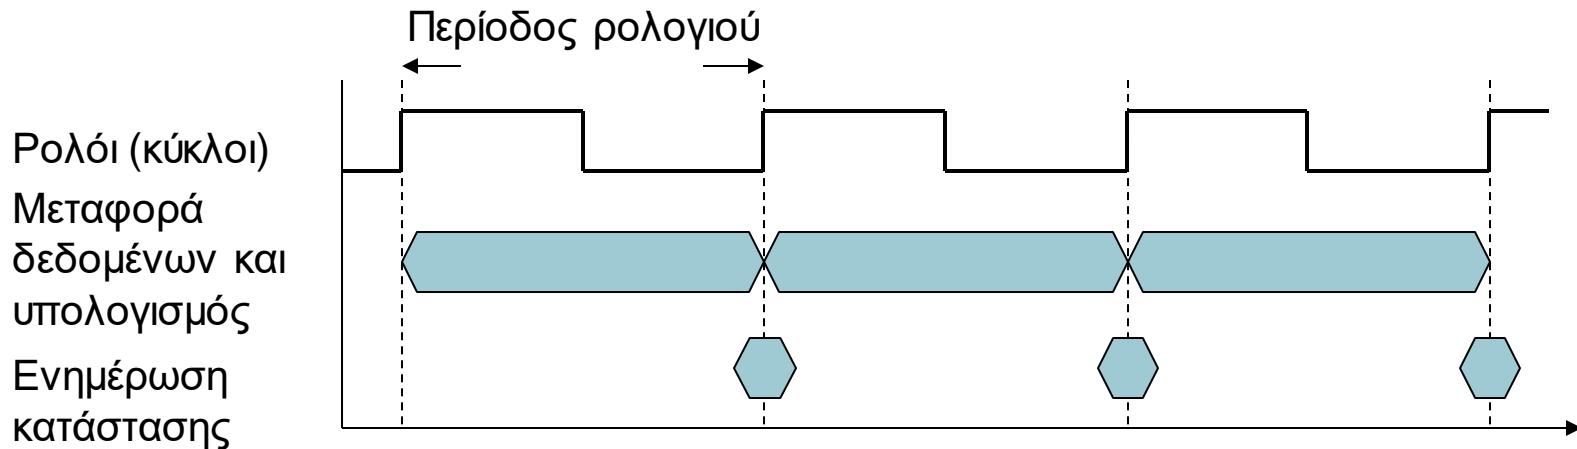
- παράδειγμα: χρόνος εκτέλεσης προγρ/τος
 - 10s στον A, 15s στον B
 - $\text{Χρόνος εκτέλεσης}_B / \text{Χρόνος εκτέλεσης}_A$
 $= 15s / 10s = 1.5$
 - Άρα ο A είναι 1.5 φορές ταχύτερος του B

Μέτρηση χρόνου εκτέλεσης

- «Παρελθών» χρόνος (elapsed time)
 - Συνολικός χρόνος απόκρισης, περιλαμβάνει **τα πάντα**
 - Επεξεργασία, είσοδο/έξοδο, επιβάρυνση ΛΣ, αδρανής χρόνος
 - Καθορίζει την απόδοση του συστήματος
- Χρόνος CPU (CPU time)
 - Ο χρόνος επεξεργασίας για μια συγκεκριμένη εργασίας
 - Χωρίς το χρόνο εισόδου/εξόδου και την κοινή χρήση από άλλες εργασίες
 - Αποτελείται από το χρόνο CPU χρήστη και το χρόνο CPU συστήματος
 - Διαφορετικά προγράμματα επηρεάζονται διαφορετικά από την απόδοση της CPU και του συστήματος

Χρονισμός CPU (clocking)

- Η λειτουργία του ψηφιακού υλικού ρυθμίζεται από ένα ρολόι σταθερού ρυθμού



- Περίοδος ρολογιού: η διάρκεια ενός κύκλου
 - π.χ., $250\text{ps} = 0.25\text{ns} = 250 \times 10^{-12}\text{s}$
- Συχνότητα (ρυθμός) ρολογιού: κύκλοι/second
 - π.χ., $4.0\text{GHz} = 4000\text{MHz} = 4.0 \times 10^9\text{Hz}$

Χρόνος CPU (CPU time)

