

## חורף תשע"ט

שם עברי מקוצר: למידה עמוקה על מאיצים חישוביים

שפת לימוד הקורס: אנגלית.

דרישות קדם: תכן לוגי, מת"מ, הסתברות.

סילבוס בעברית

אלגוריתמי למידה עמוקה משמשים כיום לפתרון בעיות בתחומים רבים ומגוונים, החל ממערכות דלות אנרגיה ובעלות יכולות חישוב נמוכות וכלה ב"מערכות על" המתבססות על מחשבי על. על מנת לאפשר פיתוח מהיר של יישומים בתחום, הוצאו לאחרונה מספר סביבות תוכנה חדשות המבוססות על חומרות ייחודיות המאפשרות ביצוע האלגוריתמים באופן יעיל. בקורס זה נתמקד בקשר בין יעילות האלגוריתמים, איכותם, ואמצעי חומרה/תוכנה מתקדמים. נלמד שיטות תוכנה מאפשרות שימוש במאיצי חומרה, כגון כרטיסים גרפיים (GPU), ונרחיב את הדיון לנושאי המחקר העדכניים בתחום.

נושאי לימוד:

- רקע על אלגוריתמי DNN כגון CNN, RNN, תוך מתן דוגמאות שימוש
- שימוש יעיל בחבילת התוכנה PyTorch המיועדת לתמוך בסביבות למידה
- אלגוריתמי למידה עמודה מתקדמים כגון: Deep Reinforcement Learning, Variational Autoencoders (VAEs)
- יסודות האצת תוכניות בעזרת תכנות מקבילי – CUDA
- אפלקציות של ראייה ממחושבת ועיבוד שפה טבעית בעזרת למידה עמוקה

מקורות:

- Ian Goodfellow and Yoshua Bengio and Aaron Courville "Deep Learning"; MIT Press book
- Nvidia GPUs – The Engine for Deep Learning <https://developer.nvidia.com/deep-learning>
- PyTorch - <http://pytorch.org/>
- Wen-mei W. Hwu, "Programming Massively Parallel Processors", Morgan Kaufmann

תוצאות למידה:

- (1) להבין את העקרונות של פתרון בעיות בעזרת אלגוריתמי למידה עמוקה
- (2) לדעת לתכנת כרטיסים גרפיים בעזרת CUDA.
- (3) לדעת איך להשתמש בחבילות תוכנה PyTorch לבניית DNNs
- (4) ללמד שיטות אופטימיזציה שונות המאפשרות ביצוע יעיל של בעיות למידה על מערכות מחשב מתקדמות
- (5) ביצוע עבודה מחקרית בתחום

הרכב הציון:

40% עבודות בית 60% פרויקט גמר

פרויקט הגמר יוכל להשתלב בנושא המחקר של הסטודנט או להוות בסיס לפרויקט המשך/ עבודה מכינה לקראת הגדרת נושא מחקר

שם הקורס באנגלית

## **Deep Learning on Computation Accelerators**

**The course will be taught in English**

**English syllabus:**

Deep learning is widely used in many market segments ranging from mobile devices to supercomputers. Recently different SW packages as well as special HW accelerators were developed to support deep learning. The course will focus on algorithms, programming languages and new SW/HW interfaces that aim to allow execution of deep learning algorithms in a productive and efficient way.

**Learning Outcomes:**

At the end of the course, the student will

- .1 Understand and be able to apply notions in deep learning
- .2 Know how to program GPUs using CUDA.
- .3 Know how to effectively use PyTorch SW packages
- .4 Know how to optimize SW and HW performance in deep neural network applications
- .5 Perform a small research project using the studied notions and techniques

Grad:

40% Drills and 60% final project

**Detailed syllabus is below :**

Date	WW	Lecture	Tutorial
25.03.18 Last class before Pesah	1	Introduction to ML and Intro to accelerators.	Setup environment , administration and Intro + Final project definition
08.04.18	2	k-NN, linear classifiers, linear regression, loss functions, optimization, descent methods, stochastic gradient descent	Numerical computation in Python: numpy and signal processing (Tensor computing) Intro to PyTorch
15.04.18	3	Neural networks: multi-layered perceptrons, backpropagation and intro to CNNs, ResNets	DNN Architectures: AlexNet, VGG, GoogLeNet, ResNet, etc.
22.04.18	4	Training neural networks: art and science. Activation functions, initialization, dropout, batch normalization, update rules, data augmentation and domain transfer learning	Training convolution neural networks in PyTorch
29.04.18	5	Recurrent neural networks: RNN, B-RNN, LSTM, GRU and applications (	NLP
06.05.18	6	Generative Models, Variational Auto Encoders, Generative Adversarial Networks, (advanced topics – adversarial attacks)	LSTM
13.05.18	7	Reinforcement learning, Deep Q-Learning, Policy Gradients	VAE, GAN training
27.05.18	8	CNNs on irregular data -- graph and manifold data (shapes etc.)	
03.06.18	9	CNNs on irregular data (cont.) Introduction to floating and point arithmetic, HW considerations Quantization of DNNs	RL, actor-critic
10.06.18	10	Data decomposition vs. functional decomposition Elements of parallel computing	Distillation Teacher-student model
17.06.18	11	Hardware for DNN training GPU as an accelerator	Cuda+pytorch
24.06.18	12	HW for DNN inference	Style transfer
01.07.18	13	Theoretical insights: why DL works Future direction (All)	