Επιστημονικοί Υπολογισμοί - Μέρος ΙΙΙ: Παράλληλοι Υπολογισμοί

Χαρμανδάρης Βαγγέλης, Τμήμα Εφαρμοσμένων Μαθηματικών

Πανεπιστήμιο Κρήτης, Εαρινό Εξάμηνο 2013/14

Κεφάλαιο 3: Θεωρία Παράλληλου Προγραμματισμού - Απόδοση

- **Απόδοση Παράλληλων Προγραμμάτων.**
- **Νόμος Amdahl.**
- **Νόμος Gustafson.**
- **Karp-Flatt metric.**
- **Τεστ Αναφοράς: Linpack.**

Απόδοση Παράλληλου Προγραμματισμού

• Βασικός στόχος του παράλληλου αλγόριθμού είναι η ταχύτερη επίλυση ενός προβλήματος. Ο χρόνος εκτέλεσης του παράλληλου αλγόριθμου πρέπει να είναι πολύ μικρότερος από τον χρόνο εκτέλεσης του σειριακού αλγόριθμου.

• Η απόδοση παράλληλων αλγορίθμων – προγραμμάτων μπορεί να μετρηθεί με εμπειρικούς δείκτες όπως ο λόγος επιτάχυνσης.

Θεωρητικοί νόμοι για διαφορετικούς τύπους προβλημάτων:

• Νόμος του Amdahl

• Νόμος του Gustafson

Απόδοση Παράλληλων Προγραμμάτων

• Η παράλληλη επεξεργασία προϋποθέτει τον καταμερισμό ενός προβλήματος (ή μιας εργασίας) σε μικρότερες διεργασίες που μπορούν να εκτελεστούν ταυτόχρονα (παράλληλα).

• Επιμέριση (Granularity): το μέγεθος της εργασίας (εντολών) κάθε διεργασίας.

• Στόχος είναι η επίτευξη μέσης επιμέρισης:

-- Μικρή επιμέριση: Μικρός φόρτος εργασίας σε κάθε επεξεργαστή, πολύ επικοινωνία.

-- Μεγάλη επιμέριση: Μεγάλος φόρτος εργασίας σε κάθε επεξεργαστή, λίγη επικοινωνία.

• Βασικός στόχος η μεγιστοποίηση του λόγου:

$$\frac{\text{Χρόνος Υπολογισμού}}{\text{Χρόνος Επικοινωνίας}} = \frac{t_{comp}}{t_{comm}}$$

Speedup Factor (Λόγος Επιτάχυνσης)

Λόγος επιτάχυνσης, S, είναι ένα μέτρο της απόδοσης ενός προγράμματος σε ένα παράλληλο υπολογιστικό σύστημα:

$$S(P) = \frac{\text{χρόνος εκτέλεσης σε ένα επεξεργαστή}}{\text{χρόνος εκτέλεσης σε } P \text{ επεξεργαστές}} = \frac{T_s}{T_p}$$

• Απόλυτος λόγος επιτάχυνσης: αν T_s είναι ο χρόνος του καλύτερου σειριακού αλγόριθμου.

• Σχετικός λόγος επιτάχυνσης: αν T_s είναι ο χρόνος του παράλληλου αλγόριθμου σε 1 επεξεργαστή.

• Βέλτιστη επιτάχυνση είναι η γραμμική: $S(P) = P$

• Υπεργραμμική επιτάχυνση ($S(P) > P$): μπορεί να εμφανιστεί σε μικρό αριθμό επεξεργαστών. Οφείλεται:

1) είτε στην διαφορετική χρήση-ιεραρχία εσωτερικής μνήμης στους διαφορετικούς επεξεργαστές (**cache effect**),

2) είτε σε αυτόματη βελτιστοποίηση (optimization) του σειριακού κώδικα από τον compiler.

Speedup Factor (Λόγος Επιτάχυνσης)

• Ο λόγος επιτάχυνσης, είναι ένα απλό και κατανοητό μέτρο απόδοσης.

• Αν ο λόγος επιτάχυνσης είναι μεγάλος ($S(P)$ είναι τάξης P) τότε ο παράλληλος αλγόριθμος είναι καλός.

• Αν ο λόγος επιτάχυνσης είναι μικρός ($S(P) << P$) τότε:

1) είτε το πρόβλημα δεν παραλληλίζεται,
2) είτε ο παράλληλος αλγόριθμος χρειάζεται βελτίωση!

