

**ΠΡΟΣ**

- 1) Όλα τα μέλη ΔΕΠ του Τμήματος Επιστήμης Υπολογιστών
- 2) Τους εκπροσώπους των Μεταπτυχιακών φοιτητών του Τμήματος Επιστήμης Υπολογιστών
- 3) Την Επταμελή Εξεταστική Επιτροπή
- 4) Όλα τα μέλη της Πανεπιστημιακής Κοινότητας

**Πρόσκληση σε Δημόσια Παρουσίαση της Διδακτορικής Διατριβής του**

**κ. Dennis Ralph Bautembach**

**Doctoral Dissertation Defense**

**Mr. Dennis Ralph Bautembach**

Την Τετάρτη, 02/02/2022 και ώρα 15:00 μ.μ. μέσω Τηλεδιάσκεψης (zoom) <https://zoom.us/j/92447661007> και από το κανάλι του Τμήματος στο Youtube, <https://www.youtube.com/channel/UC7uE3QiMTQjkrpByB Gnt6Q/live>, θα γίνει η δημόσια παρουσίαση και υποστήριξη της Διδακτορικής Διατριβής του υποψηφίου διδάκτορα του Τμήματος Επιστήμης Υπολογιστών κ. **Dennis Ralph Bautembach** με θέμα:

**“Simulating Spiking Neural Networks on Multiple GPUs”**  
**“ Προσομοίωση Νευρωνικών Δικτύων Δυναμικών Ενέργειας σε Πολλαπλές Μονάδες Επεξεργασίας Γραφικών”**

#### **ΠΕΡΙΛΗΨΗ**

Τα Νευρωνικά Δίκτυα Δυναμικών Ενέργειας (ΝΔΔΕ) είναι μια κατηγορία Τεχνητών Νευρωνικών Δικτύων (ΤΝΔ) που επιχειρούν να μοντελοποιήσουν, με μεγαλύτερη ακρίβεια, τις διαδικασίες σε βιολογικά νευρωνικά δίκτυα όπως ο (ανθρώπινος) εγκέφαλος. Είναι μια γενίκευση των «συμβατικών» ή «βαθέων» ΤΝΔ. Τα συμβατικά νευρωνικά δίκτυα, είτε είναι συνελικτικά, επαναλαμβανόμενα ή άλλης μορφής, τυπικά είναι διαστρωματωμένα και παράγουν συνεχείς εξόδους, οι οποίες μπορούν να υπολογιστούν μέσω απλών πολλαπλασιασμών μήτρας σε συνδυασμό με μη γραμμικές συναρτήσεις ενεργοποίησης. Αντίθετα, τα ΝΔΔΕ μπορούν να μοιάζουν με αυθαίρετους κατευθυνόμενους γράφους. Αποτελούνται από νευρώνες, που αντιστοιχούν στις κορυφές του γράφου, οι οποίοι συνδέονται μέσω συνάψεων, που αντιστοιχούν στις ακμές του γράφου. Τόσο οι νευρώνες όσο και οι συνάψεις έχουν τη δική τους κατάσταση, που αποτελείται από ποικιλία