Χρόνος CPU = ΚύκλοιρολογιούCPU × Χρόνος κύκλουρολογιού

$$= \frac{\text{ΚύκλοιρολογιούCPU}}{\text{Ρυθμόςρολογιού}}$$

- Η απόδοση βελτιώνεται με
 - Μείωση του αριθμού των κύκλων ρολογιού
 - Αύξηση του ρυθμού του ρολογιού
- Ο σχεδιαστής του υλικού κάνει συχνά συμβιβασμούς μεταξύ του ρυθμού ρολογιού και του πλήθους των κύκλων ρολογιού

Παράδειγμα χρόνου CPU

- Υπολογιστής A: ρολόι 2GHz, χρόνος CPU 10s
- Σχεδίαση του Υπολογιστή B
 - Στόχος είναι χρόνος CPU 6s
 - Μπορεί το ρολόι να είναι ταχύτερο, αλλά προκαλεί αύξηση των κύκλων $1.2 \times$ κύκλοι ρολογιού
- Πόσο ταχύτερο μπορεί να είναι το ρολόι του B;

$$\text{Ρυθμός ρολογιού}_B = \frac{\text{Κύκλοι ρολογιού}_B}{\text{Χρόνος CPU}_B} = \frac{1.2 \times \text{Κύκλοι ρολογιού}_A}{6s}$$

$$\begin{aligned}\text{Κύκλοι ρολογιού}_A &= \text{Χρόνος CPU}_A \times \text{Ρυθμός ρολογιού}_A \\ &= 10s \times 2\text{GHz} = 20 \times 10^9\end{aligned}$$

$$\text{Ρυθμός ρολογιού}_B = \frac{1.2 \times 20 \times 10^9}{6s} = \frac{24 \times 10^9}{6s} = 4\text{GHz}$$

Πλήθος εντολών και CPI

Κύκλοι ρολογιού = Πλήθος εντολών × Κύκλοι ανά εντολή (CPI)

Χρόνος CPU = Πλήθος εντολών × CPI × Χρόνος κκύκλο ρολογιού

$$= \frac{\text{Πλήθος εντολών} \times \text{CPI}}{\text{Ρυθμός ρολογιού}}$$

- Πλήθος εντολών (Instruction Count) προγράμματος
 - Καθορίζεται από το πρόγραμμα, την αρχιτεκτονική συνόλου εντολών (ISA), και το μεταγλωττιστή
- Μέσος αριθμός κύκλων ανά εντολή (CPI – clocks per instruction)
 - Καθορίζεται από το υλικό της CPU
 - Αν οι διαφορετικές εντολές έχουν διαφορετικό CPI
 - Το μέσο CPI επηρεάζεται από το μίγμα των εντολών

Παράδειγμα CPI

- Υπολογιστής A: Cycle Time = 250ps, CPI = 2.0
- Υπολογιστής B: Cycle Time = 500ps, CPI = 1.2
- ίδια αρχιτεκτονική συνόλου εντολών (ISA)
- Ποιος είναι ταχύτερος, και κατά πόσο;

$$\begin{aligned}\text{Χρόνος } \text{CPU}_A &= \text{Πλήθος εντολών} \times \text{CPI}_A \times \text{Χρόνος κύκλου}_A \\ &= I \times 2.0 \times 250\text{ps} = I \times 500\text{ps} \quad \leftarrow \boxed{\text{Α ταχύτερος...}}\end{aligned}$$

$$\begin{aligned}\text{Χρόνος } \text{CPU}_B &= \text{Πλήθος εντολών} \times \text{CPI}_B \times \text{Χρόνος κύκλου}_B \\ &= I \times 1.2 \times 500\text{ps} = I \times 600\text{ps}\end{aligned}$$

$$\frac{\text{Χρόνος } \text{CPU}_B}{\text{Χρόνος } \text{CPU}_A} = \frac{I \times 600\text{ps}}{I \times 500\text{ps}} = 1.2 \quad \leftarrow \boxed{\dots \text{κατά τόσο}}$$

Το CPI με λεπτομέρεια

- Αν διαφορετικές κατηγορίες εντολών διαρκούν διαφορετικό αριθμό κύκλων

$$\text{Κύκλοι ρολογιού} = \sum_{i=1}^n (\text{CPI}_i \times \text{Πλήθος εντολών}_i)$$

