

Csapó Tamás Gábor

Deep Learning a gyakorlatban Python és LUA alapon

Generatív modellezés, Generatív Versengő Hálózatok

Deep learning híradó (1)

- CCAI: Climate Change AI
 - intersection of climate change and machine learning
 - „CCAI is a group of volunteers from academia and industry who believe that tackling climate change requires concerted societal action, in which machine learning can play an impactful role.”
 - <https://www.climatechange.ai>
 - How Artificial Intelligence could help mitigate climate change
 - Virtual briefing & E-Paper presentation
 - Wednesday, Dec 2, 16:00 CET
 - <https://calendar.boell.de/en/event/how-artificial-intelligence-could-help-mitigate-climate-change>
 - Climate Change AI Happy Hour Series
 - Wednesday December 2 @ 6:30pm CET
 - https://www.climatechange.ai/events/happy_hour

Deep learning híradó (2)

Verse by Verse

An experimental AI-powered muse that helps you compose poetry inspired by classic American poets

Let's write a poem

Forrás: <https://sites.research.google/versebyverse/>

Deep learning híradó (3)

- NeurIPS 2020 : December 6-12, virtual only
- ICPR 2020
 - International Conference on Pattern Recognition
 - Virtual only / Jan 10-15, 2021
- ICLR 2021
 - Ninth International Conference on Learning Representations
 - Virtual only / May 4-7, 2021
- CVPR 2021
 - IEEE/CVF Conference on Computer Vision and Pattern Recognition
 - Virtual only / June 19-25, 2021
- IJCAI 2021
 - 30th International Joint Conference on Artificial Intelligence
 - Montreal, Canada / Aug 21-26, 2021
- ICANN 2021:
 - International Conference on Artificial Neural Networks
 - Bratislava, Slovakia / September 14-17, 2021
- Interspeech 2021
 - Brno, Czechia / Aug 30 – Sep 3, 2021

Nagyházi (1)

- <http://smartlab.tmit.bme.hu/oktatas-deep-learning-eloadas?eloadas=1>
- <http://smartlab.tmit.bme.hu/oktatas-deep-learning-nagy-hazi>
- Beszámoló dokumentum, Határidő: 2020. dec. 11., 23:59
 - Github-ra feltöltött forráskód, readme.md, beszámoló PDF
 - Github-on az utolsó, határidő előtti commit-ot nézzük
- Megajánlott jegy
 - csak az MS1 és MS2 időre történő teljesítés esetén
 - és megfelelő nagyházi feladat esetén
 - a felvett vizsgaalkalomig kijavítjuk a házit és jelezzük, hogy mire van vele esély (5-ös, 4-es, +1 jegy)

Nagyházi (2) – szóbeli beszámoló

- Jelentkezzetek vizsgára és ott mutassátok be
- Megajánlott jegyért és aláírásért is

Prezentációs fóliák

- PPT vagy PDF a Github repoba feltöltve a vizsga előtti nap éjfélig.
 - Téma bemutatása
 - Korábbi munkák
 - Kidolgozott megoldás
 - Kiértékelés
 - Összefoglalás
- Lehet angolul és magyarul is.

Nagyházi (3) – szóbeli beszámoló

Prezentációs videó

- Unlisted YouTube link, a GitHub repo README.MD-jébe írjátok bele a vizsga előtti nap éjfélig feltöltve.
- 10 perc (+/- 1 perc)
- A prezentációs fóliák bemutatása
- Egyik sarokban a előadó személy mutatása (webkamerával)
- Minden csapattag beszéljen

Javasolt software:

- Felvétel: OBS Studio
- Utómunkák: OpenShot
- vagy Teams meeting előzetes rögzítése

Nagyházi (4) – szóbeli beszámoló

- Szóbeli beszámoló
 - 10 perces előadás, melyet a felvett vizsga során vetítünk le és értékeljük & kérdezzük
 - az írásbeliben leadott anyaghoz képest lehetnek még újdonságok
 - az előzetes értékelés itt lesz végleges és lesz 5-ös / 4-es / +1 / csak aláírás. +1 / csak aláírás esetén még vizsgázni kell.
 - minden további plusz egy jegyet is beszámítunk (Kahoot, kisházi), de csak ha minimum 2-es jegye van valakinek
- Vizsga
 - 3 kérdés, amit papíron ki kell dolgozni és utána ebből, és az egész anyagból szóbeli
 - az egyik kérdés fixen a backpropagation

5. kis házi feladat:

4. kisHF jav: jövő hétre

Hiperparaméter optimalizálás

Készíts kísérletsorozatot, melyben automatikus hiperparaméter optimalizálást végzel a CIFAR-10 adatbázison képosztályozási feladatra. Legyen legalább 100 tanítás, melynek eredményeit elemzed is (pl. hálózat mérete és az osztályozás pontossága hogyan függ össze?).

