



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΤΕΧΝΟΛΟΓΙΑΣ ΠΛΕΡΟΦΟΡΙΚΗΣ ΚΑΙ ΥΠΟΛΟΓΙΣΤΩΝ
ΕΡΓΑΣΤΗΡΙΟ ΥΠΟΛΟΓΙΣΤΙΚΩΝ ΣΥΣΤΗΜΑΤΩΝ
<http://www.cs-lab.ece.ntua.gr>

Διπλωματικές Εργασίες
Ακαδημαϊκό έτος 2017-18

1 Ανάλυση της επίδοσης εφαρμογών σε αρχιτεκτονικές με ανομοιόμορφη πρόσβαση μνήμης (Non Uniform Memory Access - NUMA) και υλοποίηση αποτελεσματικής κατανομής και χρονοδρομολόγησης

Ένας από τους τρόπους αύξησης της κλιμακωσιμότητας των υπολογιστικών συστημάτων που έχουν πολλαπλούς επεξεργαστές στο ίδιο σύστημα είναι μέσω των Αρχιτεκτονικών με Ανομοιόμορφη Πρόσβαση Μνήμης ή αλλιώς Non Uniform Memory Access (NUMA) systems. Η NUMA αρχιτεκτονική αποτελεί έναν σχεδιασμό συστήματος μνήμης πολυεπεξεργαστικών υπολογιστικών συστημάτων, στα οποία ο χρόνος πρόσβασης της κύριας μνήμης (RAM) εξαρτάται από την απόσταση της θέσης μνήμης που προσπελαύνει ο επεξεργαστής. Σε μία NUMA αρχιτεκτονική, ένας επεξεργαστής έχει γρηγορότερη πρόσβαση σε μία τοπική μνήμη από ότι σε μία απομακρυσμένη, η οποία όμως είναι τοπική για κάποιον άλλον επεξεργαστή. Στόχος της παρούσας διπλωματικής είναι η μελέτη και η ανάλυση της επίδοσης που προκαλεί η NUMA αρχιτεκτονική κατά την εκτέλεση σύγχρονων εφαρμογών, καθώς επίσης και η αναγνώριση προτύπων και συμπεριφορών και η κατηγοριοποίηση των εφαρμογών σε ευαίσθητες και μη-ευαίσθητες, ως προς την συμπεριφορά τους λόγω της NUMA αρχιτεκτονικής. Επιπλέον, θα υλοποιηθεί εργαλείο και πολιτικές αποτελεσματικής χρονοδρομολόγησης πολλαπλών εφαρμογών, τόσο μέσω της κατάλληλης κατανομής των κόμβων μνήμης (memory node allocation) όσο και μέσω της κατάλληλης επιλογής των υπολογιστικών κόμβων (compute node allocation).

Σχετικά Μαθήματα: Προηγμένα Θέματα Αρχιτεκτονικής Υπολογιστών, Λειτουργικά Συστήματα, Εργαστήριο Λειτουργικών Συστημάτων

Επικοινωνία: Βασίλης Καρακώστας, vkarakos@cs-lab.ece.ntua.gr, 210-772-4133

Κωστής Νίκας, knikas@cs-lab.ece.ntua.gr, 210-772-4159

Γεώργιος Γκούμας, goumas@cs-lab.ece.ntua.gr, 210-772-2402

2 Ανάλυση της επίδοσης εφαρμογών σε ετερογενείς αρχιτεκτονικές ARM big.LITTLE και υλοποίηση εργαλείου αποτελεσματικής χρονοδρομολόγησης

Οι ετερογενείς αρχιτεκτονικές έχουν γίνει ιδιαίτερα δημοφιλείς τα τελευταία χρόνια λόγω της βελτιωμένης ενεργειακής απόδοσης που μπορούν να πετύχουν σε σχέση με κλασσικές ομοιογενείς αρχιτεκτονικές που αποτελούνται από όμοιους επεξεργαστές. Αν και υπάρχουν πολλοί τρόποι υλοποίησης ετερογενών αρχιτεκτονικών, στην παρούσα διπλωματική εργασία θα επικεντρωθούμε σε ετερογενείς αρχιτεκτονικές ίδιου συνόλου εντολών αρχιτεκτονικής (ISA) με διαφορετικούς πυρήνες. Πιο συγκεκριμένα, θα επικεντρωθούμε στην αρχιτεκτονική big.LITTLE της ARM, η οποία συνδυάζει απλούς και ενεργειακά αποδοτικούς επεξεργαστικούς πυρήνες (LITTLE), με περισσότερο εξελιγμένους και γρήγορους αλλά και πιο ενεργειακά κοστοβόρους πυρήνες (big). Στόχος της παρούσας διπλωματικής είναι η μελέτη και η ανάλυση της επίδοσης σύγχρονων εφαρμογών κατά την εκτέλεσή τους σε πυρήνες big/LITTLE, και η υλοποίηση εργαλείου και πολιτικών αποτελεσματικής χρονοδρομολόγησης που στοχεύει την ταυτόχρονη εκτέλεση πολλαπλών εφαρμογών μέσω της κατάλληλης επιλογής εκτέλεσης αυτών σε big/LITTLE πυρήνες.