- Σταθμισμένο (weighted) μέσο CPI

$$\text{CPI} = \frac{\text{Κύκλοιρολογιού}}{\text{Πλήθος εντολών}} = \sum_{i=1}^n \left(\text{CPI}_i \times \underbrace{\frac{\text{Πλήθος εντολών}_i}{\text{Πλήθος εντολών}}} \right)$$

Σχετική συχνότητα εντολών

Παράδειγμα CPI

- Εναλλακτικές ακολουθίες μεταγλωττισμένου κώδικα με εντολές τριών κατηγοριών A, B, C

Κατηγορία εντολών	A	B	C
CPI για εντολές της κατηγορίας	1	2	3
Πλήθος εντολών (IC) Ακολουθία 1	2	1	2
Πλήθος εντολών (IC) Ακολουθία 2	4	1	1

- Ακολουθία 1: IC = 5
 - Κύκλοι ρολογιού
 $= 2 \times 1 + 1 \times 2 + 2 \times 3$
 $= 10$
 - Μέσο CPI = $10/5 = 2.0$
- Ακολουθία 2: IC = 6
 - Κύκλοι ρολογιού
 $= 4 \times 1 + 1 \times 2 + 1 \times 3$
 $= 9$
 - Μέσο CPI = $9/6 = 1.5$

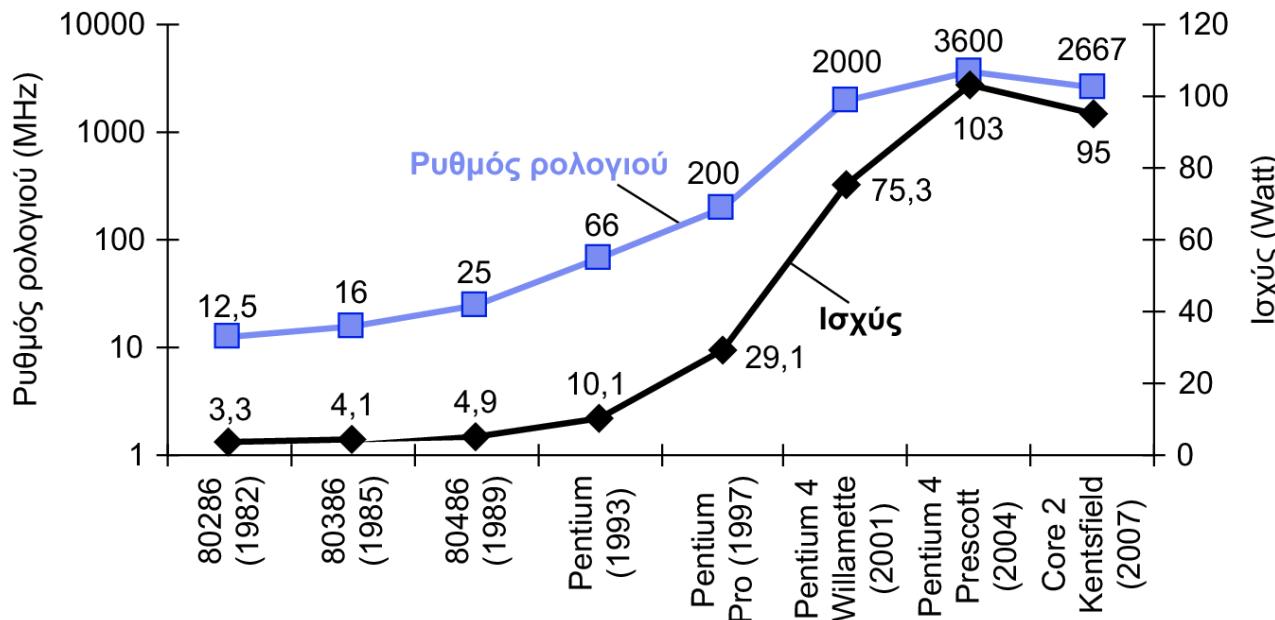
Σύνοψη της απόδοσης

ΓΕΝΙΚΗ ΣΙΚΟΝΑ

$$\text{Χρόνος CPU} = \frac{\text{Εντολές}}{\text{Πρόγραμμα}} \times \frac{\text{Κύκλοι ρολογιού}}{\text{Εντολή}} \times \frac{\text{Δευτερόλεπτα}}{\text{Κύκλος ρολογιού}}$$