χαρακτηριστικών, τα οποία μπορούν να διέπονται από αυθαίρετες δυναμικές. Επιπλέον, οι νευρώνες έχουν ένα σχήμα πυροδότησης με μορφή ακίδας, οπότε ένα σήμα/μήνυμα πρέπει να μεταδοθεί στους γείτονές τους μέσω των εξερχόμενων συνάψεών τους. Η έξοδος ενός ΝΔΔΕ είναι το μοτίβο πυροδότησης του. Μπορούμε αμέσως να δούμε την ομοιότητα αυτής της συμπεριφοράς με τις ηλεκτροχημικές διεργασίες που συμβαίνουν στον εγκέφαλο. Πολλά πλεονεκτήματα μπορούν να προκύψουν από αυτή την ομοιότητα: Ο Maass απέδειξε το 1996 ότι τα ΝΔΔΕ είναι θεμελιωδώς πιο ισχυρά υπολογιστικά από τα συμβατικά ΤΝΔ. Στην πράξη, τα ΝΔΔΕ εξακολουθούν να υστερούν σε σχέση με τα ΤΝΔ, αλλά η έρευνα γύρω από αυτά παραμένει ζωντανή και πολλά υποσχόμενη. Το χάσμα συρρικνώνεται συνεχώς, έτσι ώστε τα ΝΔΔΕ να μπορούν μια μέρα να ανταποκρίνονται στη φήμη τους. Μια πτυχή στην οποία τα ΝΔΔΕ έχουν ήδη ξεπεράσει τα ΤΝΔ είναι η απόδοση ισχύος, ειδικά σε συνδυασμό με νευρομορφικό υλικό. Στην πραγματικότητα, είναι τόσο αποτελεσματικά που η μετατροπή των ΤΝΔ σε ΝΔΔΕ οριοθετεί ένα συγκεκριμένο πεδίο έρευνας. Η καινοτομία των ΝΔΔΕ έχει επίσης μειονεκτήματα. Πολλά λυμένα προβλήματα, όπως η αποτελεσματική εξαγωγή συμπερασμάτων και η εκπαίδευση των ΤΝΔ, πρέπει να επανεξεταστούν για τα ΝΔΔΕ λόγω της δραστικά διαφορετικής φύσης τους. Η διαδικασία εξαγωγής συμπερασμάτων (inference) απαιτεί πλήρη προσομοίωση. Ενώ η εκπαίδευση μέσω μετα-αλγορίθμων όπως ο Αλγόριθμος Οπισθοδιάδοσης (ΑΟ) (Backpropagation) είναι δυνατή (έχουν γίνει αρκετές προσπάθειες προσαρμογής του ΑΟ σε ΝΔΔΕ), τα ΝΔΔΕ προσφέρονται για ένα διαφορετικό είδος εκπαίδευσης: τη νευροπλαστικότητα. Καθώς ένα ΝΔΔΕ προσομοιώνεται, αυτοπροσαρμόζεται συνεχώς, παράγοντας συνεχώς βελτιούμενα αποτελέσματα. Η εκπαίδευση γίνεται εγγενές μέρος του μοντέλου και ο προσομοιωτής γίνεται υπεύθυνος για την οδήγησή του. Αυτός είναι ο λόγος για τον οποίο αφιερώσαμε τη συγκεκριμένη έρευνα στην προσομοίωση, την οποία θεωρούμε ακόμη πιο θεμελιώδες ζήτημα από την εκπαίδευση: Ένας γρήγορος, αποδοτικός από πλευράς πόρων και φιλικός προς το χρήστη προσομοιωτής όχι μόνο επιταχύνει τις υπάρχουσες προσομοιώσεις αλλά και επιταχύνει τη σχεδίαση δικτύου (πρωτότυπο/συντονισμό παραμέτρων, κ.λπ.) και την έρευνα σε άλλους αλγόριθμους, συμπεριλαμβανομένης της εκπαίδευσης, προάγοντας το πεδίο στο σύνολό του. Για το σκοπό αυτό παρουσιάζουμε το Spike, έναν προσομοιωτή ΝΔΔΕ που αναπτύξαμε. Το Spike υπερτερεί όσον αφορά την απόδοση (ταχύτητα, χρόνο ρύθμισης, κατανάλωση μνήμης) και ευκολία χρήσης έναντι των υφιστάμενων προσομοιωτών. Είναι επίσης ο πρώτος προσομοιωτής που κλιμακώνεται γραμμικά σε οκτώ Μονάδες Επεξεργασίας Γραφικών (GPUs). Αυτό επιτυγχάνεται με νέους αλγόριθμους για την δημιουργία των ακίδων και την πλαστικότητα, ένα νέο σχήμα παραλληλοποίησης, καθώς και μία σύγχρονη Διεπαφή Προγραμματισμού Εφαρμογών (Application Programming Interface - API). Η διατριβή αυτή διερευνά αυτά τα ζητήματα και παρουσιάζει την αντιμετώπισή τους σε διάφορα επίπεδα βελτιστοποίησης, ξεκινώντας από κάποιες πρώτες βασικές υλοποιήσεις μέχρι την τελευταία τους εκδοχή η οποία ξεπερνά σε επιδόσεις τις καλύτερες υφιστάμενες τεχνικές.

Επιβλέπων: Καθηγητής, Α. Αργυρός

## ABSTRACT

Spiking neural networks (SNNs) are a class of Artificial Neural Networks (ANNs) that attempt to more accurately model the processes inside biological neural networks such as the (human) brain. They are a generalization of "conventional" or "deep" ANNs. Conventional neural networks (be it convolutional, recurrent, or other networks) are typically layer-based

and produce continuous outputs, which can be computed via simple matrix multiplications interleaved with non-linear activation functions. In contrast, SNNs can resemble arbitrary directed graphs. They consist of neurons, corresponding to the graph's vertices, which are connected via synapses, corresponding to the graph's edges. Both neurons and synapses have their own state, consisting of arbitrary attributes, which can be governed by arbitrary dynamics. In addition, neurons can fire or "spike" in which case a signal/message must be transmitted to their neighbors via their outgoing synapses. A SNN's output is its firing pattern. We can immediately see how this behavior is quite similar to the electro-chemical processes happening in the brain. Several advantages can be derived from this similarity. Maass proved in 1996 that SNNs are fundamentally more powerful computationally than conventional ANNs. In practice, SNNs still lag behind ANNs but research around them remains vivid and promising. The gap is constantly shrinking so that SNNs may one day live up to their reputation. One aspect in which SNNs have already overtaken ANNs is power-efficiency, especially in combination with neuromorphic hardware. In fact, they are so efficient that converting ANNs into SNNs has become its own field of research. SNNs' novelty also bears disadvantages. Many solved problems such as the efficient inference and training of ANNs, have to be re-thought for SNNs due to their drastically different nature. Inference requires full-blown simulation. While training via meta-algorithms such as Backpropagation (BP) is possible (in fact, several attempts to adapt BP to SNNs have been made), SNNs lend themselves to a different kind of training: neuroplasticity. As the SNN is being simulated, it constantly self-adapts, producing ever-improving outputs. Training becomes an inherent part of the model and the simulator becomes responsible for driving it. This is why we have dedicated this research to simulation, which we see as an even more fundamental issue than training: A fast, resource-efficient, and user-friendly simulator not only speeds up existing simulations. It accelerates network design (prototyping/parameter tuning/etc.) and research into other algorithms, including training, advancing the field as a whole. To this effect, we present Spice (/spaik/), a state of the art SNN simulator. Spice is superior in terms of performance (speed, setup time, memory consumption) and ease of use. It is also the first simulator to scale linearly to eight GPUs. This is achieved by novel algorithms for spike delivery and plasticity, a novel parallelization scheme, as well as a unique, modern API. We explore these algorithms and witness their evolution over several optimization levels, from naïve "first" implementations all the way to outperforming the state of the art.

Supervisor: Professor, A. Argyros