

236605	שם הקורס: למידה עמוקה על מאיצים חישוביים	מרצה אחראי: פרופ' אבי מנדלסון מרצה: פרופ' אלכס ברונשטיין מרצה ו מתרגל : חיים בסקין	2 ה', 1 ת' (3 נקודות)
--------	---	---	--------------------------

שם עברי מקוצר: למידה עמוקה על מאיצים חישוביים

שפת לימוד הקורס: אנגלית

דרישות קדם: תכן לוגי, מת"מ, הסתברות.

סילבוס בעברית

אלגוריתמי למידה עמוקות משומשים 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 בחבילות תוכנה 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 (קטנה) בתחום

הרכב הציון:

30% עבודות בית 30% רמת פרזנטציה של העבודה 40% עבודת 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:

30% Drills, 30% final presentation and 40% final project

Detailed syllabys is below :

WW	Lecture	Tutorial
1	Introduction	Setup environment , administration and Intro
2	Elements of machine learning: data-driven approach, k-nearest neighbor classifier, linear classification,	Numerical computation in Python: numpy (Tensor computing)
3	Linear regression Loss functions, optimization, descent methods, stochastic gradient descent	Signal processing in Python: (Tensor computing)
4	Neural networks: multi-layered perceptrons, backpropagation	Intro to PyTorch
5	Convolutional neural networks	Training convolution neural networks in PyTorch
6	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 Python: AlexNet, VGG, GoogLeNet, ResNet, etc.
7	Data decomposition vs. functional decomposition	Final project definition
8	Hardware for DNN training	Introduction to CUDA
9	Elements of parallel computing	Efficient implementation of matrix operators and convolution on CUDA
10	GPU as an accelerator	GPU in PyTorch, performance considerations
11	Recurrent neural networks: RNN, LSTM and applications in NLP, CV	RNNs, LSTM training
12	Variational Autoencoders (VAEs), Deep Q-Learning	VAEs, Deep Q-Learning
13	Summary and material completion	