- Η απόδοση εξαρτάται από:
 - Αλγόριθμο: επηρεάζει το πλήθος εντολών, πιθανόν και το CPI
 - Γλώσσα προγραμματισμού: επηρεάζει το πλήθος εντολών και το CPI
 - Μεταγλωττιστής: επηρεάζει το πλήθος εντολών και το CPI
 - Αρχιτεκτονική συνόλου εντολών (ISA): επηρεάζει το πλήθος εντολών, το CPI, και την περίοδο (συχνότητα) του ρολογιού

Οι τάσεις στην ηλεκτρική ισχύ



- Στη τεχνολογία ολοκληρωμένων κυκλωμάτων CMOS

$$\text{Ισχύς} = \text{Φορτίο χωρητικότητη τας} \times \text{Τάση}^2 \times \text{Συχνότητα}$$

$\times 30$

$5V \rightarrow 1V$

$\times 1000$

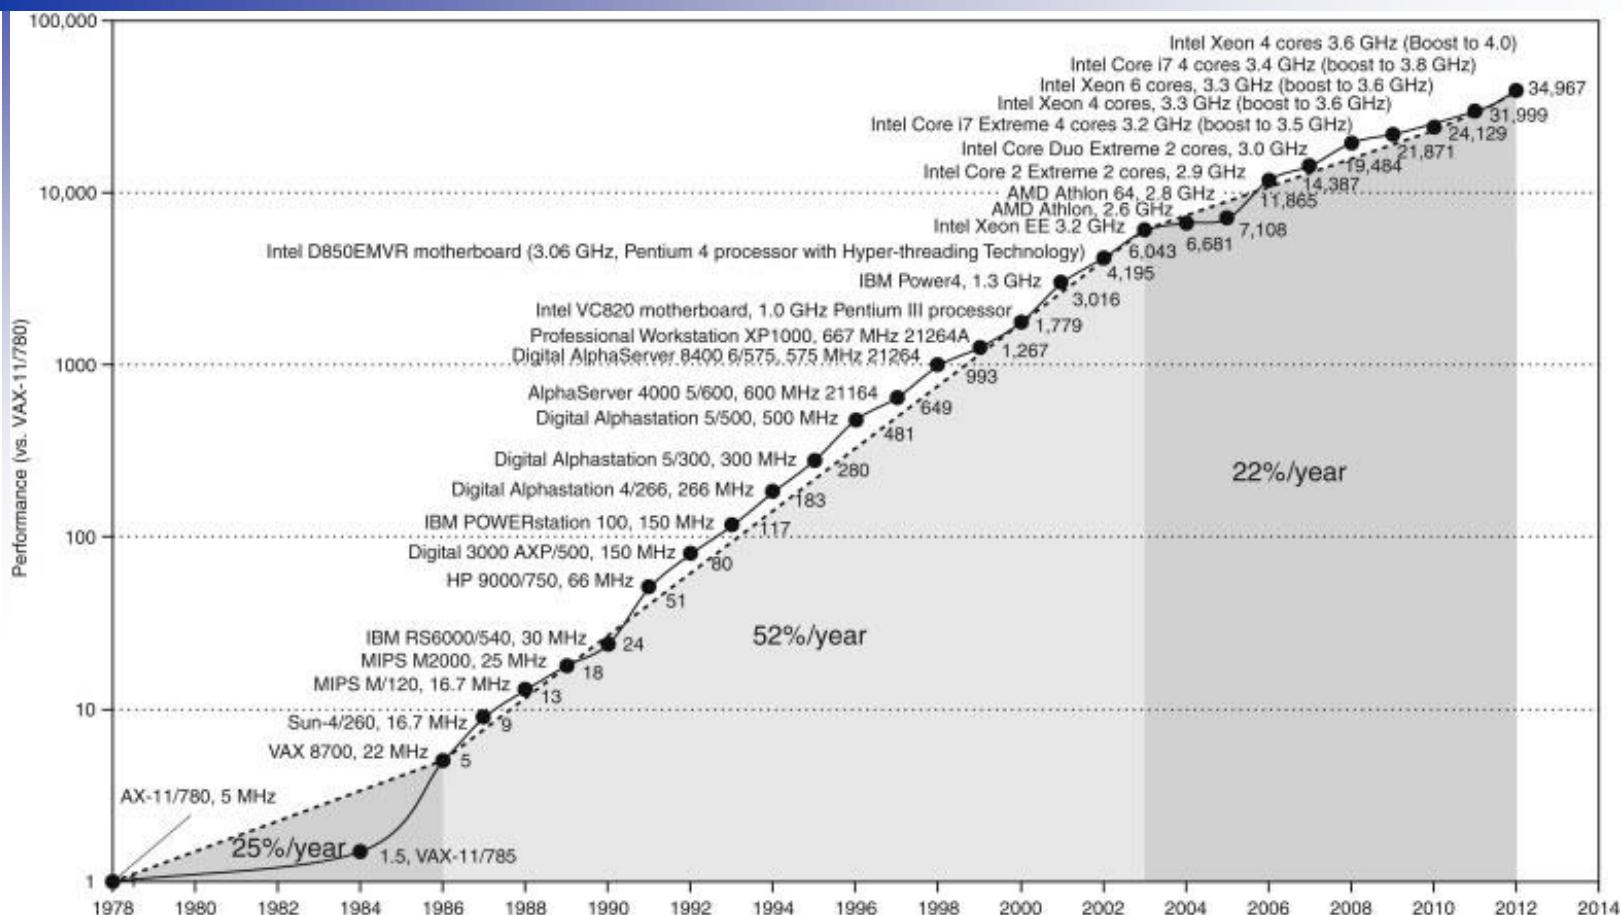
Μείωση της ισχύος

- Υποθέστε ότι μια νέα CPU έχει
 - 85% του φορτίου χωρητικότητας (capacitive load) της παλιάς CPU
 - μειωμένη τάση κατά 15% και συχνότητα κατά 15%

$$\frac{P_{\text{new}}}{P_{\text{old}}} = \frac{C_{\text{old}} \times 0,85 \times (V_{\text{old}} \times 0,85)^2 \times F_{\text{old}} \times 0,85}{C_{\text{old}} \times V_{\text{old}}^2 \times F_{\text{old}}} = 0,85^4 = 0,52$$

- Το τείχος της ισχύος (power wall)
 - Δεν μπορούμε να μειώσουμε άλλο την τάση
 - Δεν μπορούμε να απαγάγουμε τη θερμότητα
- Πώς αλλιώς μπορούμε να βελτιώσουμε την απόδοση;