Σχετικά Μαθήματα: Προηγμένα Θέματα Αρχιτεκτονικής Υπολογιστών, Λειτουργικά Συστήματα, Εργαστήριο Λειτουργικών Συστημάτων

Επικοινωνία: Βασίλης Καρακώστας, vkarakos@cslab.ece.ntua.gr, 210-772-4133

Κωστής Νίκας, knikas@cslab.ece.ntua.gr, 210-772-4159

Γεώργιος Γκούμας, goumas@cslab.ece.ntua.gr, 210-772-2402

3 Μελέτη, μοντελοποίηση και βελτιστοποίηση επίδοσης σε αρχιτεκτονικές ανομοιόμορφης πρόσβασης στη μνήμη (NUMA) μεγάλης κλίμακας

Καθώς τα πολυπύρνα συστήματα γίνονται πιο περίπλοκα με βαθύτερες ιεραρχίες μνήμης, η μοντελοποίηση των δυνατοτήτων και των ορίων της αρχιτεκτονικής καθίσταται ιδιαίτερα χρήσιμη για τη βελτιστοποίηση των εφαρμογών που εκτελούνται σε τέτοια συστήματα. Ένα μοντέλο για αυτό το σκοπό είναι το μοντέλο roofline, που χρησιμοποιείται ευρέως για τη βελτιστοποίηση εφαρμογών (π.χ. Intel Advisor/VTune). Η παρούσα διπλωματική έχει ως στόχο τη μελέτη, την εξαγωγή και την επέκταση του μοντέλου roofline στην αρχιτεκτονική της Numascale, μία NUMA αρχιτεκτονική μεγάλης κλίμακας, όπου πολλαπλοί επεξεργαστές έχουν cache-coherent πρόσβαση σε κοινή μνήμη με ασύμμετρες ταχύτητες. Η συγκεκριμένη αρχιτεκτονική παρέχει ευκολία προγραμματισμού σε μοντέλα κοινού χώρου διευθύνσεων, όπως το OpenMP, αλλά παρουσιάζει προκλήσεις στην επίτευξη υψηλών επιδόσεων, εξαιτίας της κλίμακας του συστήματος και της ανομοιόμορφης πρόσβασης στη μνήμη. Στο πλαίσιο της διπλωματικής, θα μελετηθεί η επίδοση εφαρμογών στην αρχιτεκτονική Numascale και βελτιστοποιήσεις καθοδηγούμενες από το μοντέλο roofline.

Σχετικά Μαθήματα: Συστήματα Παράλληλης Επεξεργασίας, Προηγμένα Θέματα Αρχιτεκτονικής Υπολογιστών

Επικοινωνία: Νικέλα Παπαδοπούλου, nikela@cslab.ece.ntua.gr, 210-772-2495

Κωστής Νίκας, knikas@cslab.ece.ntua.gr, 210-772-4159

4 Τεχνικές μοντελοποίησης, πρόβλεψης και προβολής της επίδοσης παράλληλων εφαρμογών σε υπολογιστικά συστήματα μεγάλης κλίμακας

Η μοντελοποίηση και πρόβλεψη της επίδοσης των παράλληλων εφαρμογών που εκτελούνται σε υπερυπολογιστές είναι κρίσιμη για τη βελτιστοποίηση της επίδοσης των εφαρμογών, τη βελτιστοποίηση της χρήσης των συστημάτων αλλά και για το σχεδιασμό των συστημάτων επόμενης γενιάς. Ένα από τα σημαντικότερα ερωτήματα που καλούνται να απαντήσουν τα διάφορα μοντέλα πρόβλεψης είναι η επίδοση των εφαρμογών σε συστήματα μεγαλύτερης κλίμακας, δηλαδή η προβολή της επίδοσης των εφαρμογών. Το συγκεκριμένο ερώτημα γίνεται επιτακτικό καθώς βρισκόμαστε στη φάση της μετάβασης από την εποχή των επιδόσεων της τάξης των PetaFLOPS στην εποχή των επιδόσεων της τάξης των ExaFLOPS, που συνοδεύεται από σημαντική αύξηση του πλήθους των πυρήνων και των κόμβων των υπερυπολογιστών. Στη βιβλιογραφία έχουν προταθεί πολλές τεχνικές μοντελοποίησης και πρόβλεψης της επίδοσης, που στηρίζονται είτε σε αναλυτικά μοντέλα είτε σε εμπειρική μοντελοποίηση. Επιπλέον, από τις τεχνικές αυτές, ορισμένες έχουν επίγνωση της αρχιτεκτονικής ή/και της εφαρμογής, ενώ άλλες αντιμετωπίζουν με γενικό τρόπο την αρχιτεκτονική ή τις εφαρμογές. Για την εφαρμογή τους, απαιτούν τη συλλογή κάποιας πληροφορίας, στο χρόνο μεταγλώττισης ή στο χρόνο εκτέλεσης, και χρησιμοποιούν ή όχι εργαλεία για την εξαγωγή τέτοιας πληροφορίας, όπως προσομοιωτές (simulators) και εργαλεία συλλογής ίχνους (tracing tools). Η παρούσα διπλωματική έχει δύο μέρη: στο πρώτο μέρος, θα μελετηθεί η σχετική βιβλιογραφία, ώστε να ταξινομηθούν οι διάφορες τεχνικές μοντελοποίησης και πρόβλεψης της επίδοσης. Στο δεύτερο μέρος, θα εξεταστούν πειραματικά οι τεχνικές εκείνες που είναι κατάλληλες για την προβολή της επίδοσης σε συστήματα μεγαλύτερης κλίμακας.