Προσοχή:

• Ο μέγιστος λόγος επιτάχυνσης δεν έχει νόημα αν είναι $<< P$.

• Καθώς ο αριθμός των επεξεργαστών, n, αυξάνεται, το σειριακό κομμάτι του κώδικα αποτελεί ολοένα και μεγαλύτερο τμήμα του συνολικού χρόνου εκτέλεσης (Νόμος του Amdahl).

Νόμος του Amdahl (1967)

• Έστω ότι για μια διεργασία απαιτείται σε ένα επεξεργαστή χρόνος t_S. Έστω ακόμη ότι ένα μέρος (ποσοστό) f της διεργασίας είναι σειριακό ενώ το υπόλοιπο 1-f παραλληλίζεται. Τότε για P επεξεργαστές ο λόγος επιτάχυνσης είναι:

$$S(P) \equiv \frac{T_S}{T_P} = \frac{t_s}{ft_s + \frac{(1-f)t_s}{P}} = \frac{P}{1+(P-1)f}$$

• Το όριο για $P \rightarrow \infty$ (μέγιστη επιτάχυνση) είναι : $S_{\max} = \lim_{P\to\infty} S(P) = \frac{1}{f}$

• **Προσοχή:** ακόμη και αν μόνο το 10% του προβλήματος είναι σειριακό τότε $S_{max} = 10$!

• Μεγάλο κομμάτι της παράλληλης επεξεργασίας αφορά την ελαχιστοποίηση του f.

