

ΚΕΦΑΛΑΙΟ 3

Συστήματα κατανεμημένης μνήμης


Distributed memory systems




ΜΥΕΟ23
Παράλληλα
Συστήματα &
Προγραμματισμός

Πολυεπεξεργαστές κατανεμημένης μνήμης

- Ανεξάρτητοι επεξεργαστές, ο καθένας με την ιδιωτική του μνήμη (κόμβος = CPU + μνήμη)




- Δίκτυο διασύνδεσης επεξεργαστών (interconnection network)
 - δίαυλος
 - δίκτυο διακοπών
 - point-to-point, στατικό, άμεσο δίκτυο



Massively Parallel Processors (MPPs)




- Initial Research Projects
 - Caltech Cosmic Cube (early 1980s) using custom Mosaic processors
- Commercial Microprocessors including MPP Support
 - Transputer (1985)
 - nCube-1(1986) /nCube-2 (1990)
- Standard Microprocessors + Network Interfaces
 - Intel Paragon (i860)
 - TMC CM-5 (SPARC)
 - Meiko CS-2 (SPARC)
 - IBM SP-2 (RS/6000)
- MPP Vector Supers
 - Fujitsu VPP series

Designs scale to 100s or 1000s of nodes




Βασική οργάνωση

- Επικοινωνία επεξεργαστών μέσω ανταλλαγής μηνυμάτων, επάνω από το δίκτυο διασύνδεσης
- Ο διαδρομητής (router) συνδέει τον κόμβο με το δίκτυο
 - Κανάλια από προς γείτονες / τοπική μνήμη



Τυπική δομή διαδρομητή



Πολυϋπολογιστές

- Λόγω του ότι κάθε κόμβος είναι ουσιαστικά ένας (σχεδόν) ολοκληρωμένος και αυτόνομος υπολογιστής, οι ΠΚΜ είναι γνωστοί και ως *πολυϋπολογιστές* (multicomputers)
- Η οργάνωση μοιάζει με δίκτυο υπολογιστών
 - Διαφορές:
 - ταχύτητα
 - τοπολογία
 - λειτουργικό σύστημα
 - ...

Ένα δίκτυο διασύνδεσης χαρακτηρίζεται από:

- Την *τοπολογία* του
 - Ποίος κόμβος συνδέεται με ποιον – χωρική διάταξη
- Τη *διαδρομή*σή του (routing)
 - Ποιο από όλα τα δυνατά μονοπάτια θα επιλεγθεί για την επικοινωνία
 - Πολλές επιλογές πολιτικών
- Τον *έλεγχο ροής* του (flow control)
 - Πώς διανέμονται οι πόροι του δικτύου (κανάλια, buffers κλπ), τι συμβαίνει σε περίπτωση συγκρούσεων
 - Αρχιτεκτονική του διαδρομητή
- Τη *μεταγωγή* του (switching)
 - Πώς μεταφέρεται εσωτερικά σε έναν διαδρομητή το μήνυμα από μία είσοδο σε μία έξοδό του
 - Κυκλώματος (circuit switching)
 - Πακέτου / μηνύματος / SAF (Store-and-Forward)
 - Virtual Cut-Through (VCT)
 - Wormhole, ...

MYE023

MYE023


MYE023

Η τοπολογία του δικτύου διασύνδεσης

Τοπολογία


- Διάταξη των κόμβων στον χώρο και συνδεσμολογία μεταξύ τους
- Γράφοι ως φυσική αναπαράσταση του δικτύου
 - κόμβοι = κορυφές
 - συνδέσεις = ακμές
- Αναδρομή στην ορολογία και τις ιδιότητες των γράφων

Ορολογία και ιδιότητες των γράφων



- Σύνολο κορυφών και σύνολο ακμών: $G = (V, E)$
 - μη κατευθυνόμενοι
- Αν $e = vu \in E$, τότε οι v, u είναι γειτονικές (*neighbors, adjacent*)
- Η ακμή είναι προσκείμενη (*incident*) στις κορυφές
- Αν η v έχει $\beta(v)$ γείτονες, τότε έχει βαθμό $\beta(v)$
- Αν όλες οι κορυφές έχουν τον ίδιο βαθμό β , τότε β -regular (τακτικός)
- $\Delta(G), \delta(G)$: μέγιστος, ελάχιστος βαθμός


Ορολογία και ιδιότητες των γράφων



- *Περίπατος (walk)*
 - ακολουθία γειτονικών κορυφών (π.χ. από v1 στη v4: $v_1, v_2, v_3, v_2, v_1, v_4$)
- *ίχνος (trail)*
 - περίπατος χωρίς επαναλαμβανόμενες ακμές (π.χ. v_1, v_2, v_3, v_1, v_4)
- *μονοπάτι (path)*
 - ίχνος χωρίς επαναλαμβανόμενες κορυφές (π.χ. v_1, v_2, v_3, v_4)
- Συνδεδεμένοι γράφοι
- Κύκλος, *Hamiltonicity*

Αποστάσεις



- Μήκος μονοπατιού
 - ο αριθμός ακμών που περιέχει



- Απόσταση $\text{dist}(v,u)$
 - το μικρότερο μήκος από όλα τα μονοπάτια $v-u$.
- Κορυφή u εκκεντρική ως προς την v : $\text{dist}(v,u) = \max_w \{v, w\}$
 - οπότε εκκεντρικότητα $e(v) = \text{dist}(v,u)$
- Διάμετρος = η μεγαλύτερη εκκεντρικότητα, $D(G)$ (diameter)
- Ακτίνα = η μικρότερη εκκεντρικότητα, $R(G)$ (radius)

Δέντρα

- Δέντρα (trees)
 - όχι κύκλοι
 - μοναδικά μονοπάτια
 - συνδεδεμένα, n κόμβοι, $n-1$ ακμές



Άλλα χαρακτηριστικά των γράφων

- *vertex-disjoint paths* (ξένα ως προς τις κορυφές)
- *edge-disjoint paths* (ξένα ως προς τις ακμές)
- *vertex connectivity*, $\kappa(G)$ (συνδεσμικότητα κορυφών)
- *edge connectivity*, $\lambda(G)$ (συνδεσμικότητα ακμών)

$$\kappa(G) \leq \lambda(G) \leq \delta(G)$$

- Και πολλά άλλα

Τι θέλουμε από έναν δίκτυο διασύνδεσης ...


