

Deep Learning Szeminárium

I. előadás: bemutatkozás, kedvcsináló

Varga Dániel (Rényi Intézet)

Előadók:

- Csiszárík Adrián (Rényi Intézet)
- Lukács András (ELTE TTK Számítógéptudományi Tanszék)
- Varga Dániel (Rényi Intézet)
- Zombori Zsolt (Rényi Intézet)

<https://bit.ly/elte-ttk-deeplearning>

Feltételezett előismeretek: lineáris algebrai alapismeretek, többváltozós analízis alapismeretek, python alapismeretek

A jegyszerzést megkönnyítő további előismeretek: gépi tanulás alapfogalmai, valószínűségszámítási alapismeretek, python tudományos programozás (numpy, scipy)

Jegyszerzés módja:

- Önálló labormunka.
- A labormunka megkezdésének feltétele rövid házi feladatok teljesítése colab notebook környezetben.
- További részletek a feltételekről és elvárásokról a tárgy weblapján hamarosan.

A kurzus felépítése:

1. Bevezető előadások a deep learning-ről
2. Közös labormunka python/numpy/tensorflow/keras környezetben
3. Előadások modern deep learning modellekről

Ajánlott olvasmányok:

- François Chollet - Deep Learning with Python
- <http://course.fast.ai/>
- <http://cs231n.stanford.edu/>
- <http://rll.berkeley.edu/deeprlcourse/>
- <http://www.deeplearningbook.org/>
- Aki nagyon naprakész szeretne lenni, annak <https://www.reddit.com/r/MachineLearning/> vagy Twitteren deep learning hírességek követését ajánljuk.
- <https://github.com/> A legizgalmasabb dolgok elég nagy része open source, vagy van elfogadható minőségű open source reimplementációja. A kód módosíthatásából lehet a legtöbbet tanulni.

...ez mind közkincs:

- `pip install tensorflow keras`
- `git clone https://github.com/tensorflow/models ; cd research/im2txt # image to text`
- `git clone https://github.com/hanzhanggit/StackGAN.git # text to image`
- `git clone https://github.com/matterport/Mask\_RCNN # object detection & segmentation`
- `git clone https://github.com/facebookresearch/DensePose # human pose detection`
- `git clone https://github.com/tensorflow/nmt # machine translation (seq2seq)`
- `git clone https://github.com/tomlepaine/fast-wavenet # speech synthesis`
- `git clone https://github.com/lengstrom/fast-style-transfer # style transfer`
- `git clone https://github.com/NVlabs/stylegan # image generation`


GPT-2: titkos is, meg nem is, és csak 174 sor kód

```
147 def model(hparams, X, past=None, scope='model', reuse=False):
148     with tf.variable_scope(scope, reuse=reuse):
149         results = {}
150         batch, sequence = shape_list(X)
151
152         wpe = tf.get_variable('wpe', [hparams.n_ctx, hparams.n_embd],
153                               initializer=tf.random_normal_initializer(stddev=0.01))
154         wte = tf.get_variable('wte', [hparams.n_vocab, hparams.n_embd],
155                               initializer=tf.random_normal_initializer(stddev=0.02))
156         past_length = 0 if past is None else tf.shape(past)[-2]
157         h = tf.gather(wte, X) + tf.gather(wpe, positions_for(X, past_length))
158
159         # Transformer
160         presents = []
161         pasts = tf.unstack(past, axis=1) if past is not None else [None] * hparams.n_layer
162         assert len(pasts) == hparams.n_layer
163         for layer, past in enumerate(pasts):
164             h, present = block(h, 'h%d' % layer, past=past, hparams=hparams)
165             presents.append(present)
166         results['present'] = tf.stack(presents, axis=1)
167         h = norm(h, 'ln_f')
168
169         # Language model loss. Do tokens <n predict token n?
170         h_flat = tf.reshape(h, [batch*sequence, hparams.n_embd])
171         logits = tf.matmul(h_flat, wte, transpose_b=True)
172         logits = tf.reshape(logits, [batch, sequence, hparams.n_vocab])
173         results['logits'] = logits
174         return results
```

Megpróbálom végigcsinálni ezt az előadást úgy, hogy egyáltalán nem mondom el, hogy miből épül fel egy mesterséges neuronháló.


Jövő héten Zombori Zsolt teljesen pontos definíciót ad majd.

Egy fekete doboz nagyon sok potméterrel



Ennél azért egy kicsit részletesebben

- valós vektorokat valós vektorokba képező folytonos függvények paraméterezett családja
- bemenetek (kép, hang, videó, szöveg, térbeli pozíció, bármilyen idősor, ...)
- kimenetek (a fentiek közül bármelyik, klasszifikációnál valószínűségek vektora)
- veszteségfüggvény (Legegyszerűbb esetben $L(y, \hat{y})$, azaz hogy mennyire vagyok elégedett a kapott $\hat{y}$ kimenettel az elvárt y kimenet ismeretében. Lehet pl. négyzetes hiba.)
- tanítás (paraméter-hangolás elvárt bemenet-kimenet párok halmazának felhasználásával, hogy a paraméterezett függvénycsaládból egy számunkra alkalmas konkrét elemet kiválasszunk.)







**RGB pixel bemenet
(224x224x3 dim)**

**kategorikus
kimenet
(4 dim)**


Kimenet: pixelenkénti klasszifikáció (haj vagy nem haj)



Output
alphabet,
space,
& blank




az AlphaGo Zero játékállás -reprezentációja



This stack is the input to the deep neural network

A word embedding
módszereknek hála a szavak is
reprezentálhatók valós
vektorokként, és így használhatók
neuronhálók bemeneteként és
kimeneteként.