Tetszőleges deep learning keretrendszert és github forráskódokat (megfelelően hivatkozva) használhatsz. A megoldást részletesen kommentezd és a tanítás kimenetét (log fájlját) is mellékelj. A leírás és kommentek angolul legyenek!

<https://github.com/BME-SmartLab-Education/vitmav45/blob/master/kishazi/5-kis-hazi-feladat.md>

Beadási határidő: 2020. december 8. 23:59

Jogi nyilatkozat

Jelen előadás diái a „*Deep Learning a gyakorlatban Python és LUA alapon*” című tantárgyhoz készültek és letölthetők a <http://smartlab.tmit.bme.hu> honlapról.

A diák nem helyettesítik az előadáson való részvételt, csupán emlékeztetőül szolgálnak.

Az előadás diái a szerzői jog védelme alatt állnak. Az előadás diáinak vagy bármilyen részének újra felhasználása, terjesztése, megjelenítése csak a szerző írásbeli beleegyezése esetén megengedett. Ez alól kivétel, mely diákon külső forrás külön fel van tüntetve.

Generative Adversarial Network (GAN)

- Ian Goodfellow

- BSc, MSc @ Stanford
- PhD @ Université de Montréal
(konzulensek: Yoshua Bengio és Aaron Courville)
- Google Brain / OpenAI / 2017-től újra Google-nél
- „Deep Learning” book egyik szerzője
(<http://www.deeplearningbook.org>)
- GAN ötlete: 2014, Montréal, pub...
- Goodfellow, Ian J.; Pouget-Abadie, Jean; Mirza, Mehdi; Xu, Bing; Warde-Farley, David; Ozair, Sherjil; Courville, Aaron; Bengio, Yoshua (2014). "Generative Adversarial Networks". [arXiv:1406.2661](https://arxiv.org/abs/1406.2661), <https://arxiv.org/abs/1406.2661>



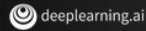
NIPS 2016 GAN tutorial



Forrás: <http://www.iangoodfellow.com/presentations.html>

Generative Adversarial Networks (GANs) Specialization

www.coursera.org/specializations/generative-adversarial-networks-gans



Generative Adversarial Networks (GANs) Specialization

About How It Works Courses **Instructors** Enrollment Options FAQ

Instructors



Sharon Zhou

Instructor
Computer Science, Stanford University

19,152 Learners
3 Courses



Eda Zhou

Curriculum Developer

19,152 Learners
3 Courses



Eric Zelikman

Curriculum Engineer

19,152 Learners
3 Courses

Offered by



DeepLearning.AI

Founded by Andrew Ng, DeepLearning.AI is an education technology company that develops a global community of AI talent.

Forrás: <https://www.coursera.org/specializations/generative-adversarial-networks-gans>


Generatív modellek

Miért érdemes a generatív modellezéssel foglalkozni?

Generatív modellezés

- Sűrűségfüggvény becslés

a dataok





Generatív modellezés

- Sűrűségfüggvény becslés

- Minta generálás
 - Tanító minták

Modell mintái



Miért érdemes a generatív modellekkel foglalkozni?

- Sokdimenziós valószínűség eloszlások
 - Valós-életbeli problémák
- Lehetséges jövő szimulálása
 - Reinforcement learning
- Hiányzó adat kezelése
 - Félig felügyelt tanulás
- Multimodális kimenet
- Valósághű generálási feladatok


Következő videó képkocka becslése

megelőző képkockák

cél

átlag

generatív modell



Single Image Super-Resolution

bicubic
(21.59dB/0.6423)



SRResNet
(23.53dB/0.7832)



SRGAN
(21.15dB/0.6868)




original



Forrás: Ledig et al 2016, <https://arxiv.org/abs/1609.04802>


iGAN (interactive)



Forrás: Zhu et al 2016, <https://arxiv.org/abs/1609.03552>

IAN (Introspective Adversarial Network)

- Neural Photo Editor



Forrás: Brock et al 2016, <https://arxiv.org/abs/1609.07093>

Képből képbe transzformálás



Forrás: Isola et al 2016, <https://arxiv.org/abs/1611.07004>

Generatív modellek

Hogy működnek más modellekhez képest?