- Το δίκτυο διασύνδεσης θα πρέπει να μεταφέρει *όσο το δυνατόν περισσότερα μηνύματα, όσο το δυνατόν γρηγορότερα με ελάχιστο κόστος και μέγιστη αξιοπιστία*. Αυτά είναι αλληλοσυγκρουόμενα, όμως.

Τοπολογία:

- Μικρή διάμετρος, μικρή μέση απόσταση
μικρή καθυστέρηση σε packet-switching, μικρή contention σε wormhole switching
- Μικρός και σταθερός βαθμός
απλοί και οικονομικοί routers, μικρότερη και σταθερή καλωδίωση, χαμηλότερη connectivity, μεγαλύτερες αποστάσεις
- Υψηλό connectivity
- Συμμετρία
- Εύκολη **ενσωμάτωση** άλλων γράφων και σε άλλους γράφους


- Διότι αν ένα δίκτυο A εμπεριέχεται σε ένα άλλο B, τότε το δεύτερο θα έχει, εκτός των άλλων, και τις ιδιότητες του πρώτου
- Διότι πολλές φορές έχουμε σχεδιάσει έναν αλγόριθμο για ένα δίκτυο A (π.χ. υπάρχουν εξαιρετικοί αλγόριθμοι πολλαπλασιασμού πινάκων για tori) αλλά η παράλληλη μηχανή μας διαθέτει διασυνδεδετικό δίκτυο B (π.χ. ο helios.cc.uoi.gr ήταν υπερκύβος).

Βασικοί γράφοι: Πλήρης γράφος (complete graph)





- Όλες οι κορυφές συνδέονται με όλες
- Ο K_N έχει N κορυφές
- $N(N-1)/2$ ακμές
- $(N-1)$ -regular
- $D(K_N) = 1$
- $\kappa(K_N) = N-1$
- Εμπεριέχει όλους τους γράφους με $\leq N$ κορυφές
- Πρακτικός μόνο για μικρό N

Βασικοί γράφοι: Γραμμικός γράφος (linear array)




- Απλό μονοπάτι
- Ο P_N έχει N κορυφές
- $N-1$ ακμές
- Μη τακτικός (βαθμοί 1 και 2)
- $D(P_N) = N-1$
- $\kappa(P_N) = 1$
- Μη πρακτικός – μόνο για εξειδικευμένες αρχιτεκτονικές (π.χ. συστολικές διατάξεις)

Βασικοί γράφοι: Δακτύλιος (ring)



- Απλός κύκλος
- Ο R_N έχει N κορυφές
- N ακμές
- 2-regular, συμμετρικός
- $D(R_N) = \text{floor}(N/2)$
- $\kappa(R_N) = 2$



- Μεγάλη διάμετρος, πολύ βασικός γράφος για κατασκευή άλλων τοπολογιών

Σχεδιασμός με βάση κριτήρια

- Συνήθως θέλουμε να βρούμε κάποιο δίκτυο που πληροί κάποια κριτήρια, π.χ. να έχει συγκεκριμένο βαθμό ή συγκεκριμένη διάμετρο με συγκεκριμένο # κόμβων / ακμών
- Θέλουμε ένα μεθοδικό τρόπο να παράγουμε τέτοια δίκτυα (π.χ. ξεκινώντας από πιο απλά δίκτυα)
- Μερικές βασικές τεχνικές
 - Γράφοι ακμών
 - Καρτεσιανό γινόμενο
 - Η μέθοδος Cayley

MYE023
MYE023
MYE023

Καρτεσιανό γινόμενο

Καρτεσιανό γινόμενο 2 γράφων

- Ορισμός:

$$G = (V, E) = G_1 \times G_2$$

- Ο G_1 (G_2) ονομάζεται 1^η (2^η) **διάσταση** (*dimension*)

$$V = \{(v_1, v_2)\}$$

- Οι κορυφές είναι το καρτεσιανό γινόμενο των κορυφών των επιμέρους γράφων και άρα έχουν ως ετικέτα/διεύθυνση ένα ζεύγος.

- Το πρώτο 1^ο (2^ο) στοιχείο του ζεύγους ονομάζεται 1^η (2^η) **συντεταγμένη** (*coordinate*)



$$E = \{(v_1, v_2)(u_1, u_2) \mid v_1 = u_1 \text{ and } v_2 u_2 \in E_2 \text{ OR } v_2 = u_2 \text{ and } v_1 u_1 \in E_1\}$$

- Δύο κορυφές στον G γειτονεύουν μόνο αν έχουν στη μία διάσταση έχουν ίδια συντεταγμένη ενώ στην άλλη έχουν γειτονικές συντεταγμένες.



Παραδείγματα

$$E = \{(v_1, v_2)(u_1, u_2) \mid v_1 = u_1 \text{ and } v_2 u_2 \in E_2 \text{ OR } v_2 = u_2 \text{ and } v_1 u_1 \in E_1\}$$



Γενίκευση σε k διαστάσεις

$$G_i = (V_i, E_i), \quad i = 1, 2, \dots, k$$

$$G = (V, E) = G_1 \times G_2 \times \dots \times G_k = (G_1 \times G_2 \times \dots \times G_{k-1}) \times G_k = G' \times G_k$$

$$V = V_1 \times V_2 \times \dots \times V_k = \{(v_1, v_2, \dots, v_k) | v_i \in V_i\}$$

$$E = \{(v_1, v_2, \dots, v_k)(u_1, u_2, \dots, u_k) | \exists j: v_j u_j \in E_j \text{ and } \forall i \neq j: v_i = u_i\}$$

- Δύο κορυφές είναι γειτονικές αν και μόνο αν έχουν τις αντίστοιχες συντεταγμένες τους ίσες, εκτός από μία και στη συγκεκριμένη διάσταση οι συντεταγμένες τους είναι γειτονικές ($v_j u_j \in E(G_j)$)