Νόμος του Amdahl

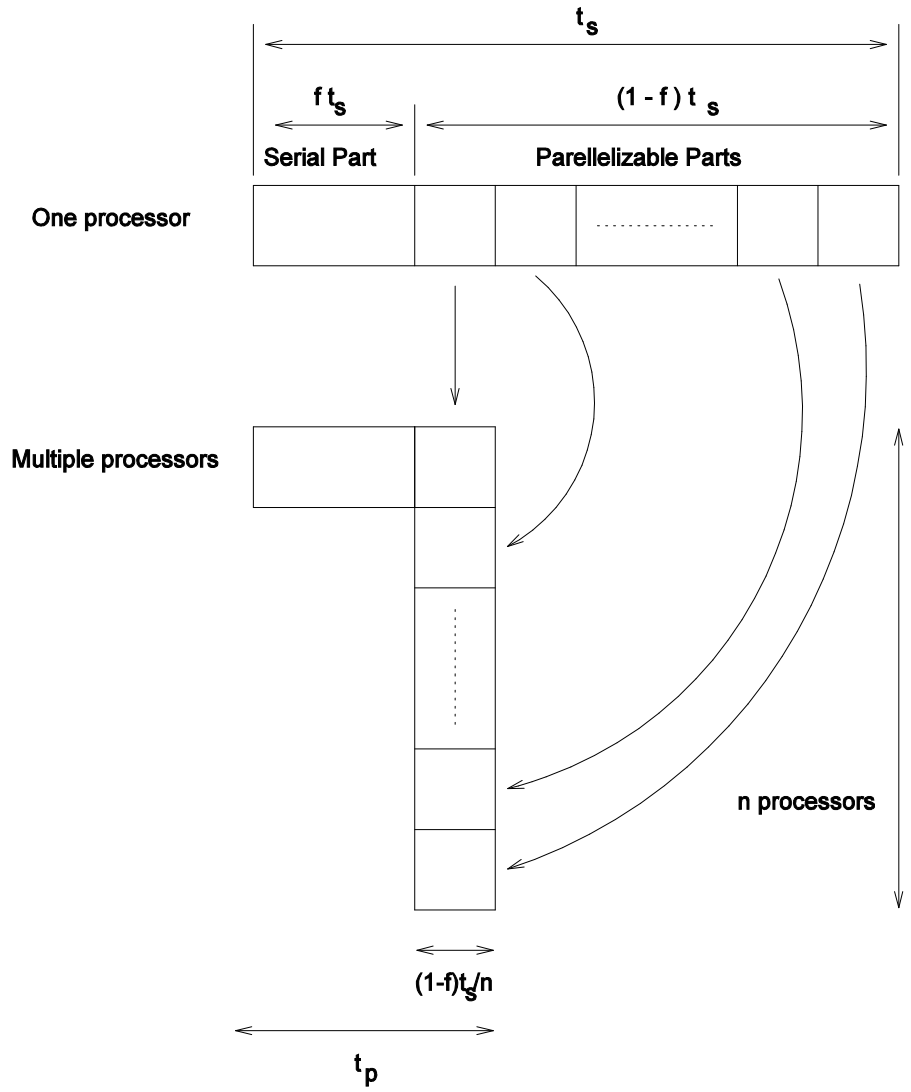

Νόμος του Amdahl

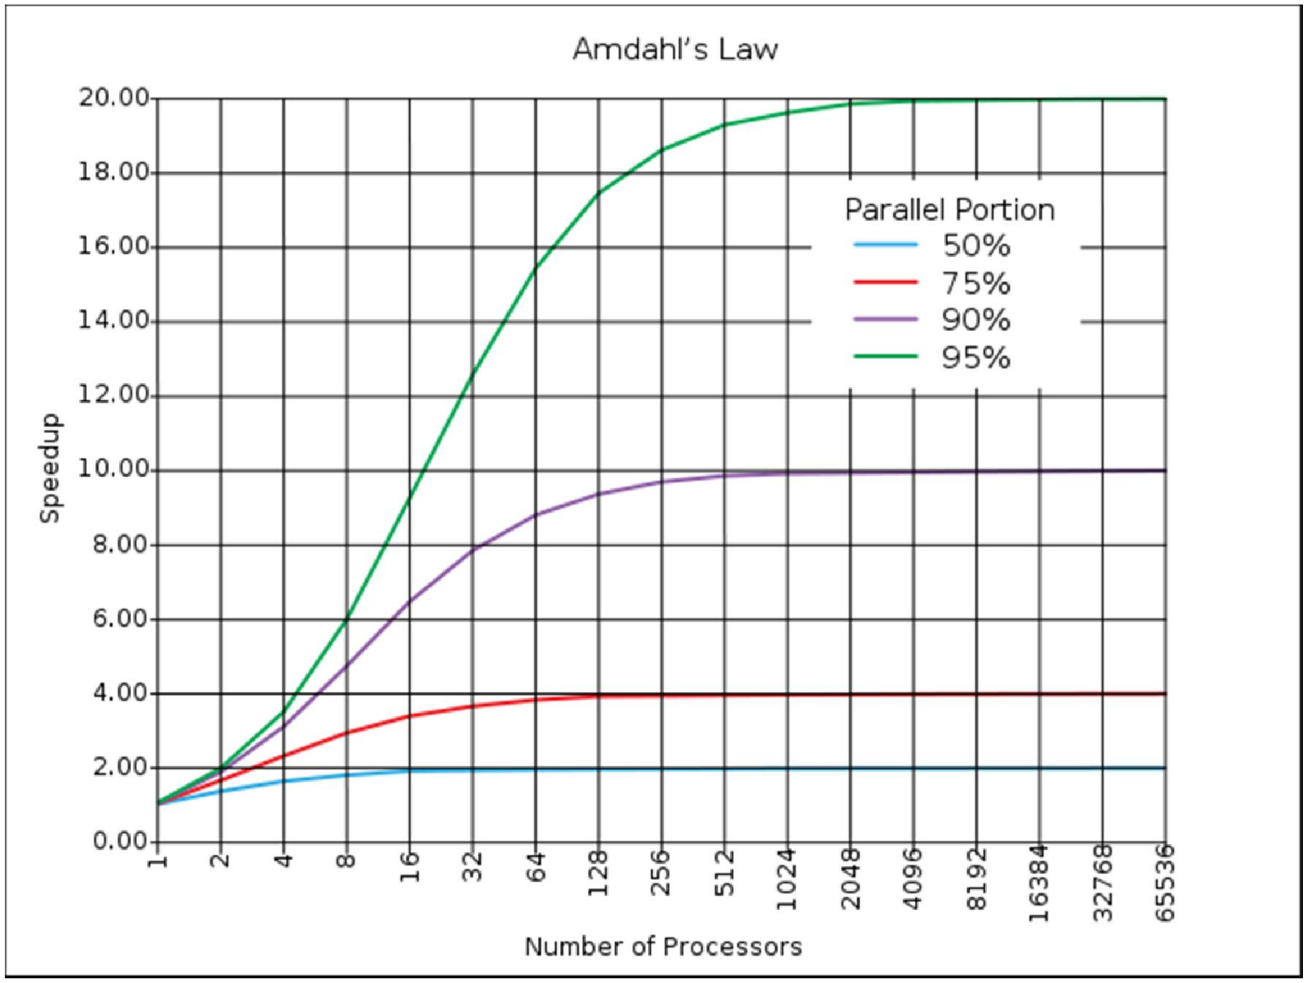

Αποδοτικότητα, Επεκτασιμότητα

Αποδοτικότητα (Efficiency) : $$E(P) = \frac{S(P)}{P} = \frac{T_s}{PT_p}$$

-- Αλγόριθμοι με σχεδόν γραμμική επιτάχυνση: $E \sim 1$

-- Πολλοί δύσκολα παραλληλίσιμοι αλγόριθμοι έχουν: $E \sim 1/\log(P)$, $E \rightarrow 0$ με $P \rightarrow \infty$!

• Επεκτασιμότητα υλικού είναι η δυνατότητα αναβάθμισης των συστημάτων (hardware) με αποτέλεσμα την αύξηση της απόδοσης.

-- Όμως περισσότεροι επεξεργαστές → μεγαλύτερο δίκτυο → αύξηση της επικοινωνίας → πτώση της απόδοσης!

• Επεκτασιμότητα (Scalability) αλγορίθμου είναι η δυνατότητα του λογισμικού (software) να διαχειριστεί μεγαλύτερα προβλήματα και άρα μεγαλύτερο όγκο δεδομένων με σχετικά μικρή αύξηση στο κόστος του αλγόριθμου.

Νόμος του Gustafson (1988)

• Ο νόμος του Amdahl θέτει ένα πάνω όριο στην μέγιστη επιτάχυνση που μπορεί να επιτευχθεί σε ένα πρόγραμμα μέσω παραλληλισμού. Ο λόγος είναι ότι το σειριακό ποσοστό *f* είναι σταθερό.

• Ο νόμος του Gustafson προτείνει ότι ο **χρόνος εκτέλεσης του σειριακού μέρους είναι σταθερός**.