Maximum likelihood becsles


$\underline{x}$: tanítóadatok

$p_{\text{modell}}(x)$ $\odot$: modell paraméterek

$$\odot^* = \underset{\odot}{\operatorname{argmax}} E_{x \sim p_{\text{adat}}} \log p_{\text{modell}}(x | \theta)$$

$\odot^*$: azon paraméterek, ami mellett a modell
legjobb becsli az adatok
valószínűség eloszlását

Generatív modellek családfája



Forrás: Goodfellow et al 2016, <http://www.iangoodfellow.com/slides/2016-12-9-gans.pdf>

Fully Visible Belief Nets

- Lánc-szabály alkalmazása

$$p_{\text{modell}}(x) = p_{\text{modell}}(x_1) \cdot \prod_{i=2}^n p_{\text{modell}}(x_i | x_1, x_2, \dots, x_{i-1})$$


- Hátrányok
 - Extrém lassú generálás: $O(n)$ (nem párhuzamosítható)
 - Generálásnál nincs látens reprezentáció



PixelCNN fűnyírók

Forrás: van den Oord et al 2016, <https://arxiv.org/abs/1606.05328>

WaveNet



Forrás: van den Oord et al 2016, <https://arxiv.org/abs/1609.03499>

Variational AE (1)

- Kódolt reprezentáción további kényszerek (nem csak bottleneck)
- Encoder: Input adatból látens változók kinyerése
 - Látens = nem megfigyelhető, rejtett, „háttérváltozó”
 - Megtanulja az adatok valószínűség-eloszlását
 - `z_mean` & `z_log_sigma`


Forrás: <http://www.slideshare.net/TJTorres1/deep-style-using-variational-autoencoders-for-image-generation>

Variational AE (2)

- Decoder: látens változókból adatok visszaalakítása
- Generatív modell
 - Ha az eloszlásból mintákat veszünk, új adatot generálhatunk
 - Véletlen mintavételezés,
 - $z = z_mean + \exp(z_log_sigma) * \epsilon$
- Valószínűségi data-encoder és data-decoder tanítása end-to-end módon


Forrás: <http://www.slideshare.net/TJTorres1/deep-style-using-variational-autoencoders-for-image-generation>

Variational AE (3)



Forrás: <http://blog.fastforwardlabs.com/2016/08/22/under-the-hood-of-the-variational-autoencoder-in.html>

Variational AE (5)



Forrás: Carl Doersch, Tutorial on Variational Autoencoders , <https://arxiv.org/abs/1606.05908>



VAE learning to generate images (log time)

Forrás: <https://openai.com/blog/generative-models/>

Generative Adversarial Networks

- Látens reprezentációt alkalmaz
(nem úgy, mint a Fully Visible Belief Nets)
- Aszimptotikusan konzisztens
(nem úgy mint a VAE)
- Nem kell Markov-lánc hozzá
(pl. a Boltzmann-géphez kell)
- Jól párhuzamosítható
- Tapasztalatok szerint általában a legjobb képeket generálja
(de ez nehezen számszerűsíthető)

Hogy működnek a GAN-ok?

Játékelmélet: kő-papír-olló

- Két játékos, kiegyenlített esélyek
- Saját nyerések + ellenfél nyerések = 0
- Egyensúly: mindegyik játékos stratégiája a lehető legjobb az ellenfél stratégiájának is

		<u>Your opponent</u>		
		Rock	Paper	Scissors
<u>You</u>	Rock	0	-1	1
	Paper	1	0	-1
	Scissors	-1	1	0

- Hogyan lehetne a játékelméletet a generatív modellezésben alkalmazni?