Μερικές ιδιότητες

$$G_1 \times G_2 = G_2 \times G_1$$

$$|V| = |V_1| \times |V_2|$$

$$v = (v_1, v_2)$$

$$\beta(v) = \beta(v_1) + \beta(v_2)$$

$$\text{dist}(v, u) = \text{dist}_1(v_1, u_1) + \text{dist}_2(v_2, u_2)$$

$$e(v) = e_1(v_1) + e_2(v_2)$$

$$D(G) = D(G_1) + D(G_2)$$

Για k διαστάσεις:

$$|V| = |V_1| \times |V_2| \times \cdots \times |V_k|$$

$$v = (v_1, v_2, \dots, v_k)$$

$$\beta(v) = \sum_{i=1}^k \beta(v_i)$$



$$\text{dist}(v, u) = \sum_{i=1}^k \text{dist}_i(v_i, u_i)$$

$$e(v) = \sum_{i=1}^k e_i(v_i)$$


$$D(G) = \sum_{i=1}^k D(G_i)$$

Γνωστά δίκτυα ως καρτεσιανά γινόμενα: Πλέγματα

- Πλέγματα: γινόμενα γραμμικών γράφων



2D πλέγμα $M \times M$





3D πλέγμα $4 \times 3 \times 2$

- Σε τετραγωνικό πλέγμα 2D, $N = M \times M$:
 - Βαθμός: 2 (γωνίες), 3 (ακμές), 4 (όλοι οι άλλοι κόμβοι)
 - Διάμετρος: $2(M-1) \approx 2(N)^{1/2}$
- Σε τετραγωνικό πλέγμα 3D, $N = M \times M \times M$:
 - Βαθμός: 3 (γωνίες), 4 (ακμές), 5 (πλευρές), 6 (όλοι οι άλλοι κόμβοι)
 - Διάμετρος: $3(M-1) \approx 3(N)^{1/3}$

Γνωστά δίκτυα ως καρτεσιανά γινόμενα: Tori

- Tori: γινόμενα δακτυλίων




- Σε τετραγωνικό torus 2D, $N = M \times M$:
 - Τακτικός, συμμετρικός γράφος, βαθμός: 4
 - Διάμετρος: $2 \times \text{floor}(M/2) \approx N^{1/2}$


Γνωστά δίκτυα ως καρτεσιανά γινόμενα: Υπερκύβοι

- Καρτεσιανό γινόμενο από γράφους 2 κόμβων


– $K_2 = L_2 = R_2 = \text{whatever}_2$ 



μονοδιάστατος κύβος – Q_1



διδιάστατος κύβος – Q_2





τριδιάστατος κύβος – Q_3

Υπερκύβος: κι άλλοι ορισμοί

- Καρτεσιανό γινόμενο από $P_2, R_2, K_2 \dots$ 
- Επίσης, είναι ιεραρχικά αναδρομικός (καρτεσιανό γινόμενο από μικρότερους κύβους)


$$Q_1 = K_2, \quad Q_d = Q_{d-1} \times Q_1 = Q_k \times Q_{d-k}$$

- Ισοδύναμος ορισμός, ενίοτε βολικότερος:
 - $N = 2^d$ κόμβοι με ετικέτες d -ψήφιους δυαδικούς αριθμούς.
 - Δύο κόμβοι γειτνιάζουν αν και μόνο αν οι ετικέτες τους διαφέρουν σε 1 bit.




Κατασκευή με βάση τον τελευταίο ορισμό


- Δύο ίδια αντίγραφα του αμέσως μικρότερου κύβου
- Συνδέω τις κορυφές με ίδια ετικέτα
- Στον πρώτο βάζω το 0 μπροστά από κάθε ετικέτα, στο δεύτερο βάζω το 1.



Διδιάστατος κύβος (Q_2)



Κατασκευή από δύο διδιάστατους κύβους



τετραδιάστατος κύβος - Q_4

Μερικές ιδιότητες

- Τακτικός, βαθμού d ($= \log_2 N$)
- Διάμετρος $D(Q_d) = d$
- Hamiltonian, vertex symmetric, edge symmetric
- Βέλτιστη συνδεσμικότητα (d) (τόσα παράλληλα μονοπάτια)
- Γενικώς, βέλτιστες είναι πάρα πολλές από τις ιδιότητές του, βέλτιστα συμπεριφέρονται πάρα πολλοί αλγόριθμοι.
 - Γι' αυτό και ήταν από τα δημοφιλέστερα / πιο μελετημένα δίκτυα
- Σημαντικότερα μειονεκτήματα:
 - Καλή, αλλά όχι και τέλεια διάμετρος, αλλά κυρίως:
 - Μεγάλος, μη σταθερός βαθμός
 - Γι' αυτό και (σε συνδυασμό με άλλες εξελίξεις) υπερσκελίστηκε από άλλα δίκτυα χαμηλού και σταθερού βαθμού (π.χ. πλέγματα).

Συγκριτικός πίνακας

	Κόμβοι	Βαθμός	Διάμετρος	Παραδείγματα συστημάτων
Πλήρης γράφος	N	$N - 1$	1	
Γραμμ. γράφος	N	1, 2	$N - 1$	
Δακτύλιος	N	2	$\lfloor N/2 \rfloor$	Sequent Symmetry, Intel Xeon Phi
Πλέγμα 2D	$N = M \times M$	2, 3, 4	$2M - 2 \approx 2\sqrt{N}$	Intel Paragon Adapt. Epiphany
Πλέγμα 3D	$N = M \times M \times M$	2, 3, ..., 6	$3M - 3 \approx 3\sqrt[3]{N}$	MIT J Machine, Sandia Red Storm
Torus 2D	$N = M \times M$	4	$2\lfloor M/2 \rfloor \approx \sqrt{N}$	Cray X1E
Torus 3D	$N = M \times M \times M$	6	$3\lfloor M/2 \rfloor \approx \sqrt[3]{N}$	Cray XT3/4/5/6 Cray XE6
Υπερκύβος	$N = 2^d$	$d = \log_2 N$	$d = \log_2 N$	Intel ipsc-1/2, nCUBE-1/2/3, SGI Origin

MYE023

MYE023

MYE023


Αντιστοιχίσεις/ενσωματώσεις

(embeddings)

Ενσωμάτωση δακτυλίου σε ισομεγέθη γραμμικό γράφο




1^{ος} τρόπος



Η ακμή 0-5 στον δακτύλιο
γίνεται μονοπάτι μήκους 5!

2^{ος} τρόπος



Όλες οι ακμές του δακτυλίου
γίνονται το πολύ μονοπάτι
μήκους 2

Με οικοδεσπότη των υπερκύβο

- Ο υπερκύβος μπορεί να προσομοιώσει ιδιαίτερα αποδοτικά σχεδόν όλα τα γνωστά δίκτυα (!)
- Βασική τεχνική για βασικούς φιλοξενούμενους:
 - Binary Reflected Gray Code (BRGC, GC για συντομία)
- $GC_1 = \{0, 1\}$ $GC_d = \{0GC_{d-1}, 1GC_{d-1}^R\}$
- $GC_2 = \{ 0\{0,1\}, 1\{1,0\} \} = \{ 00, 01, 11, 10 \}$
 $GC_3 = \{ 0\{00,01,11,10\}, 1\{10,11,01,00\} \} = \dots$
- Κάθε στοιχείο της ακολουθίας διαφέρει από το προηγούμενο και το επόμενο του σε ακριβώς 1 bit.