Σχετικά Μαθήματα: Συστήματα Παράλληλης Επεξεργασίας

Επικοινωνία: Νικέλα Παπαδοπούλου, nikela@cslab.ece.ntua.gr, 210-772-2495

Γεώργιος Γκούμας, goumas@cslab.ece.ntua.gr, 210-772-2402

5 Ανάλυση ιστορικών δεδομένων υπερυπολογιστικών συστημάτων

Οι διαχειριστές των σύγχρονων υπερυπολογιστικών συστημάτων έχουν τη δυνατότητα συλλογής σημαντικής πληροφορίας για τη συμπεριφορά των εφαρμογών που εκτελούνται στο σύστημα, τα αιτήματα των χρηστών και την ποιότητα υπηρεσίας που λαμβάνουν, αλλά και τη συνολική κατάσταση του συστήματος. Η συλλογή ιστορικών δεδομένων του συστήματος δίνει δυνατότητες για τη βελτίωση της χρήσης του συστήματος, αφού η επεξεργασία της μπορεί να συμβάλλει στη μείωση του χρόνου αναμονής από την πλευρά των χρηστών, στη βελτίωση των πολιτικών δέσμευσης πόρων και χρονοδρομολόγησης των εργασιών, αλλά και στην ανθεκτικότητα του συστήματος σε σφάλματα. Η παρούσα διπλωματική περιλαμβάνει την ανάλυση δεδομένων που έχουν συλλεχθεί κατά τη λειτουργία του εθνικού υπερυπολογιστικού συστήματος ARIS (<https://hpc.grnet.gr/>) και την εξόρυξη σχέσεων μεταξύ συμβάντων του συστήματος, αιτημάτων των χρηστών και συμπεριφοράς των εφαρμογών, με στόχο τη βελτίωση της λειτουργίας του συστήματος και της ικανοποίησης των χρηστών, καθώς και την ανάπτυξη μίας μεθοδολογίας συστηματικής συλλογής και επεξεργασίας αντίστοιχων δεδομένων σε υπερυπολογιστικά συστήματα.

Σχετικά Μαθήματα: Συστήματα Παράλληλης Επεξεργασίας, Τεχνητά Νευρωνικά Δίκτυα και Μηχανική Μάθηση

Επικοινωνία: Νικέλα Παπαδοπούλου, nikela@cslab.ece.ntua.gr, 210-772-2495

Κωστής Νίκας, knikas@cslab.ece.ntua.gr, 210-772-4159

6 Μελέτη επίδοσης διαφορετικών αλγορίθμων/τεχνικών διαχείρισης μνήμης (memory management techniques)

Η διαχείριση του ελεύθερου χώρου (free space management) αποτελεί θεμελιώδη πτυχή κάθε συστήματος διαχείρισης μνήμης, είτε αυτό αφορά βιβλιοθήκες κατανομής μνήμης επιπέδου χρήστη (malloc), είτε βιβλιοθήκες χρόνου εκτέλεσης λογισμικού (runtime libraries), είτε το ίδιο το λειτουργικό σύστημα (διαχείριση τμημάτων του εικονικού χώρου διευθύνσεων μιας διεργασίας και του φυσικού χώρου μνήμης). Βασικά κριτήρια για την ανάπτυξη/επιλογή αλγορίθμων διαχείρισης ελεύθερου χώρου αποτελούν α) ο χρόνος κατανομής μνήμης (allocation time) β) ο εξωτερικός θρυμματισμός (external fragmentation) και γ) ο εσωτερικός θρυμματισμός (internal fragmentation). Στα πλαίσια αυτής της διπλωματικής θα μελετήσουμε την επίδοση διαφόρων τεχνικών (first fit, best fit, buddy allocation κ.α) για την κατανομή μνήμης μονάδων σταθερού ή μεταβλητού μεγέθους με γνώμονα τα παραπάνω κριτήρια χρησιμοποιώντας έναν απλό προσομοιωτή (υλοποίηση σε C/C++/Python). Στη συνέχεια θα εστιάσουμε στις απαιτήσεις διαχείρισης μνήμης ενός σύγχρονου λειτουργικού συστήματος. Θα μελετήσουμε την επίδοση του buddy allocator του πυρήνα του Linux για σύγχρονες και απαιτητικές σε μνήμη εφαρμογές καθώς ένα σύστημα γηραίνει (aging).