Forrás: <http://www.cs.toronto.edu/~dtarlow/pos14/talks/goodfellow.pdf>

Játékelmélet: pénzhamisítás

diszkriminátor





generátor




Forrás: Goodfellow (2016), <https://arxiv.org/abs/1701.00160>

Adversarial Net (~versengő háló)



Diszkriminátor hálózat

$\{0,1\}$
 $\uparrow$
 $\mathcal{X}$




Forrás: <https://devblogs.nvidia.com/photo-editing-generative-adversarial-networks-1/>

Generátor hálózat

- $x = G(z; \theta^{(G)})$
- G differenciálható legyen
 - nem kell invertálhatónak lennie
 - z tetszőleges méretére tanítható
 - z és x dimenziójának nem kell megegyeznie (általában x dimenziója nagyobb, mint z dimenziója)



Generátor hálózat



Forrás: <https://devblogs.nvidia.com/photo-editing-generative-adversarial-networks-1/>

Tanítás menete

- SGD jellegű algoritmus (pl. Adam) egyidejűleg két minibatch-en:
 - egy minibatch tanító minta
 - egy minibatch generált minta
- Opcionálisan valamelyik játékost futtathatjuk k lépésen keresztül

Kahoot!

Névnek a NEPTUN
kódodat add meg!

<https://kahoot.it/>

LINDEMANN - MESTERSÉGES INTELLIGENCIA KÉSZÍTETTE AZ ÚJ KLIPET: ICH WEISS ES NICHT

Novemberben jelenik meg a 2015-ös Skills In Pills album folytatása

2019. október 20. (vasárnap) 19:35

A Rammstein énekes Till Lindemann, valamint a Hypocrisy és a Pain éléről ismert Peter Dinklage közös projektjének első albuma Skills In Pills címmel jött ki 2015 nyarán, a folytatás, a második Lindemann nagylemez pedig november 22-én jelenik meg, a címe F & M (Frau & Mann) lesz.

A Steh Auf című első előzetes dal után pénteken kijött a második teljes nótája is, az Ich weiß es nicht, amelyhez most megérkezett egy különleges klip is, amelyet teljes egészében Mesterséges Intelligencia (MI, AI) alkotott. A GAN (generatív ellenséges hálózat - generative adversarial networks) technológia lényege, hogy az algoritmusok versenyeznek egymással. A MI két, egymással vetélkedő hálózatot használ fel az információk "ütköztetéséhez", hogy az emberi agyhoz hasonlóan - amelyben az új ötletet találkozásából születnek - kreatív tartalmat



Forrás: <https://hammerworld.hu/2019/10/20/lindemann-mesterseges-intelligencia-keszitette-az-uj-klipet-ich-wei-es-nicht>
<https://www.youtube.com/watch?v=obY4c9aUqUq>

- „There are many interesting recent development in deep learning... The most important one, in my opinion, is adversarial training (also called GAN for Generative Adversarial Networks). This, and the variations that are now being proposed is the most interesting idea in the last 10 years in ML, in my opinion.”

– Yann LeCun, 2016

1) Minimax játék

$$\mathcal{J}^{(D)} = -\frac{1}{2} \mathbb{E}_{x \sim p_{\text{adat}}} \log D(x) - \frac{1}{2} \mathbb{E}_z \log (1 - D(G(z)))$$

$$\mathcal{J}^{(G)} = -\mathcal{J}^{(D)}$$

↓
bináris keresztentropiánsok
megfelelő hőttség

D: próbálja $\mathcal{J}^{(D)}$ -t minimalizálni

$$\left. \begin{array}{l} D(x)=1 \rightarrow \log: 0 \\ D(G(z))=0,1 \rightarrow \log: 2 \end{array} \right\} : 1$$

G: próbálja $\mathcal{J}^{(D)}$ -t maximalizálni

cél: egyensúlyi helyzet

2) Heurisztikus játék (nem-telítődő)

- Költség függvények

$$\mathcal{J}^{(0)} = -\frac{1}{2} E_{x \sim p_{\text{adat}}} \log D(x) - \frac{1}{2} E_z \log(1 - D(G(z)))$$

$$\mathcal{J}^{(G)} = -\frac{1}{2} E_z \log D(G(z))$$


Minimax, G célja: helyes válasz ^{log} valószínűsége + minimalizálja

Heurisztikus, G célja: hibás válasz ^{log} valószínűsége + maximalizálja

Egyszerű: néha

gyakorlatban jól működik

Generátor költségei




Forrás: Goodfellow (2016), <https://arxiv.org/abs/1701.00160>

Batch Normalization

- Tanító adatok normalizálása
 - Átlag és szórás számítása
 - Nulla várható érték, egységnyi szórás
- BatchNorm: Normalizálás minden rétegben
- Rétegek jobban függetlenné válnak egymástól
- Gyorsabb konvergencia
- Túltanulás esélye csökken
- Regularizációs hatás
 - átlag és szórás számítása az adott minibatch-en
- Keras:
 - `from keras.layers import BatchNormalization`
 - `model.add(BatchNormalization(momentum=0.8))`

DCGAN (Deep Convolutional...)