Μερικός κώδικας Gray



- Με λιγότερα από 2^d στοιχεία.
- Έστω ότι $GC_{d,\lambda}$ είναι τα πρώτα λ στοιχεία του GC_d
- Τότε, μερικός κώδικας Gray με k στοιχεία, είναι ο:

$$PGC_{d,k} = \{ \mathbf{0}GC_{d-1,k/2}, \mathbf{1}GC_{d-1,k/2}^R \}$$



- Π.χ. έστω ότι θέλουμε τον $PGC_{3,6}$.
 - $GC_2 = \{00, 01, 11, 10\}$, $GC_{2,3} = \{00, 01, 11\}$
 - $PGC_{3,6} = \{ \mathbf{0} \{00, 01, 11\}, \mathbf{1} \{11, 01, 00\} \}$
 $= \{ 000, 001, 011, 111, 101, 100 \}$

Path/Ring embedding

- Αν δακτύλιος με 2^d κόμβους, αντιστοιχίζουμε τον κόμβο i του δακτυλίου στον κόμβο $GC(i)$ του κύβου



- Αν έχει k κόμβους (k άρτιο), τότε αντιστοιχίζουμε τον κόμβο i του δακτυλίου στον κόμβο $PGC(i)$



Κόμβος στον R_6	0	1	2	3	4	5
Κόμβος στον Q_3	000	001	011	111	101	100

Path/Ring embedding

- Γιατί δουλεύει;
 - Διότι γειτονικοί κόμβοι στο δακτύλιο αντιστοιχίζονται σε γειτονικά στοιχεία του GC.
 - Όμως, γειτονικά στοιχεία του GC διαφέρουν σε ακριβώς 1 bit.
 - Επομένως, οι αντίστοιχοι κόμβοι στον υπερκύβο είναι επίσης γειτονικοί.

Mesh / torus embedding


- Είδαμε ότι $Q_d = Q_{d_1} \times Q_{d_2} \times \cdots \times Q_{d_k}$ ($d = d_1 + d_2 + \cdots + d_k$)
- Με χρήση πολλαπλών κωδίκων Gray
- Π.χ. στο κύβο Q_d , $d = d_1 + d_2$, αντιστοιχίζω torus $2^{d_2} \times 2^{d_1}$
- Χρησιμοποιώ 2 κώδικες, GC_{d_1} και GC_{d_2}
- Ο κόμβος (i, j) αντιστοιχίζεται στον $GC_{d_2}(i) || GC_{d_1}(j)$

$$x = (x_a x_{a-1} \cdots x_1)$$

$$y = (y_b y_{b-1} \cdots y_1)$$

$$x || y = (x_a x_{a-1} \cdots x_1 y_b y_{b-1} \cdots y_1)$$

Παράδειγμα





$2 \times 4 = 2^1 \times 2^2$, άρα 2 κώδικες: με 1 και 2 ψηφία

$$G_1 = \{00, 01, 11, 10\}$$

$$G_2 = \{0, 1\}.$$

$(0, 0) \rightarrow \mathbf{000}$	$(0, 1) \rightarrow \mathbf{001}$	$(0, 2) \rightarrow \mathbf{011}$	$(0, 3) \rightarrow \mathbf{010}$
$(1, 0) \rightarrow \mathbf{100}$	$(1, 1) \rightarrow \mathbf{101}$	$(1, 2) \rightarrow \mathbf{111}$	$(1, 3) \rightarrow \mathbf{110}$



MYE023
MYE023
MYE023

Κατηγορίες διαδρόμησης

(routing)

Με βάση τις αποφάσεις διαδρομής (I)

- Πώς και πού παίρνονται οι αποφάσεις
 - Κατανεμημένη (distributed routing)
 - Σε κάθε router καθώς τον διασχίζει το μήνυμα
 - Η επικεφαλίδα έχει μόνο την ταυτότητα του παραλήπτη / προορισμού
 - Κάθε router απλά αποφασίζει σε ποιο κανάλι εξόδου θα προωθήσει το μήνυμα
 - Ιδιαίτερα βολικό σε συμμετρικά δίκτυα (όλοι οι routers χρησιμοποιούν τον ίδιο αλγόριθμο)
 - Πηγής (source routing)
 - Η πηγή αποφασίζει όλο το μονοπάτι και το ενσωματώνει στην επικεφαλίδα του μηνύματος (συνήθως αναφέρεται ποιο κανάλι πρέπει να χρησιμοποιήσει κάθε ενδιάμεσος κόμβος)
 - Κάθε ενδιάμεσος κόμβος μηχανικά το προωθεί στο κανάλι εξόδου που του λέει το μήνυμα και «αφαιρεί» τα bit που αναφέρονται σε αυτόν
 - Αν οι routers έχουν k κανάλια εξόδου και το μονοπάτι είναι μήκους D , θα χρειαστούν $D \log_2 k$ bits για την κωδικοποίηση του μονοπατιού
 - Ακόμα λιγότερα σε δίκτυα καρτεσιανού γινομένου, όπου μπορούμε να σημειώσουμε μόνο την αλλαγή διάστασης (μαζί με τη νέα κατεύθυνση) (street-sign routing)

Με βάση τις αποφάσεις διαδρόμησης (II)

- Υβριδική / πολλαπλών φάσεων (hybrid/multiphase routing)
 - Η πηγή προκαθορίζει μόνο μερικούς ενδιάμεσους κόμβους και όχι όλο το μονοπάτι
 - Από ενδιάμεσο σε ενδιάμεσο κόμβο η διαδρόμηση γίνεται κατανεμημένα
 - Π.χ. το randomized routing του Valiant (1 τυχαίος ενδιάμεσος κόμβος).
- Κεντριοποιημένη (centralized routing)
 - Κάποιος εξωτερικός ελεγκτής παίρνει τις αποφάσεις
 - Έχει χρησιμοποιηθεί σε μηχανήματα SIMD και σε μερικά MINs