Σχετικά Μαθήματα: Λειτουργικά Συστήματα Υπολογιστών

Επικοινωνία: Χλόη Αλβέρτη, xalverti@cslab.ece.ntua.gr, 210-772-2279

Βασίλης Καρακώστας, vkarakos@cslab.ece.ntua.gr, 210-772-4133

Γεώργιος Γκούμας, goumas@cslab.ece.ntua.gr, 210-772-2402

7 Υλοποίηση και μελέτη επίδοσης εφαρμογών υψηλής έντασης σε ετερογενή συστήματα (CPU , GPU, FPGA) με τη χρήση του προγραμματιστικού μοντέλου OpenCL.

Την τελευταία δεκαετία η αύξηση της πολυπλοκότητας μιας ευρείας κατηγορίας υπολογιστικών εφαρμογών και η κατάρρευση της κλιμάκωσης της ενεργειακής επίδοσης των επεξεργαστών γενικού σκοπού προκάλεσε μια στροφή προς τα ετερογενή υπολογιστικά συστήματα (heterogeneous computing). Η εννορηστρομένη χρήση επεξεργαστών γενικού σκοπού (CPU) και προγραμματιζόμενων επιταχυντών ειδικού σκοπού (HW accelerators) για υπολογιστικές εφαρμογές υψηλής έντασης εφαρμόζεται ήδη σε υπολογιστικά συστήματα κέντρων δεδομένων (data centers), αλλά και σε συστήματα υψηλών επιδόσεων (High Performance Computing -HPC). Στόχος η αύξηση της απόδοσης με όρους επίδοσης (performance) αλλά και κατανάλωσης ισχύος (power efficiency). Οι επαναδιαμορφούμενες αρχιτεκτονικές, γνωστές και με τον αγγλικό όρο FPGAs (Field Programmable Gate Arrays), είναι ένα ισχυρό υπολογιστικό υλικό το οποίο επιτρέπει στους σχεδιαστές τη δημιουργία συστημάτων εξειδικευμένων εφαρμογών (application-specific). Παρά τη μεγάλη ευελιξία και τη συχνή υπεροχή τους σε ενεργειακή κατανάλωση/επίδοση συγκριτικά με τους επεξεργαστές γενικού σκοπού αλλά και με άλλους επιταχυντές (π.χ GPU), ο προγραμματισμός τους με μοντέλα επιπέδου μεταφοράς καταχωρητή (RTL-based programming model) δρούσε ανασταλτικά στην ευρεία χρήση τους. Τα τελευταία χρόνια όμως αναπτύχθηκαν προηγμένα εργαλεία σύνθεσης (HLS) με στόχο την αυτοματοποίηση τη διαδικασίας σχεδίασης, και πρόσφατα άρχισε να υποστηρίζεται/ χρησιμοποιείται το προγραμματιστικό μοντέλο της OpenCL που στοχεύει στον παράλληλο προγραμματισμό ετερογενών συστημάτων (CPU, GPU, FPGA, DSP κ.α) διευκολύνοντας παράλληλα τη φορητότητα μεταξύ διαφορετικών πλατφορμών. Η εξέλιξη αυτή σε συνδυασμό με την εξέλιξη των αρχιτεκτονικών FPGA, καθιστά τις τελευταίες μια ελκυστική τεχνολογία επιταχυντών ευρείας χρήσης. Ανακοινώσεις μεγάλων εταιριών (Intel, IBM, Microsoft) για λύσεις που συνδέουν CPUs και FPGAs είναι στοιχεία που καταδεικνύουν τη στροφή αυτή.

Η παρούσα διπλωματική περιλαμβάνει εξοικείωση με το προγραμματιστικό μοντέλο της OpenCL, υλοποίηση αλγορίθμων υψηλής έντασης σε ετερογενή συστήματα (FPGA και GPU) και εφαρμογή τεχνικών βελτιστοποίησης στηριζόμενων στις ιδιαιτερότητες της κάθε αρχιτεκτονικής. Τέλος περιλαμβάνει τη σύγκριση των διάφορων υλοποιήσεων με όρους επίδοσης και κατανάλωσης ισχύος.