A beágyazás során megpróbálunk
közeli vektorokba képezni olyan
szavakat, amiknek a
szövegkörnyezetük gyakran
hasonló.





A neuronháló modellek építésének fő lépései (nem okvetlenül pontosan ebben a sorrendben)

- tanulóadatok (bemenet-kimenet párok) összegyűjtése
- veszteségfüggvény megtervezése
- neurális architektúra megtervezése (milyen paraméterezett függvénycsaládok milyen kompozíciójaként álljon elő a neuronháló)
- `while` kudarc:
 - hiperparaméter-hangolás, architektúra-hangolás
 - tanítás

Látens reprezentációk

Deep neural networks learn hierarchical feature representations



<https://distill.pub/2017/feature-visualization/>

<https://distill.pub/2017/feature-visualization/appendix/>

POSITIVE CHANNEL



Channel Objective



Diversity




Dataset examples

NEGATIVE CHANNEL



Negative Channel



Negative dataset examples

POSITIVE CHANNEL



Channel Objective



Diversity



Dataset examples

NEGATIVE CHANNEL



Negative Channel



Negative dataset examples

POSITIVE CHANNEL



Channel Objective



Diversity



Dataset examples

NEGATIVE CHANNEL



Negative Channel



Negative dataset examples


POSITIVE CHANNEL



Channel Objective



Diversity




Dataset examples

NEGATIVE CHANNEL



Negative Channel




Negative dataset examples

Alkalmazások


Alkalmazások

Nem reprezentatív lista, főleg az alapján válogatva, hogy szerintem mennyire érdekes vagy látványos az alkalmazás.

Mask R-CNN - képszegmentálás



DensePose - pose estimation



StackGAN - text to image

Text
description

This bird is
blue with white
and has a very
short beak

This bird has
wings that are
brown and has
a yellow belly




A white bird
with a black
crown and
yellow beak

This bird is
white, black,
and brown in
color, with a
brown beak



The bird has
small beak,
with reddish
brown crown
and gray belly

This is a small,
black bird with
a white breast
and white on
the wingbars.

Stage-I
images



Stage-II
images



Unsupervised Image-to-image Translation




DeepFakes

videó



Tacotron 2 - beszédsszintézis

[link: Tacotron 2 szintézis példák](#)



GPT-2, nyelvmodellezés

SYSTEM PROMPT (HUMAN-WRITTEN)	<i>In a shocking finding, scientist discovered a herd of unicorns living in a remote, previously unexplored valley, in the Andes Mountains. Even more surprising to the researchers was the fact that the unicorns spoke perfect English.</i>
MODEL COMPLETION (MACHINE-WRITTEN, 10 TRIES)	The scientist named the population, after their distinctive horn, Ovid’s Unicorn. These four-horned, silver-white unicorns were previously unknown to science. Now, after almost two centuries, the mystery of what sparked this odd phenomenon is finally solved. Dr. Jorge Pérez, an evolutionary biologist from the University of La Paz, and several companions, were exploring the Andes Mountains when they found a small valley, with no other animals or humans. Pérez noticed that the valley had what appeared to be a natural fountain, surrounded by two peaks of rock and silver snow. Pérez and the others then ventured further into the valley. “By the time we reached the top of one peak, the water looked blue, with some crystals on top,” said Pérez.

Cherry-picked

Kawasaki Z1000

I recently acquired this bike from its original owner. It has always been a good bike in every regard, but I found some problems along the way: It has some wear and tear on the engine bay, the front end has been modified to a wider track and the suspension was modified as well. The bike has been running very well, and the engine is still working perfectly (I have changed oil and filters and both of my oil changes since acquiring this bike).

The bike is still in working order and it has all the original items including the oil filter. I am giving this kz1000 a thorough overhaul with a complete overhaul in the oil system and front end as well as some complete brakes and exhaust work.


As a side project, I also have a very old motorbike that is a great engine swap to take these bikes to the next level.

Non-cherry-picked

Mély megerősítéssel tanulás szimulált 3D környezetben

videó: tanult mozgás


videó: competitive self-play




Generatív neuronhálók

Generatív neuronhálók

Generative Adversarial Network





Variational Autoencoder



Látens reprezentációk generatív modellekben

Digits autoencoder demo





The relationship between Source #1 and Source #2 is applied to the target image.



Coeff: -1.0



Coeff: 0.0



Coeff: 2.0








https://github.com/Puzer/stylegan/blob/master/Play_with_latent_directions.ipynb

Reconstruction

Gender-biased
smilevector

Gender-balanced
smilevector








Eddig csak az eredményeit soroltam, de a deep learning nem varázsszer

- Hatalmas az adat-igénye.
- Hatalmas a számítási kapacitás-igénye.
- Nincs szisztematizált matematikai vagy mérnöki megalapozása. Főleg próbálgatás illetve szájhagyomány útján terjedő babonák alapján tervezik a hálózatokat.
- Kevesebb sikert mutathat fel azokon a területeken, ahol nem lehet olyan eltolás-invarianciákat kihasználni, mint a képeknél és a hangoknál.

...és még egy nagy gond

Adversarial perturbation



videó: fizikailag
megvalósított
adversarial példa

Adversarial patch



Bemelegítő házi feladat jövő hétre: colab hello world

<https://colab.research.google.com>

Runtime / Change runtime type / Runtime type: Python 3
Runtime / Change runtime type / Hardware accelerator: GPU

```
import matplotlib.pyplot as plt
from keras.datasets import cifar10
(x_train, y_train), (x_test, y_test) = cifar10.load_data()
plt.imshow(x_train[12])
```


Köszönöm a figyelmet!

**A következő héten a mesterséges
neuronhálóak fogalmilag pontos
bevezetése, tanításuk alapelvei.**