Με βάση την υλοποίηση του αλγορίθμου

- Δύο υλοποιήσεις:
 - Αλγοριθμική
 - Είτε σε hardware, είτε σε software υπάρχει κάποιος στοιχειώδης αλγόριθμος για τον σχηματισμό της διαδρομής (π.χ. e-cube, dimension-ordered routing).
 - Είναι αναγκαστικά «δεμένη» με συγκεκριμένη τοπολογία. Αν ο router είναι γενικός, για να φτιαχτεί οποιαδήποτε τοπολογία, η αλγοριθμική διαδρομηση είναι δύσκολη αν όχι αδύνατη.
 - Στην περίπτωση της διαδρομησης πηγής, μόνο η πηγή χρησιμοποιεί τον αλγόριθμο, φυσικά.
 - Με πίνακα
 - Κάθε κόμβος έχει πίνακα με τα κανάλια που πρέπει να χρησιμοποιήσει για κάθε δυνατό προορισμό
 - ▷ Μεγάλο μέγεθος πίνακα = $\Theta(\# \text{ κόμβων})$
 - ▷ Και ανάλογα αργή η αναζήτηση σε αυτόν
 - Interval routing: για μείωση του πίνακα, κρατάμε ένα διάστημα διευθύνσεων ανά κανάλι εξόδου (δηλ. 2 αριθμούς)
 - ▷ Ανοιχτό πρόβλημα για τις περισσότερες τοπολογίες
 - Στην περίπτωση της διαδρομησης πηγής, μόνο η πηγή χρειάζεται πίνακα, φυσικά.

Με βάση την προσαρμοστικότητα του αλγορίθμου

- Δηλαδή, αν χρησιμοποιείται κι άλλη πληροφορία εκτός της διεύθυνσης του προορισμού
 - Σταθερή (απροσάρμοστη 😊) διαδρομή (deterministic)
 - Διαλέγει πάντα το ίδιο μονοπάτι μεταξύ δύο κόμβων (συνήθως κάποιο ελάχιστο).
 - Απλή, γρήγορη, η πιο συνηθισμένη στην πράξη
 - Καλή για ομοιόμορφη κίνηση και για αξιόπιστα δίκτυα, αλλιώς όχι
 - «Τυφλή» (oblivious)
 - Χρησιμοποιεί για τις αποφάσεις της μόνο τη δ/νση προορισμού
 - Περιλαμβάνει τη σταθερή διαδρομή
 - Όμως μπορεί να ΜΗΝ είναι σταθερή, αλλά τυχαία.
 - Πολλά εναλλακτικά μονοπάτια και αποφασίζει ποιο από όλα κάθε φορά
 - Καλή εναλλακτική τεχνική αντί της προσαρμοζόμενης, για ομοιόμορφη κατανομή της κίνησης στο δίκτυο

Με βάση την προσαρμοστικότητα του αλγορίθμου (II)

– Προσαρμοζόμενη (adaptive)

- Χρησιμοποιεί και πληροφορία από την κίνηση του δικτύου και την κατάσταση των καναλιών για να αποφασίσει τον επόμενο κόμβο προκειμένου να αποφύγει είτε την μεγάλη κίνηση είτε ελαττωματικούς κόμβους
- Είναι βασικά κατανεμημένα (δεν έχει πολύ νόημα για την περίπτωση της διαδρόμησης πηγής)
- Αποτελείται από δύο λειτουργίες:
 - ▶ Routing function: επιστρέφει σύνολο πιθανών καναλιών εξόδου
 - ▶ Selection function: επιλέγει ένα από όλα τα κανάλια
- Θεωρητικά έχει τις προϋποθέσεις για την καλύτερη δυνατή διαδρόμηση
- Θέλει προσοχή να αποφεύγονται deadlocks και άλλες συναφείς, καταστροφικές καταστάσεις
- Προφανώς απαιτεί πιο πολύπλοκο hardware

Με βάση το μήκος των μονοπατιών

- Πλησιάζουμε τον προορισμό;
 - Ελάχιστη ή άπληστη (*minimal / greedy / profitable*)
 - Με κάθε βήμα πλησιάζουμε περισσότερο στον προορισμό.
 - Συνήθως με σταθερές και τυφλές διαδρομές
 - Μη ελάχιστη (*non-minimal, non-greedy, misrouting*)
 - Σε κάποιο βήμα μπορεί να μην ακολουθήσουμε τη συντομότερη πορεία
 - Σχεδόν πάντα σε προσαρμοζόμενες διαδρομές
 - Προκειμένου π.χ. να αποφύγουμε τη συντομότερη διαδρομή λόγω μεγάλης κίνησης
 - Θέλει προσοχή να αποφεύγονται deadlocks και άλλες συναφείς (livelock), καταστροφικές καταστάσεις


Με βάση την πρόοδο της διαδρομής (μόνο adaptive)

- Το μονοπάτι μεγαλώνει;
 - Προοδευτική (*progressive*)
 - Το μονοπάτι μεγαλώνει σε κάθε βήμα (όχι απαραίτητα πλησιάζοντας στον προορισμό)
 - *Backtracking*
 - Το μονοπάτι μπορεί και να μικρύνει κάποια στιγμή
 - Π.χ. αν συναντήσουμε κίνηση γυρνάμε πίσω και ακολουθούμε άλλη πορεία (άρα δεν μπορεί να είναι σταθερή)
 - Δύσκολη (έως αδύνατη) σε wormhole, εύκολη σε circuit switching

Παράδειγμα: διαδρόμηση σε υπερκύβο

- Σε υπερκύβο Q_d , απόσταση μεταξύ δύο κόμβων v και u
 - $\text{dist}(v,u) = \# \text{ bits που διαφέρουν τα } v \text{ και } u$
- Αλγόριθμος διαδρόμησης:
 - Γνωρίζουμε ότι οι γειτονικοί κόμβοι διαφέρουν σε ακριβώς 1 bit
 - Σε κάθε βήμα, ο τρέχον κόμβος επιλέγει έναν γείτονά του ώστε να διαφέρει σε ένα bit λιγότερο από αυτά του προορισμού
 - Έτσι με κάθε βήμα «διορθώνεται» και 1 bit, μέχρι να καταλήξουμε τελικά στον προορισμό

- Ελάχιστη;
- Κατανεμημένη;
- Σταθερή;



MYE023

MYE023

MYE023


Μεταγωγή (switching)

Μεταγωγή

- Ενώ ο έλεγχος ροής φυσικού μέσου μεταφέρει bits μεταξύ δύο διαδρομητών, η μεταγωγή (*switching*) ενώνει εσωτερικά σε έναν διαδρομητή το κανάλι εισόδου με το επιλεγμένο κανάλι εξόδου και μεταφέρει δεδομένα.
- Μερικές τεχνικές μεταγωγής:
 - Κυκλώματος (circuit switching)
 - Πακέτου / μηνύματος / SAF (Store-and-Forward)
 - Virtual Cut-Through (VCT)
 - Wormhole
 - Virtual channels
 - Pipelined circuit switching