• Έστω *n* το μέτρο μεγέθους (measure) ενός προβλήματος. Έστω ακόμη ότι η εκτέλεση του σε ένα παράλληλο σύστημα με *P* επεξεργαστές μπορεί να γραφεί σαν $f(n) + (1-f(n))=1$, όπου $f(n)$ είναι ο χρόνος εκτέλεσης του σειριακού μέρους του κώδικα και $(1-f(n))$ ο χρόνος εκτέλεσης του παράλληλου μέρους του κώδικα.

• Τότε ο συνολικός χρόνος εκτέλεσης του προγράμματος σε ένα επεξεργαστή είναι: $f(n) + P(1-f(n))$. Ο λόγος επιτάχυνσης είναι:

$$S(P) = f(n) + P(1 - f(n)) = P - f(n)(P - 1)$$

Νόμος του Gustafson (1988)

• Καθώς ο αριθμός των επεξεργαστών αυξάνει, αυξάνει και το παράλληλο τμήμα του κώδικα.

• Υποθέτοντας ότι το σειριακό μέρος $f(n)$ μειώνετε με το μέγεθος του προβλήματος, n, ο λόγος επιτάχυνσης αυξάνει.

• Το όριο για $n \rightarrow \infty$ είναι :

$$S_{\max} = \lim_{n \to \infty} S(P) = P$$

• Πρακτικά ο νόμος του Gustafson θεωρεί ότι η επίδραση του σειριακού μέρους είναι η ίδια ακόμη και για πολύ μεγάλα παράλληλα συστήματα ενώ νόμος του Amdahl ότι επίδραση του σειριακού μέρους αυξάνει όσο μεγαλώνει ο αριθμός των επεξεργαστών!

• Τα περισσότερα ρεαλιστικά-πολύπλοκα προβλήματα ακολουθούν υβριδική συμπεριφορά μεταξύ του νόμου του Gustafson και του νόμου του Amdahl.

Karp-Flatt Metric (1990)

• Η μετρική Karp-Flatt είναι ένας δείκτης παραλληλισμού ενός κώδικα σε παράλληλα συστήματα χρησιμοποιώντας το σειριακό μέρος.