- Radford et al 2015




Forrás: <https://blog.openai.com/generative-models>

DCGAN, hálószobák (LSUN bedrooms)



Forrás: Radford et al (2015), <https://arxiv.org/abs/1511.06434>


DCGAN, Számítási műveletek arcképeken



Forrás: Radford et al (2015), <https://arxiv.org/abs/1511.06434>

Jürgen Schmidhuber

- 1997, LSTM
- Goodfellow (2014) NIPS cikk egyik bírálata:
 - „Finally, how is the submission related to the first work on "adversarial" MLPs for modeling data distributions through estimating conditional probabilities, which was called "predictability minimisation" or PM (Schmidhuber, NECO 1992)? The new approach seems similar in many ways.”
 - Schmidhuber, J., 1992 „Learning Factorial Codes by Predictability Minimization”, Neural Computation 4(6) pp. 863-879



Forrás:

https://mobile.nytimes.com/2016/11/27/technology/artificial-intelligence-pioneer-jurgen-schmidhuber-overlooked.html?_r=0&referer=

Forrás: http://media.nips.cc/nipsbooks/nipspapers/paper_files/nips27/reviews/1384.html

GAN további ötletek

Kimeneti címkék felhasználása


- Eleinte GAN csak kis képekre működött jól
- Ötlet 1: $p(x)$ helyett $p(y|x)$ tanítása
 - azaz a címkéket is hozzávesszük az adatokhoz
 - feltételes valószínűség generálás során is használható
 - pl. „béka” (CIFAR-10)
- Ötlet 2: $p(x)$ helyett $p(x, y)$ tanítása
 - már a közös eloszlás tanítása is segít
- Generált képek szubjektív minőségét javítja

G és D egyensúlya

- Általában a diszkriminátor „nyer”
- Ez nem gond, mert az elmélet is arra épül, hogy D tökéletes
- Futtassuk-e D-t gyakrabban, mint G-t?
 - Gyakorlati tapasztalat: nem érdemes
- Semmiképp nem érdemes D-t korlátozni, hogy ne legyen túl okos
 - Inkább: heurisztikus költség a minimax helyett
 - Vagy: one-sided label smoothing



Felügyelt diszkriminátor hálózat



Forrás: Salimans et al (2016), <https://arxiv.org/abs/1606.03498>

Kiértékelés


- Generatív modellek kiértékelésére nincs tökéletes módszer
 - Jól betanított modell is generálhat rossz mintát
 - Nehéz számszerűsíteni a generált minták jóságát
- Szubjektív kiértékelés
 - Néhány generált minta vizsgálata...

Kiértékelés (2)


Please adjust the reality / naturalness of each ultrasound tongue image by moving the horizontal slider between 1-100!



Unknown dist
pdata



Well known
distribution



Loss

	Fully fake	Fake	Intermediate	Real	Fully real
rating	<input type="range"/>				

Submit & next sample


Probléma: darabszám



Forrás: Goodfellow (2016), <https://arxiv.org/abs/1701.00160>


További GAN alkalmazások

GAN és művészet




Forrás: <https://mtyka.github.io/machine/learning/2017/06/06/highres-gan-faces.html>

Rajzból képbe...



Text-To-Image / GAN




Forrás: Reed et al (2016), <https://arxiv.org/abs/1605.05396>

Text-To-Image / GAN: flowers

Caption	Image
this flower has yellow petals and a red stamen	
the center is yellow surrounded by wavy dark red petals	
this flower has lots of small round orange petals	

Forrás: <https://github.com/reedscot/icml2016>

MuseGAN



Forrás: <https://salu133445.github.io/musegan/>

- Karras et al., (NVIDIA), „PROGRESSIVE GROWING OF GANS FOR IMPROVED QUALITY, STABILITY, AND VARIATION”, ICLR 2018
- http://research.nvidia.com/publication/2017-10_Progressive-Growing-of



- <https://www.youtube.com/watch?v=XOxxPcy5Gr4>

Realistic neural talking heads

Varying the number of frames

Training frames:



Face landmarks



1-shot result



8-shot result




32-shot result

- [„Few-Shot Adversarial Learning of Realistic Neural Talking Head Models”](#)
- <https://www.youtube.com/watch?v=p1b5aiTrGzY> 5:08


Image-to-image translation

GAN / pix2pix: Image-to-image translation



Forrás: <https://phillipi.github.io/pix2pix/>

CycleGAN: unpaired image-to-image translation



Forrás: <https://github.com/eriklindernoren/Keras-GAN>

CycleGAN: unpaired image-to-image translation

Monet ↔ Photos



Monet → photo



photo → Monet

Zebras ↔ Horses



zebra → horse



horse → zebra

Summer ↔ Winter



summer → winter



winter → summer



Photograph



Monet



Van Gogh



Cezanne




Ukiyo-e


Forrás: <https://junyanz.github.io/CycleGAN/>

StarGAN: img-to-img translation

(a) Cross-domain models




(b) StarGAN



Forrás: <https://lyusungwon.github.io/studies/2019/01/15/stargan/>


StarGAN: img-to-img translation with a single model



Forrás: <https://lyusungwon.github.io/studies/2019/01/15/stargan/>

GAN összefoglalás

GAN összefoglalás (1)




Forrás: Goodfellow (2016), <https://arxiv.org/abs/1701.00160>

GAN összefoglalás (2)

- GAN: generatív modell, felügyelt tanulás
- Többféle költségfüggvény lehet
 - Minimax, heurisztikus, ML
- D és G hálózat egyensúlya
- Valósághű képeket (vagy pl. hangot) tud generálni

Cégek: hogyan alkalmazzák a GAN-okat?





Tweets
976

Following
423

Followers
42.2K

Likes
1,859

Ian Goodfellow

@goodfellow_ian

Google Brain research scientist Lead author of deeplearningbook.org Co-author of ML security blog cleverhans.io

📍 San Francisco, CA

🔗 iangoodfellow.com

📅 Joined September 2016

Tweet to Ian Goodfellow

Tweets


Tweets & replies

Media



Ian Goodfellow @goodfellow_ian · Oct 28

Impressive high-res GAN results! youtube.com/watch?v=XOxxPc... (Maybe jump to 2:00 or 4:30)



Progressive Growing of GANs for Improved Quality...

Submitted to ICLR 2018 We strongly recommend watching the video full-screen at 1080p @ 60.

youtube.com


💬 12

↻ 151

❤️ 396



The GAN zoo



Forrás: https://raw.githubusercontent.com/hindupuravinash/the-gan-zoo/master/cumulative_gans.jpg



Statistics > Machine Learning

Stopping GAN Violence: Generative Unadversarial Networks

Samuel Albanie, Sébastien Ehrhardt, João F. Henriques

(Submitted on 7 Mar 2017)

While the costs of human violence have attracted a great deal of attention from the research community, the effects of the network-on-network (NoN) violence popularised by Generative Adversarial Networks have yet to be addressed. In this work, we quantify the financial, social, spiritual, cultural, grammatical and dermatological impact of this aggression and address the issue by proposing a more peaceful approach which we term Generative Unadversarial Networks (GUNs). Under this framework, we simultaneously train two models: a generator G that does its best to capture whichever data distribution it feels it can manage, and a motivator M that helps G to achieve its dream. Fighting is strictly verboten and both models evolve by learning to respect their differences. The framework is both theoretically and electrically grounded in game theory, and can be viewed as a winner-shares-all two-player game in which both players work as a team to achieve the best score. Experiments show that by working in harmony, the proposed model is able to claim both the moral and log-likelihood high ground. Our work builds on a rich history of carefully argued position-papers, published as anonymous YouTube comments, which prove that the optimal solution to NoN violence is more GUNs.

Comments: Under review as a conference paper at SIGBOVIK 2017

Subjects: **Machine Learning (stat.ML)**; Learning (cs.LG)

Cite as: [arXiv:1703.02528 \[stat.ML\]](#)

(or [arXiv:1703.02528v1 \[stat.ML\]](#) for this version)

Submission history

From: Samuel Albanie [[view email](#)]

[v1] Tue, 7 Mar 2017 18:54:04 GMT (832kb,D)

Köszönöm a figyelmet!

`csapot@tmit.bme.hu`