Μεταγωγή κυκλώματος

- Τρεις φάσεις:
 - σχηματισμός (και δέσμευση) του μονοπατιού από το probe
 - μεταφορά του μηνύματος
 - αποδέσμευση του μονοπατιού



Μεταγωγή SAF

- Πακέτου / μηνύματος / SAF (Store-and-Forward)
 - Το μήνυμα χωρίζεται σε πακέτα σταθερού μήκους
 - Κάθε πακέτο προωθείται ανεξάρτητα.
 - Οι κόμβοι
 - (α) το λαμβάνουν και το αποθηκεύουν σε buffer και
 - (β) το προωθούν στον επόμενο κόμβο




Μεταγωγή VCT




- Σαν το SAF αλλά:
 - Αν το κανάλι εξόδου είναι ελεύθερο, καθώς λαμβάνονται τα bits της επικεφαλίδας, αποφασίζεται το κανάλι εξόδου και όλο το μήνυμα διοχετεύεται κατευθείαν εκεί (άρα ελάχιστη καθυστέρηση).
 - Αν όχι, buffering όπως στο SAF.
 - Ταχύτητα αν δεν υπάρξει εμπόδιο
 - Όμως, δεν εξαλείφεται η ανάγκη για buffers που έχει και το SAF.

Μεταγωγή wormhole

- Ανάμεσα σε VCT και circuit switching. Το μήνυμα χωρίζεται σε ΠΟΛΥ μικρά πακέτα, τα *flits* (1-4 bytes). Το πρώτο αποτελεί την επικεφαλίδα
- Η επικεφαλίδα προχωρά με VCT αλλά τα υπόλοιπα flits ακολουθούν (και δεσμεύουν) τους προηγούμενους κόμβους, χωρίς κενά, σαν σε pipeline.
- Αν η επικεφαλίδα μπλοκάρει κάπου, τα flits αποθηκεύονται *εκεί που βρίσκονται* (άρα πολύ μικροί buffers απαιτούνται), εμποδίζοντας με τη σειρά τους άλλα flits να περάσουν.




Χρονισμός



Ας υποθέσουμε
ότι ...

- Κάθε πακέτο αποτελείται από **1 flit** επικεφαλίδας και **M flits** δεδομένων
 - Σύνολο: **M+1 flits** για το πλήρες πακέτο
- Το μήνυμα πρέπει να διανύσει μονοπάτι μήκους **D** για να φτάσει στον προορισμό του
- Δεν συναντάει κανένα εμπόδιο (δηλαδή αναμονή λόγω κατειλημμένων καναλιών) στον δρόμο του
- Κανάλια με συχνότητα **B Hz**
- Το κανάλι έχει πλάτος **1 phit** (= #bits που μεταφέρει ταυτόχρονα σε 1 κύκλο)
 - Υποθέτουμε $1 \text{ phit} = 1 \text{ flit}$
 - Δηλαδή χωρητικότητα / ρυθμός μεταφοράς: **B flits / sec.**
 - Χρόνος **μεταφοράς**, για να διασχίσει ένα flit το κανάλι: **$t_w = 1/B \text{ sec.}$**

Χρόνοι



- Για να αποφασιστεί το κανάλι εξόδου (Route & control) σε ενδιάμεσο κόμβο, απαιτείται χρόνος t_r
 - Χρόνος διαδρόμησης
- Για να μεταφερθεί από την είσοδο στην έξοδο σε ένα ενδιάμεσος κόμβος χρειάζεται χρόνος t_m
 - Περιλαμβάνει όλες τις καθυστερήσεις (buffering, πέρασμα από switch κλπ) για να περάσει από κανάλι εισόδου σε κανάλι εξόδου
 - Χρόνος διάσχισης

Ο χρονισμός πιο αναλυτικά

- $T_{\text{circuit switching}} = D(t_w + t_r + t_m) + (M+1)t_w$

Ο χρόνος για να σχηματιστεί το μονοπάτι από το probe

Χρόνος για το ack και για να μεταδοθεί το μήνυμα πάνω στο κύκλωμα

- $T_{\text{SAF}} = D((M+1)t_w + (M+1)t_m + t_r) = D(t_w + t_r + t_m) + DM(t_w + t_m)$

Μεταφορά ολόκληρου του μηνύματος από κόμβο σε κόμβο. Μόνο το 1^ο flit χρησιμοποιείται για διαδρόμηση.

- $T_{\text{VCT}} = T_{\text{WR}} = D(t_w + t_r + t_m) + Mt_w$

Ο χρόνος για να φτάσει το header flit

Τα άλλα flit ακολουθούν από πίσω και καταφθάνουν το ένα μετά το άλλο.

Αν ο χρόνος να διασχισθεί ένας διαδρομητής (t_m) είναι μεγαλύτερος από τον χρόνο μετάδοσης στο κανάλι (t_w), τότε ο όρος πρέπει να είναι Mt_m .


Αν ο διαδρομητής ήταν μόνο input-buffered?

Σύγκριση

- Υπεραπλουστεύοντας, ας υποθέσουμε ότι $t_w \approx t_r \approx t_m = 1$ χρονική μονάδα. Οι εκφράσεις μας απλοποιούνται ως εξής:
 - $T_{\text{circuit switching}} = T_{\text{VCT}} = T_{\text{WR}} = \Theta(D+M)$
 - $T_{\text{SAF}} = \Theta(DM)$
- Αν τα μηνύματα δεν είναι πάρα πολύ μικρά, ($M = O(D)$), τότε
 - $T_{\text{circuit switching}} = T_{\text{VCT}} = T_{\text{WR}} = \Theta(M)$
 - Επομένως οι μεταγωγές κυκλώματος, VCT και wormhole εξαρτώνται σχεδόν αποκλειστικά από το M και άρα είναι **ανεξάρτητες της απόστασης** (*distance insensitive*).
- Όλα αυτά, βέβαια, με την προϋπόθεση ότι δεν υπάρχουν συγκρούσεις / αναμονές στο μονοπάτι του μηνύματος.