Απόδοση μονοεπεξεργαστών

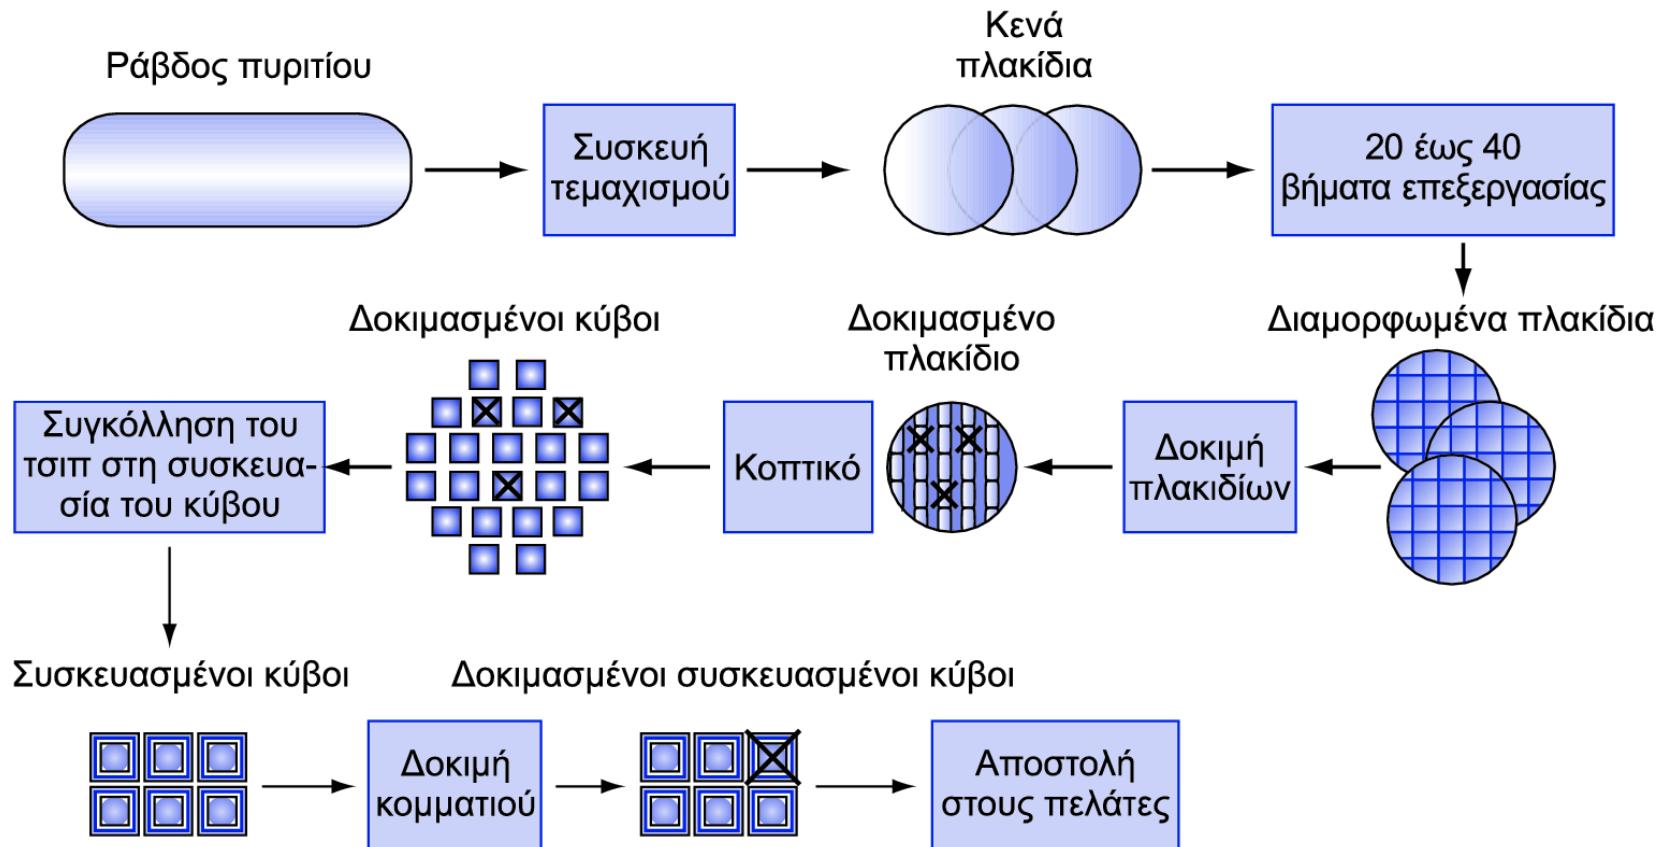


Περιορίζεται από την ισχύ, την παραλληλία επιπέδου εντολής (instruction-level parallelism), το λανθάνοντα χρόνο μνήμης (memory latency)

Πολυεπεξεργαστές

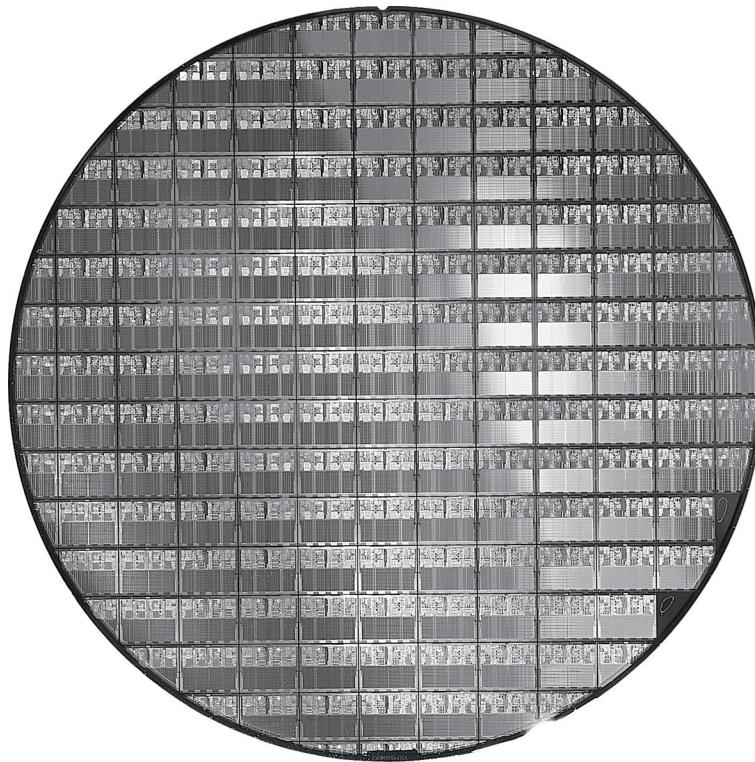
- Πολυπύρηνοι μικροεπεξεργαστές (multicore microprocessors)
 - Περισσότεροι του ενός επεξεργαστές ανά τσιπ
- Απαιτεί ρητό παράλληλο προγραμματισμό (explicitly parallel programming)
 - Σύγκριση με παραλληλία επιπέδου εντολής (instruction level parallelism – ILP)
 - Το υλικό εκτελεί πολλές εντολές ταυτόχρονα
 - Ο προγραμματιστής δεν το γνωρίζει
 - Μεγάλες δυσκολίες
 - Προγραμματισμός για μέγιστη απόδοση
 - Εξισορρόπηση φορτίου (load balancing)
 - Βελτιστοποίηση επικοινωνίας (communication) και συγχρονισμού (synchronization)