Σχετικά Μαθήματα: Συστήματα Παράλληλης Επεξεργασίας, Ψηφιακά Συστήματα VLSI

Επικοινωνία: Χλόη Αλβέρτη, xalverti@cslab.ece.ntua.gr, 210-772-2279

Νικέλα Παπαδοπούλου, nikela@cslab.ece.ntua.gr, 210-772-2495

Αθηνά Ελαφρού, athena@cslab.ece.ntua.gr, 210-772-2133

Γεώργιος Γκούμας, goumas@cslab.ece.ntua.gr, 210-772-2402

8 Μελέτη και Αξιολόγηση Παράλληλων Δομών Δεδομένων σε Αρχιτεκτονικές με Ανομοιόμορφη Πρόσβαση Μνήμης (NUMA)

Στα συστήματα ανομοιόμορφης πρόσβασης μνήμης (NUMA), ο χρόνος πρόσβασης στη μνήμη εξαρτάται από την τοποθεσία της μνήμης σε σχέση με τον επεξεργαστή. Ένας επεξεργαστής προσπελάει πολύ γρηγορότερα τα δεδομένα που είναι αποθηκευμένα στην τοπική μνήμη από ότι τα δεδομένα που βρίσκονται σε μία απομακρυσμένη. Σύμφωνα με το νόμο του Amdahl σε μία παράλληλη εφαρμογή, και κατ' επέκταση και σε μία παράλληλη δομή δεδομένων, η απόδοση αυξάνεται καθώς αυξάνουμε τον αριθμό των επεξεργαστικών μονάδων (διεργασίες, νήματα). Ωστόσο, η απόδοση παράλληλων εφαρμογών που εκτελούν ταυτόχρονες προσβάσεις σε κοινή μνήμη υποβαθμίζεται σε NUMA αρχιτεκτονικές εξαιτίας των ανομοιόμορφων προσβάσεων των επεξεργαστικών μονάδων στη μνήμη (NUMA effect). Στο πλαίσιο αυτής της διπλωματικής θα μελετήσουμε την επίδραση του NUMA effect σε παράλληλες δομές δεδομένων όπως ουρές, λίστες, δέντρα και θα προσπαθήσουμε να σκιαγραφήσουμε τα χαρακτηριστικά μιας NUMA-aware παράλληλης δομής δεδομένων (NUMA-aware concurrent data structure).

Σχετικά Μαθήματα: Συστήματα Παράλληλης Επεξεργασίας

Σχετική Βιβλιογραφία:

[1] “Black-box Concurrent Data Structures for NUMA Architectures”, Irina Calciu, Siddhartha Sen, Mahesh Balakrishnan, Marcos K. Aguilera

[2] “Asynchronized Concurrency: The Secret to Scaling Concurrent Search Data Structures”, Tudor David, Rachid Guerraoui, Vasileios Trigonakis

[3] “Lock Cohorting: A General Technique for Designing NUMA Locks”, Dave Dice, Nir Shavit

Επικοινωνία: Χριστίνα Γιαννούλα, cgiannoula@cslab.ece.ntua.gr

Δημήτρης Σιακαβάρας, jimsiak@cslab.ece.ntua.gr, 210-772-2459

Γεώργιος Γκούμας, goumas@cslab.ece.ntua.gr, 210-772-2402

9 Δημιουργία βιβλιοθήκης για αυτόματη παραλληλοποίηση δένδρων δυαδικής αναζήτησης με χρήση της τεχνικής RCU-HTM

Οι παράλληλες δομές δεδομένων βρίσκονται στην καρδιά των περισσότερων παράλληλων εφαρμογών και παίζουν πολύ σημαντικό ρόλο στην εκμετάλλευση των σύγχρονων πολυ-πύρηνων επεξεργαστών. Πέρα από την απόδοση, που αποτελεί τον πρωταρχικό στόχο, η προγραμματιστική ευκολία είναι επίσης ένας σημαντικός παράγοντας κατά την υλοποίηση τέτοιων δομών δεδομένων. Το μεγαλύτερο πρόβλημα σε αυτές τις δομές είναι το γεγονός ότι πολλαπλά νήματα εκτέλεσης πρέπει να συντονίσουν τις προσβάσεις τους σε κοινά σημεία της δομής (π.χ., κόμβοι του δέντρου). Υπάρχουν διάφοροι τρόποι συγχρονισμού των πολλαπλών νημάτων, οι πιο διαδεδομένοι είναι τα κλειδώματα (locks), οι

ατομικές εντολές (atomic operations), το Read-Copy-Update (RCU) [1] και η Hardware Transactional Memory (HTM) [2,3]. Το RCU-HTM [4,5] είναι μία τεχνική η οποία συνδυάζει το RCU με το HTM και καταφέρνει να παρέχει αποδοτικά δυαδικά δένδρα αναζήτησης. Σκοπός αυτής της διπλωματικής είναι η δημιουργία μίας βιβλιοθήκης για την αυτόματη μετατροπή κώδικα σειριακών δυαδικών δέντρων σε παράλληλα.