Wormhole switching

- Το wormhole switching έχει επικρατήσει διότι
 - Ταχύτητα ακόμα και σε δίκτυα μεγάλης διαμέτρου
 - Ελάχιστο buffering
 - Οπότε γίνεται δυνατή η υλοποίηση routers σε ανεξάρτητο chip και όχι μέσω της μνήμης του κόμβου
 - *High-speed (low latency) routers and networks*
- Σε υψηλή κίνηση είναι ιδιαίτερα επιρρεπές σε deadlocks αφού δεσμεύει πολλούς πόρους (κανάλια) στην πορεία του.



Τεχνική: virtual channels (εικονικά κανάλια)


- Συνήθως οι buffers στα κανάλια είναι ουρές FIFO
 - Επομένως, αν το header flit μπλοκάρει, όλα τα προηγούμενα κανάλια δεσμεύονται (σαν το *circuit switching*)
 - Κανένα άλλο μήνυμα δεν μπορεί να προχωρήσει
- Τεχνική για βελτίωση της κατάστασης: virtual channels
 - Κάθε φυσικό κανάλι «υποδιαιρείται» σε πολλά εικονικά («λογικά») κανάλια.
 - Τα εικονικά κανάλια πολυπλέκονται στο φυσικό κανάλι χρονικά
 - Κάθε εικονικό κανάλι ορίζεται ουσιαστικά από ζεύγος buffers σε δύο γειτονικούς routers



Virtual channels

- Αν πολυπλέκονται χρονικά κ εικονικά κανάλια πάνω σε 1 φυσικό κανάλι B bits/sec, είναι σαν να έχω k διαφορετικά φυσικά κανάλια, το καθένα (B/k) bits/sec, δηλαδή πιο πολλά αλλά πιο αργά κανάλια.
- Αρχικά χρησιμοποιήθηκαν για το πρόβλημα του deadlock
- Όμως, μπορούν να βελτιώσουν και τις επιδόσεις μιας και πλέον το φυσικό κανάλι δεν δεσμεύεται εξ ολοκλήρου από κάποιο μπλοκαρισμένο μήνυμα
- Μπορούν έτσι να προχωρούν μαζί παραπάνω από ένα μηνύματα στο κανάλι

Virtual channels




- Εδώ, αν το A είχε μπλοκάρει στον R_2 , θα περίμενε αναγκαστικά και το B (άρα 2 μηνύματα σε αναμονή, ενώ τώρα κανένα)
- Επίσης, αν το A ήταν τεράστιο, το B θα περίμενε για πολύ ώρα ενώ τώρα όχι.
- Όμως σίγουρα χάνουμε σε ταχύτητα και επίσης αυξάνει και η πολυπλοκότητα του διαδρομητή
- Επομένως καλό είναι να μην είναι πολλά τα virtual channels

MYE023
MYE023
MYE023

Κλιμακώσιμα συστήματα,
υπολογιστικές συστάδες
(clusters)


Ομαδοποιημένοι ή κλιμακώσιμοι πολυεπεξεργαστές

- Clustered ή **scalable** multiprocessors (κλιμακώσιμοι)
- Πολυεπεξεργαστές με οργάνωση κατανεμημένης μνήμης μόνο που:
 - Κάθε κόμβος αποτελείται από ομάδα επεξεργαστών / πυρήνων που μοιράζονται την τοπική μνήμη.
 - Άρα, κάθε ομάδα είναι ένας μικρός συμμετρικός πολυεπεξεργαστής
- Το δίκτυο διασύνδεσης συνδέει τις ομάδες



Παραδείγματα

- **SGI Origin 2000** (και μετέπειτα UV-1000, UV-2000):
 - Κόμβος = 1 πλακέτα με 2 CPUs MIPS και κοινόχρηστη τοπική μνήμη
 - Σύστημα = υπερκύβος που συνδέει πλακέτες-κόμβους
- **Sequent Numa-Q:**
 - Κόμβος = Pentium Quad (4 επεξεργαστές Pentium) με κοινόχρηστη τοπική μνήμη
 - Σύστημα = δακτύλιος μεταξύ των κόμβων



Υπολογιστικές συστάδες (clusters) και πλέγματα (grids)

- Σύνολο από αυτόνομους υπολογιστές (PCs) συνδεδεμένα με ένα δίκτυο μεταξύ τους:
 - Οι συστάδες (*clusters*) είναι συνήθως ομοιογενείς (παρόμοιοι υπολογιστές, με ίδιο λειτουργικό σύστημα) και είναι τοποθετημένοι στον ίδιο χώρο
 - Τα πλέγματα (*grids*) αναφέρονται συνήθως σε ανομοιογενείς συλλογές από υπολογιστές, με διαφορετικά χαρακτηριστικά και λειτουργικά συστήματα, οι οποίοι επίσης μπορεί να είναι εξαπλωμένοι γεωγραφικά σε μεγάλες αποστάσεις.
 - Μιλάμε για clusters αλλά ότι πούμε αντίστοιχα ισχύει και για πλέγματα
- Κάθε κόμβος-PC σε ένα cluster είναι ένας μικρός SMP
 - Π.χ. διαθέτει είτε πολλαπλούς επεξεργαστές είτε – πλέον το συνηθέστερο – έναν πολυπύρρηνο επεξεργαστή
 - Επομένως το όλο σύστημα έχει οργάνωση είναι ομαδοποιημένου πολυεπεξεργαστή.

Υπολογιστικές συστάδες (clusters) και πλέγματα (grids)

- Δίκτυο διασύνδεσης
 - Κάρτα δικτύου = διαδρομητής
 - Από σχετικά αργό αλλά πολύ οικονομικό (π.χ. Gbit Ethernet)
 - Έως πολύ γρήγορο και ακριβό (π.χ. Myrinet, Infiniband)
- Κάθε κόμβος = αυτόνομος υπολογιστής, με δικό του χώρο μνήμης και δικό του λειτουργικό σύστημα (συνήθως Linux)
 - Υπάρχει όμως ενδιάμεσο λογισμικό ώστε να δίνεται η εντύπωση – ψευδαίσθηση ενιαίου συστήματος (SSI – Single System Image), αν χρειάζεται
- Προγραμματίζονται σαν να είναι 1 μηχανή
 - Κυρίως με μεταβίβαση μηνυμάτων

MYE023

MYE023


MYE023

Κατανεμημένη κοινή μνήμη, NUMA


Γιατί;