Κατασκευή ολοκληρωμένων



- **Εσοδεία (yield):** ποσοστό τσιπ ανά πλακίδιο (wafer) που λειτουργούν σωστά

AMD Opteron X2 Wafer



- X2: 300mm πλακίδιο, 117 τσιπ, τεχνολογία 90nm
- X4: τεχνολογία 45nm

Κόστος Ολοκληρωμένων

$$\text{Κόστος ανά κύβο} = \frac{\text{Κόστος ανά πλακίδιο}}{\text{Κύβοιανά πλακίδιο} \times \text{Εσοδεία}}$$

Κύβοιανά πλακίδιο \approx Επιφάνεια πλακιδίου / Επιφάνεια κύβου

$$\text{Εσοδεία} = \frac{1}{(1 + \text{Ατέλειες} \text{ανά μονάδα επιφανείας} \times \text{Επιφάνεια κύβου} / 2)^2}$$

- Μη γραμμική εξάρτηση από την επιφάνεια (area) και το ρυθμό ατελειών (defect rate)
 - Κόστος και επιφάνεια πλακιδίου (wafer): σταθερά
 - Ρυθμός ατελειών (defect rate) εξαρτάται από τη διαδικασία κατασκευής
 - Επιφάνεια τσιπ (die/chip area): εξαρτάται από την αρχιτεκτονική και τη σχεδίαση του κυκλώματος

Μετροπρογράμματα SPEC CPU

- Χρησιμοποιούνται προγράμματα για τη μέτρηση της απόδοσης
 - Υποτίθεται τυπικά για ένα πραγματικό φορτίο εργασίας (workload)
- Standard Performance Evaluation Corp (SPEC)
 - Αναπτύσσει μετροπρογράμματα (benchmarks) για CPU, είσοδο/έξοδο, Ιστό, ...
- SPEC CPU2006
 - «Παρελθών» (elapsed) χρόνος για την εκτέλεση μιας συλλογής προγραμμάτων
 - Αμελητέα είσοδος/έξοδος, άρα εστιάζουν στην απόδοση της CPU
 - Κανονικοποίηση σε σχέση με μια μηχανή αναφοράς (reference machine)
 - Σύνοψη ως γεωμετρικός μέσος (geometric mean) των λόγων απόδοσης (performance ratios)
 - CINT2006 (integer) and CFP2006 (floating-point)

$$\sqrt[n]{\prod_{i=1}^n \text{Λόγος χρόνου εκτέλεσης}}$$

CINT2006 για Opteron X4 2356

Όνομα	Περιγραφή	IC×10 ⁹	CPI	Tc (ns)	Χρόν. εκτ.	Χρον. ανφ.	SPECratio
perl	Interpreted string processing	2,118	0.75	0.40	637	9,777	15.3
bzip2	Block-sorting compression	2,389	0.85	0.40	817	9,650	11.8
gcc	GNU C Compiler	1,050	1.72	0.40	724	8,050	11.1
mcf	Combinatorial optimization	336	10.00	0.40	1,345	9,120	6.8
go	Go game (AI)	1,658	1.09	0.40	721	10,490	14.6
hmmer	Search gene sequence	2,783	0.80	0.40	890	9,330	10.5
sjeng	Chess game (AI)	2,176	0.96	0.40	837	12,100	14.5
libquantum	Quantum computer simulation	1,623	1.61	0.40	1,047	20,720	19.8
h264avc	Video compression	3,102	0.80	0.40	993	22,130	22.3
omnetpp	Discrete event simulation	587	2.94	0.40	690	6,250	9.1
astar	Games/path finding	1,082	1.79	0.40	773	7,020	9.1
xalancbmk	XML parsing	1,058	2.70	0.40	1,143	6,900	6.0
Geometric mean							11.7