Σχετικά Μαθήματα: Συστήματα Παράλληλης Επεξεργασίας

Σχετική Βιβλιογραφία:

[1] <https://en.wikipedia.org/wiki/Read-copy-update>

[2] https://en.wikipedia.org/wiki/Transactional_memory

[3] http://www.cs.cmu.edu/afs/cs/academic/class/15418-s12/www/lectures/20_transactionalmem.pdf

[4] <http://transact2017.cse.lehigh.edu/siakavaras.pdf>

[5] "RCU-HTM: Combining RCU with HTM to Implement Highly Efficient Concurrent Binary Search Trees" PACT 2017, Dimitrios Siakavaras, Konstantinos Nikas, Georgios Goumas, and Nectarios Koziris

Επικοινωνία: Δημήτρης Σιακαβάρας, jimsiak@cslab.ece.ntua.gr, 210-772-2459

Γεώργιος Γκούμας, goumas@cslab.ece.ntua.gr, 210-772-2402

10 Τεχνικές συμπίεσης Βαθιών Νευρωνικών Δικτύων που προσαρμόζονται στην αρχιτεκτονική του υλικού

Τα Βαθιά Νευρωνικά Δίκτυα (Deep Neural Networks) έχουν εντυπώσει σε διάφορα πεδία της σύγχρονης επιστήμης, όπως η όραση υπολογιστών (computer vision), η επεξεργασία φυσικής γλώσσας (natural language processing) και η αναγνώριση φωνής (speech recognition), λόγω της υψηλής ακρίβειας που μπορούν να επιτύχουν σε εφαρμογές αυτών των πεδίων. Καθώς το μέγεθος των δικτύων συνεχίζει να αυξάνεται προκειμένου να αυξηθεί περαιτέρω η ακρίβεια και να επιλυθούν πιο πολύπλοκα προβλήματα, η ενέργεια που καταναλώνουν και το αποτύπωμα μνήμης τους κλιμακώνονται επίσης. Επί του παρόντος, τα περισσότερα μοντέλα υψηλής ακρίβειας δεν μπορούν να χρησιμοποιηθούν στην πλειονότητα των ενσωματωμένων συστημάτων (embedded/mobile/edge devices) εξαιτίας της περιορισμένης μνήμης και υπολογιστικής δύναμης των συστημάτων αυτών, εμποδίζοντας την ευρεία πρακτική εφαρμογή τους στη βιομηχανία. Έχει αποδειχθεί, ωστόσο, ότι τα Βαθιά Νευρωνικά Δίκτυα εμπεριέχουν εγγενώς πλεονάζουσα πληροφορία στα βάρη τους. Τεχνικές περικοπής (pruning) έχουν προταθεί για να αξιοποιήσουν αυτό το χαρακτηριστικό και να μειώσουν το μέγεθος των μοντέλων, μηδενίζοντας βάρη τα οποία δε θεωρούνται σημαντικά. Οι τεχνικές αυτές, ωστόσο, εισάγουν μη-κανονικότητα στους υπολογισμούς που εμπλέκονται στην εφαρμογή των Βαθιών Νευρωνικών Δικτύων (inference), γεγονός που μπορεί να είναι επιζήμιο για την επίδοση. Για την αντιμετώπιση αυτού του προβλήματος, οι τελευταίες τεχνικές περικοπής που έχουν προταθεί στη βιβλιογραφία προσαρμόζονται στην αρχιτεκτονική του υλικού, λαμβάνοντας υπόψη πληροφορίες σχετικά με το υλικό κατά τη διαδικασία εκπαίδευσης των Βαθιών Νευρωνικών Δικτύων. Στα πλαίσια αυτής της διπλωματικής, θα αξιολογήσουμε τον αντίκτυπο τέτοιων τεχνικών στο μέγεθος του μοντέλου και την επίδοση σε πολλαπλές πλατφόρμες υλικού.