- Συστήματα κατανεμημένης μνήμης:
 - Αρχιτεκτονική: **κλιμακώσιμη**
 - Προγραμματισμός (MPI): αρκετά **δύσκολος** αλλά και δυνατότητα επιδόσεων
- Συστήματα κοινόχρηστης μνήμης (SMPs):
 - Αρχιτεκτονική: **δύσκολα κλιμακώσιμη**
 - Προγραμματισμός: **οικείος / προσιτός**
- Το ιδεώδες:
 - Κλιμακώσιμες αρχιτεκτονικές που να προγραμματίζονται εύκολα (αλλά μην ξεχνάμε και τις επιδόσεις)
 - Μετά το σειριακό, το πιο εύκολο είναι ο προγραμματισμός κοινής μνήμης (π.χ. OpenMP)
- Λύση: «*emulation*» της κοινόχρηστης μνήμης πάνω από το σύνολο των ιδιωτικών μνημών
 - με hardware
 - με software (π.χ. σε clusters όπου είναι αδύνατον να αλλάξει το hardware)
 - Άρα λογικά κοινόχρηστη, φυσικά κατανεμημένη μνήμη

Hardware – κόμβος συστήματος




Ανομοιομορφη προσπέλαση μνήμης (NUMA)




- Η CPU προσπελαίνει όλο τον χώρο διευθύνσεων ενιαία
- Η τοπική μνήμη έχει μόνο ένα μικρό κομμάτι του χώρου
- Ο ελεγκτής DSM ελέγχει κάθε διεύθυνση που προσπελαίνει η CPU
 1. Αν είναι για την τοπική μνήμη δεν κάνει τίποτε
 2. Αν όχι, αναλαμβάνει την επικοινωνία με τον κόμβο που την χειρίζεται (**home node**), στέλνοντας κατάλληλο μήνυμα. Μόλις έρθει η απάντηση, δίνει δεδομένα στη CPU σαν να ήταν αποθηκευμένο τοπικά

Ανομοιομορφη προσπέλαση μνήμης (NUMA)



- Το μόνο που καταλαβαίνει η CPU είναι η διαφορά στην ταχύτητα προσπέλασης κάποιων δεδομένων (τα απομακρυσμένα κάνουν πολύ παραπάνω χρόνο να έρθουν)
 - NUMA (non-uniform memory access)
 - Π.χ. Cray T3D: 2 κύκλοι για τα τοπικά και περίπου 150 κύκλοι για τα απομακρυσμένα δεδομένα
 - Συστήματα με 4 επεξεργαστές AMD Opteron 8347HE: περίπου 26% (32%) επιπλέον χρόνος για απομακρυσμένη ανάγνωση (εγγραφή).

Ανομοιομορφη προσπέλαση μνήμης (NUMA)




Ερώτηση: Μείωση χρόνου προσπέλασης???

- Απάντηση: caches για τα απομακρυσμένα δεδομένα
- Όμως, πάλι: πρόβλημα συνοχής για τα κοινά δεδομένα!

Λύσεις:


- Πρωτόκολλα συνοχής => cache-coherent NUMA (ccNUMA)
- Αποφυγή προβλήματος. Π.χ. στον Cray T3D δεν υπήρχε πρωτόκολλο συνοχής. Απλά, στις caches δεν επιτρέπονταν κοινά δεδομένα

Γενίκευση: πολυπύρηνος ή πολυεπεξεργαστι- κός κόμβος



- Διπλό cache coherency:
 - «εξωτερικό» πρωτόκολλο από ελεγκτή DSM για απομακρυσμένα δεδομένα
 - Υποχρεωτικά πρωτόκολλο καταλόγων
 - «εσωτερικό» πρωτόκολλο από caches των CPUs του κόμβου για τα τοπικά
 - Πρωτόκολλο snooping

Παράδειγμα: Sequent Numa-Q



- Το IQ-Link ενσωμάτωνε το ρόλο του διαδρομητή και του ελεγκτή DSM.
- Υλοποιούσε το εξωτερικό πρωτόκολλο
 - SCI (αλυσιδωτοί κατάλογοι)
- Εσωτερικά στην ομάδα, οι Pentium είχαν διατηρούσαν τη συνέπεια με πρωτόκολλο MESI


MYE023
MYE023
MYE023

Κατανεμημένη μνήμη και multicores

Πολυπύρρηνοι επεξεργαστές και κατανεμημένη μνήμη

- Κυρίως δύο περιπτώσεις:
 - Χρήση multicore CPUs ως κόμβων ενός μεγαλύτερου συστήματος
 - Το σύστημα δομείται ως ένα δίκτυο από τέτοιους κόμβους
 - Χρήση multicore CPU ώστε να αποτελεί ολόκληρο το σύστημα
 - Λογικά, μιλάμε για CPU με αρκετούς πυρήνες (ίσως many-core CPU)
- Στην πρώτη περίπτωση ο κάθε επεξεργαστής έχει δικά του κανάλια για να συνδεθεί με τοπική μνήμη + επιπλέον κανάλια για να συνδεθεί με άλλους επεξεργαστές
 - AMD Opterons
 - Intel Xeon (E5, E6 series)
- Στη δεύτερη περίπτωση, μέσα στον ίδιο τον επεξεργαστή περιλαμβάνονται οι πυρήνες, οι ιδιωτικές μνήμες και το δίκτυο διασύνδεσης
 - NoC (Network-on-Chip)
 - MPSoC / MCSoc (Multiprocessor/Multicore System-on-Chip)

Παράδειγμα: AMD Opterons




ISTANBUL (6-πύρηνος)

- 3 κανάλια HT ανά επεξεργαστή
- Μεταγωγή Virtual Cut-Through
- Μπορεί να συνδεθούν 8 κόμβοι με μέγιστη απόσταση 3 hops και να περισσέψουν και κανάλια για I/O
- HT Assist (1MiB στην L3) για υλοποίηση απλού πρωτοκόλλου καταλόγων

MAGNY-COURS (12-πύρηνος)

- 2 Istanbul ενωμένοι
- Μέχρι 4 επεξεργαστές στο σύστημα
- Επομένως μέχρι 48 πυρήνες (χωρίς προσθήκη επιπλέον υλικού)
- NUMA factor:
 - ≈ 1.2 για 1 hop (20% πιο αργή)
 - ≈ 1.5 για 2 hop (50% πιο αργή)

Παράδειγμα: Eriphany-16



- Για εγγραφές, 1.5 κύκλος per hop
 - για εγγραφή σε μνήμη που είναι σε απόσταση $D \Rightarrow 1.5 \times D$ κύκλοι
- Eriphany-64 (δεν κυκλοφοράει στο εμπόριο προς το παρόν):
 - πλέγμα 8×8