• Έστω ότι ένας παράλληλος κώδικας «τρέχει» σε P επεξεργαστές και ότι T_S είναι ο χρόνος εκτέλεσης του σειριακού μέρους και T_P ο χρόνος εκτέλεσης του παράλληλου μέρους σε ένα επεξεργαστή. Τότε ο συνολικός χρόνος εκτέλεσης του προγράμματος σε P επεξεργαστές, $T(P)$, είναι:

$$T(P) = T_s + \frac{T_P}{P}$$

• Ορίζοντας το «πειραματικό» σειριακό μέρος ως $e = T_s/T(1)$ έχουμε:

$$T(P) = T(1)e + \frac{T(1)(1-e)}{P}$$

Karp-Flatt Metric (1990)

• Χρησιμοποιώντας το λόγος επιτάχυνσης, $S=T(1)/T(P)$, τελικά:

$$\frac{1}{S} = e + \frac{1-e}{P} \Rightarrow e = \frac{\frac{P}{S} - 1}{P - 1}$$

• Η χρήση του «πειραματικού» σειριακού μέρους βοηθάει στο να έχουμε ένα εμπειρικό μέτρο που μπορεί να χρησιμοποιηθεί πρακτικά στη ανάλυση περίπλοκων αλγορίθμων.

• Όσο μικρότερο το *e* τόσο καλύτερος ο παραλληλισμός.

• Για δεδομένο μέγεθος προβλήματος *n* η αποτελεσματικότητα του παράλληλου προγράμματος συνήθως μειώνεται όσο ο αριθμός των επεξεργαστών αυξάνει. Χρησιμοποιώντας την μετρική Karp-Flatt μπορούμε να υπολογίσουμε αν η μείωση της αποτελεσματικότητας οφείλεται στο τύπου του προβλήματος ή στον αλγόριθμο.

Το Τεστ Αναφοράς LINPACK

• Το Τεστ Αναφοράς LINPACK (LINPACK Benchmarks) είναι ένα μέτρο της ταχύτητας εκτέλεσης πράξεων πραγματικών αριθμών ενός υπολογιστικού συστήματος.

• Αποτελείται από μια σειρά χαρακτηριστικών υπο-προγραμμάτων τα οποία λύνουν ένα σύστημα γραμμικών εξισώσεων. Τα προγράμματα είναι γραμμένα σε FORTRAN ή C και ο αλγόριθμος είναι "LU decomposition with partially pivoting".

• Το LINPACK χρησιμοποιεί μία χαρακτηριστική βιβλιοθήκη γραμμικής άλγεβρας (BLAS, Basic Linear Algebra Subprograms) για εκτέλεση βασικών πράξεων πινάκων.

• Ο συνολικός αριθμός πράξεων του αλγόριθμου επίλυσης συστήματος n γραμμικών εξισώσεων είναι: $2/3\ n^3 + n^2 + O(n)$.

• R_∞: η απόδοση του αλγόριθμου σε flops για πολύ μεγάλο πρόβλημα ($n=N_{max}$).

• R_{Peak}: η θεωρητική απόδοση για κάθε σύστημα.

Το Τεστ Αναφοράς LINPACK

• Λίστα επίδοσης στο τεστ LINPACK των καλύτερων υπολογιστικών συστημάτων στον κόσμο (06/2010).

Name	Number of CPU's	R_∞ (Gflops)	N_{max} (Order)	R_{Peak} (Gflops)
Jaguar, Cray XT	224256	1759000	5474272	2331000
Nebulae, , Intel X5650	120640	1271000	2359296	2984300
Roadrunner, IBM Cluster	122400	1042000	2249343	1375776
Kraken XT5, Cray XT	98928	831700	2078999	1028851
Juelich (FZJ), IBM Cluster	294912	825500	4043519	1002700

Βιβλιογραφία

- *Parallel Programming,* B. Wilkinson, M. Allen, Prentice Hall, 2nd Ed. 2005.
- *Parallel Computing: Theory and Practice*, M. J. Quinn, McGraw-Hill, 1994.
- *Scientific Computing: An introduction with Parallel Computing*, G. Golub, J. Ortega, Academic Press, 1993.
- http://en.wikipedia.org/wiki/Parallel_computing
- LINPACK: http://www.netlib.org/linpack/, http://www.top500.org/
- BLAS: http://www.netlib.org/blas/