Σχετικά Μαθήματα: Συστήματα Παράλληλης Επεξεργασίας, Τεχνητά Νευρωνικά Δίκτυα και Μηχανική Μάθηση

Επικοινωνία: Αθηνά Ελαφρού, athena@cslab.ece.ntua.gr, 210-772-2133

Γεώργιος Γκούμας, goumas@cslab.ece.ntua.gr, 210-772-2402

11 Κλιμάκωση της τεχνολογίας Blockchain

Η τεχνολογία blockchain, που αρχικά δημιουργήθηκε για να αποτελέσει τη βάση λειτουργίας του δικτύου Bitcoin, λειτουργεί ως ένα κοινόχρηστο δημόσιο λογιστικό βιβλίο στο οποίο εγγράφονται όλες οι επιβεβαιωμένες συναλλαγές – ένα σύνολο συναλλαγών αποτελούν ένα block και το κάθε block αναφέρεται στο προηγούμενό του δημιουργώντας μια αλυσίδα [1]. Η επιβεβαίωση των συναλλαγών γίνεται με καταναμημένο τρόπο δυναμικά από οποιονδήποτε συμμετέχει στο δίκτυο του blockchain και περιλαμβάνει μια μαθηματική απόδειξη εργασίας (Proof-of-Work ή εν συντομία PoW). Η διαφάνεια συναλλαγών, η έλλειψη κεντρικού ελέγχου, η μη αντιστρέψιμη φύση του και η ψευδο-ανωνυμία που προσφέρει έχουν οδηγήσει στην υιοθέτηση της τεχνολογίας blockchain σε πληθώρα εφαρμογών πέρα από το νόμισμα (διαχείριση ψηφιακών περιουσιακών στοιχείων, από τίτλους ιδιοκτησίας και μετοχές μέχρι ταξιδιωτικά μίλια, δημιουργία ψηφιακών ταυτοτήτων που χρησιμοποιούνται σε ψηφιακές υπογραφές, δημιουργία επαληθεύσιμης καταγραφής για κάθε είδους δεδομένο, αρχείο ή διεργασία). Ωστόσο, η τεχνολογία blockchain δεν μπορεί να χρησιμοποιηθεί ως έχει στην πρωτότυπη μορφή της για οποιουδήποτε είδους εφαρμογές, γιατί έχει σημαντικά μειονεκτήματα σε ότι αφορά τη ρυθμαπόδοση (throughput), τον χρόνο απόκρισης (latency) και το μέγεθος του ίδιου του blockchain. Η αδυναμία κλιμάκωσης (scalability) επιτείνει το πρόβλημα [3]. Στόχος της διπλωματικής είναι να αντιμετωπίσει αυτούς τους περιορισμούς του blockchain υιοθετώντας διαφορετικές σχεδιαστικές επιλογές που θα το καταστήσουν καταλληλότερο για τη χρήση του σε εφαρμογές που απαιτούν υψηλό throughput και χαμηλό latency. Οι επιλογές αυτές αφορούν σε:

- αντικατάσταση του υποκείμενου αδόμητου δικτύου P2P στο οποίο βασίζεται η τεχνολογία blockchain με καταναμημένο δίκτυο κατακερματισμού (DHT). Τα DHTs είναι δομημένα P2P δίκτυα τα οποία κατανέμουν δεδομένα και φόρτο δρομολόγησης στους εμπλεκόμενους κόμβους σύμφωνα με συγκεκριμένους, αυστηρούς κανόνες [2].
- αντικατάσταση του PoW με κατάλληλες διαδικασίες επαλήθευσης που θα είναι αποδοτικές αλλά και φειδωλές στη χρησιμοποίηση των πόρων του συστήματος.

Σχετικά Μαθήματα: Καταναμημένα Συστήματα

Σχετική Βιβλιογραφία:

[1] Nakamoto, Satoshi. "Bitcoin: A peer-to-peer electronic cash system." (2008): 28.

[2] Androutsellis-Theotokis, Stephanos, and Diomidis Spinellis. "A survey of peer-to-peer content distribution technologies." ACM computing surveys (CSUR) 36.4 (2004): 335-371.

[3] McConaghy, Trent, et al. "BigchainDB: a scalable blockchain database." white paper, BigChainDB (2016).

Επικοινωνία: Κατερίνα Δόκα, katerina@cslab.ece.ntua.gr, 210-772-1175

12 Ανάλυση των δεδομένων του Bitcoin blockchain για εξαγωγή πληροφορίας

Το bitcoin είναι ένα ψηφιακό νόμισμα που αποκτά όλο και μεγαλύτερη δημοφιλία, κυρίως λόγω του ότι δεν παράγεται και δεν ελέγχεται από καμία συγκεκριμένη τράπεζα ή κυβέρνηση, αλλά "ζει" εντελώς καταναμημένα. Βασίζεται στην τεχνολογία blockchain, που λειτουργεί ως ένα κοινόχρηστο δημόσιο λογιστικό βιβλίο στο οποίο εγγράφονται όλες οι επιβεβαιωμένες συναλλαγές – ένα σύνολο συναλλαγών αποτελούν ένα block και το κάθε block αναφέρεται στο προηγούμενό του δημιουργώντας μια αλυσίδα [1]. Στο bitcoin blockchain επομένως κρύβεται πολύτιμη πληροφορία για συναλλαγές που αξίζει να συγκεντρωθεί και να αναλυθεί συστηματικά. Στην πρωτογενή μορφή τους τα δεδομένα