Υψηλοί ρυθμοί αστοχίας κρυφής
μνήμης (cache misses)

Μετροπρογράμματα SPEC Power

- Κατανάλωση ισχύος διακομιστή (server) σε διαφορετικά επίπεδα φορτίου εργασίας
 - Απόδοση: ssj_ops/sec (Server-Side Java Ops)
 - Ισχύς: Watts (Joules/sec)

$$\text{Overall ssj_ops per Watt} = \left(\sum_{i=0}^{10} \text{ssj_ops}_i \right) \Bigg/ \left(\sum_{i=0}^{10} \text{power}_i \right)$$

SPECpower_ssj2008 για X4

Φορτίο στόχου %	Απόδοση (ssj_ops/sec)	Μέση ισχύς (Watts)
100%	231,867	295
90%	211,282	286
80%	185,803	275
70%	163,427	265
60%	140,160	256
50%	118,324	246
40%	920,35	233
30%	70,500	222
20%	47,126	206
10%	23,066	180
0%	0	141
Overall sum	1,283,590	2,605
$\Sigma ssj_ops / \Sigma power$		493

Παγίδα: νόμος του Amdahl

- Η βελτίωση μιας πλευράς ενός υπολογιστή και η αναμονή ανάλογης βελτίωσης της συνολικής απόδοσης

$$T_{\text{μετάτη βελτίωση}} = \frac{T_{\text{που επηρεάζεται}}}{\text{συντελεστής βελτίωσης}} + T_{\text{που δεν επηρεάζεται}}$$

- Παράδειγμα: ο πολ/σμός είναι τα 80s/100s
 - Πόση βελτίωση της απόδοσης του πολ/σμού ώστε η συνολική απόδοση να 5-πλασιαστεί;
$$20 = \frac{80}{n} + 20$$
 - Δεν γίνεται!
- Πόρισμα: κάνε τη συνηθισμένη περίπτωση γρήγορη

Πλάνη: Χαμηλή ισχύς αδράνειας

- Δείτε το μετροπρόγραμμα ισχύος στον X4
 - Στο 100% του φορτίου: 295W
 - Στο 50% του φορτίου: 246W (83%)
 - Στο 10% του φορτίου: 180W (61%)
- Κέντρα δεδομένων Google
 - Κυρίως λειτουργούν στο 10% – 50% του φορτίου
 - Με φορτίο 100% σε λιγότερο από 1% του χρόνου
- Σκεφθείτε τη σχεδίαση επεξεργαστών με κατανάλωση ισχύος ανάλογη με το φορτίο

Παγίδα: μέτρο απόδοσης MIPS

- MIPS: Millions of Instructions Per Second
 - Δεν λαμβάνει υπόψη:
 - Διαφορές ISA μεταξύ υπολογιστών
 - Διαφορές πολυπλοκότητας μεταξύ εντολών

$$\begin{aligned} \text{MIPS} &= \frac{\text{Πλήθος εντολών}}{\text{Χρόνος εκτέλεσης} \times 10^6} \\ &= \frac{\text{Πλήθος εντολών}}{\text{Πλήθος εντολών} \times \text{CPI}} \times 10^6 = \frac{\text{Ρυθμός ρολογιού}}{\text{CPI} \times 10^6} \end{aligned}$$

- Το CPI ποικίλει μεταξύ προγραμμάτων σε μια δεδομένη CPU

Συμπερασματικές παρατηρήσεις

- Ο λόγος κόστος/απόδοση βελτιώνεται
 - Λόγω της εξέλιξης της τεχνολογίας
- Ιεραρχικά επίπεδα αφαίρεσης
 - Στο υλικό και στο λογισμικό
- Αρχιτεκτονική συνόλου εντολών (Instruction set architecture – ISA)
 - Η διασύνδεση υλικού και λογισμικού
- Χρόνος εκτέλεσης: το καλύτερο μέτρο απόδοσης
- Η ισχύς είναι περιοριστικός παράγοντας
 - Χρήση παραλληλίας για βελτίωση της απόδοσης