του blockchain είναι απλές καταγραφές μεταφοράς bitcoins μεταξύ λογαριασμών, που δεν αποκαλύπτουν άμεσα και διαισθητικά πληροφορίες για τον πραγματικό κόσμο. Ωστόσο με κατάλληλη μοντελοποίηση με χρήση θεωρίας γράφων, αποθήκευση, δεικτοδότηση και επεξεργασία των δεδομένων του bitcoin blockchain με μπορούμε να εξάγουμε γνώση που σχετίζεται με τη ροή χρημάτων, να αναγνωρίσουμε μοτίβα συμπεριφοράς χρηστών και να ανιχνεύσουμε πιθανές απάτες. Δεδομένου του μεγάλου όγκου της πληροφορίας και της ταχύτητας με την οποία παράγεται, το σύστημα για την ανάλυση των δεδομένων του bitcoin blockchain θα πρέπει αναπτυχθεί σε κατανεμημένη και κλιμακώσιμη υποδομή.

Σχετικά Μαθήματα: Κατανεμημένα Συστήματα

Σχετική Βιβλιογραφία:

[1] Nakamoto, Satoshi. "Bitcoin: A peer-to-peer electronic cash system." (2008): 28.

[2] Haslhofer, Bernhard, Roman Karl, and Erwin Filtz. "O Bitcoin Where Art Thou? Insight into Large-Scale Transaction Graphs." SEMANTiCS (Posters, Demos, SuCCESS). 2016.

[3] Marcin, Sergio Ivan. "Bitcoin Live: Scalable system for detecting bitcoin network behaviors in real time." (2015).

[4] <https://uncharted.software/assets/louvain-clustering-for-big-data-graph-visual-analytics.pdf>

Επικοινωνία: Κατερίνα Δόκα, katerina@cslab.ece.ntua.gr, 210-772-1175

13 Ανάλυση δεδομένων σε περιβάλλον πολλαπλών μηχανών

Τα τελευταία χρόνια η ανάλυση μεγάλου όγκου δεδομένων έχει γίνει απαραίτητη τόσο στην επιστημονική κοινότητα όσο και στον επιχειρηματικό κόσμο παγκοσμίως ως τρόπος να εξαχθεί αξία από τον τεράστιο όγκο δεδομένων που παράγονται με τέτοιο ραγδαίο ρυθμό. Για την ανάλυση των δεδομένων έχει προταθεί και αναπτυχθεί πλήθος από πλατφόρμες αποθήκευσης και επεξεργασίας, καθεμιά από τις οποίες μπορεί να είναι καλή επιλογή για συγκεκριμένου είδους δεδομένα (π.χ., PostgreSQL για σχεσιακά δεδομένα, Neo4j για δεδομένα γράφων, Hbase για δεδομένα κειμένου, κλπ.) ή συγκεκριμένου είδους επεξεργασία (π.χ., Hadoop MapReduce για μαζική, Spark Streaming για πραγματικού χρόνου, κλπ.). Όταν ένας αναλυτής θέλει να τρέξει μια ροή εργασιών (workflow), έναν γράφο δηλαδή από εργασίες, όπου η έξοδος κάποιας εργασίας είναι είσοδος μιας άλλης, θα πρέπει να αποφασίσει τον κατάλληλο συνδυασμό από πλατφόρμες που θα βελτιστοποιήσει την εκτέλεση της ροής του με βάση διάφορα κριτήρια, όπως χρόνο εκτέλεσης ή κόστος (σε χρησιμοποιούμενους πόρους) [1]. Στην παρούσα διπλωματική θα μελετήσουμε τη βελτιστοποίηση εκτέλεσης ροών εργασιών που σχετίζονται με ανάλυση δεδομένων γράφων (π.χ. ανάλυση στον γράφο συνδέσεων του Facebook ή ανάλυση του γράφου των άρθρων της wikipedia), κατανέμοντας κάθε εργασία του γράφου στην κατάλληλη πλατφόρμα. Οι πλατφόρμες επιλογής είναι η Neo4j [2], Spark GraphX [4], Flink [5] και GraphLab [3].

Σχετικά Μαθήματα: Κατανεμημένα Συστήματα

Σχετική Βιβλιογραφία:

[1] Doka, Katerina, et al. "Ires: Intelligent, multi-engine resource scheduler for big data analytics workflows." Proceedings of the 2015 ACM SIGMOD International Conference on Management of Data. ACM, 2015.

[2] <https://neo4j.com/>

[3] <https://turi.com/>

[4] <https://spark.apache.org/graphx/>

[5] <https://flink.apache.org/>

Επικοινωνία: Κατερίνα Δόκα, katerina@cslab.ece.ntua.gr, 210-772-1175