

Neuronové sítě 2 - Úvod do neuronových sítí

18NES2 -8. hodina, ZS 2024/25

Zuzana Petříčková

20. listopadu 2024

Neuronové sítě 2 - Úvod do neuronových sítí

1 Co jsme dělali minule

2 Konvoluční neuronové sítě

- Regularizace
- Učení modelu od začátku
- Data Augmentation
- Přenesené učení

Co bylo minule

- Ukázky praktických úloh
 - Obrázky - klasifikace do více tříd
 - Texty - binární klasifikace
 - Číselné vektory (malá data) - regrese
- Ladění hyperparametrů u jednotlivých modelů
- Umělé neuronové sítě a zobecňování
 - Praktické ukázky - nedokončili jsme

Dnes

- Umělé neuronové sítě a zobecňování
 - Dokončení praktických ukázek pro MLP a pro konvoluční neuronovou síť
 - Funkcionální API v Kerasu a vytváření složitějších architektur
- Konvoluční neuronová síť pro klasifikaci - praktické ukázky
 - Model učený od začátku
 - Augmentace dat
 - Model učený pomocí přeneseného učení (transfer learning)

Konvoluční neuronové sítě a zobecňování

- Konvoluční neuronové sítě mívají problémy s přeучením
- Problémem je, pokud máme k dispozici málo dat (stovky, malé tisíce vzorů)
- Navíc: učení může být velmi pomalé
- Jak zobecňování zlepšit?
 - **standardní regularizace**
 - **data augmentation:** rozšíření dat
 - **transfer learning**

Konvoluční neuronové sítě a zobecňování

Nejčastěji používané techniky regularizace

- **Early stopping**
- **L1/L2 regularizace** - u ReLU jednotek v konvolučních a plně propojených vrstvách
- **Dropout** - přidání speciální vrstvy za každou plně propojenou vrstvu
- **Normalizace** dat, vah, výstupů vrstev, oblíbená technika je Batch Normalization
- **Label smoothing** (zašumění labelů)
- **Ensembling**

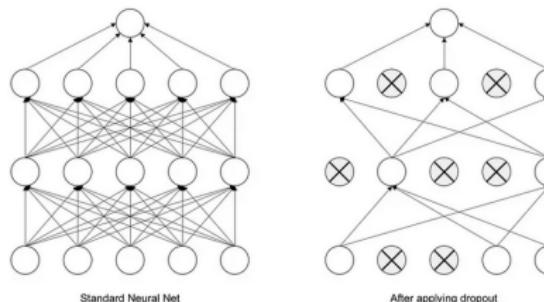
Typické pro konvoluční sítě’:

- **Augmentace dat**
- **Transfer learning (přenesené učení)**

Konvoluční neuronová síť a regularizace

Dropout (Srivastava et al., 2014)

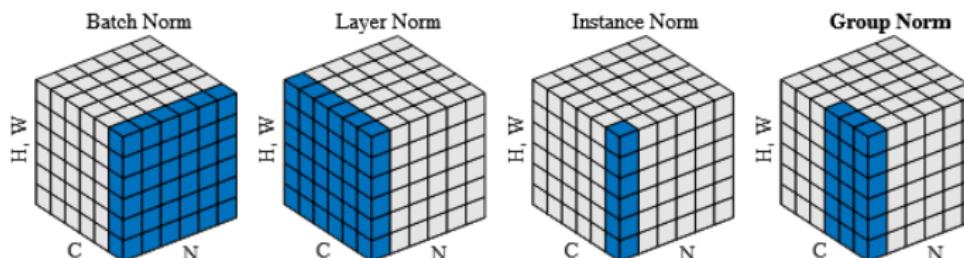
- vysoce účinná metoda
- spočívá v náhodném vypínání (deaktivování) některých skrytých neuronů během učení
- při testování a používání modelu jsou všechny neurony aktivované
- implementované přidáním speciální **dropout** vrstvy za každou plně propojenou vrstvu



Konvoluční neuronová síť a regularizace

Normalizace vstupů jednotlivých vrstev

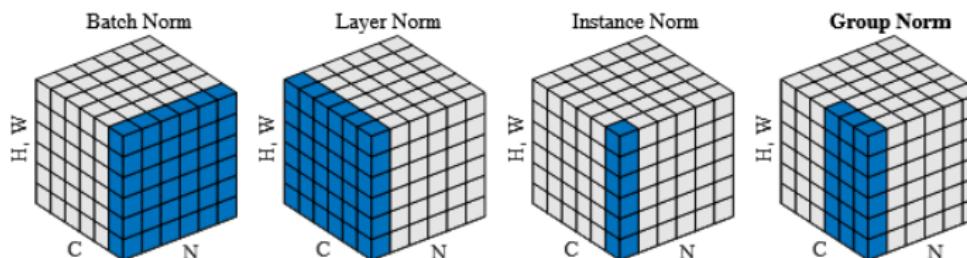
- snaha zafixovat střední hodnoty a rozptyly vstupů každé vrstvy
- snaha o řešení problému mizejících gradientů
- $N \dots$ batch (počet FM), $C \dots$ channels (kanály), $H, W \dots$ rozměry FM (matice příznaků)
- různé varianty:



Konvoluční neuronová síť a regularizace

Normalizace vstupů jednotlivých vrstev

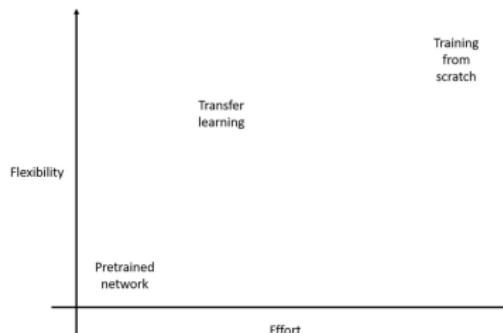
- implementováno pomocí přidání další vrstvy (např. za konvoluční vrstvu)
- rychlejší učení, menší citlivost na inicializaci vah
- robustnost k šumu v datech (nahradí Dropout)



Wu, Y., et al. "Group Normalization", <https://arxiv.org/pdf/1803.08494>

Možnosti vytvoření a učení konvolučních neuronových sítí

- učení od začátku (training from scratch)
- použití již naučeného modelu (pretrained network)
- přenesené učení (transfer learning)
- doučení již naučeného modelu (finetuning)



Zdroj :

<https://matlabacademy.mathworks.com/details/deep-learning-onramp/deeplearning>

Ukázka modelu učeného od začátku na malých datech: klasifikace psů a koček

- zdroj dat: Kaggle soutěž 2013
<https://www.kaggle.com/c/dogs-vs-cats> (pro stažení dat potřebujeme mít Kaggle účet)
- alternativně (bez přihlášení): <https://www.microsoft.com/en-us/download/details.aspx?id=54765>
- 25000 snímků psů a koček (12500 koček, 12500 psů), cca. 500 MB (komprimované)

Předzpracování:

- vybereme jen podmnožinu dat: 4000 snímků psů a koček (2000 koček, 2000 psů) ... malá data
- data rozdělíme na trénovací, validační a testovací množinu v poměru 2000 : 1000 : 1000
- na datech naučíme základní - referenční - CNN model

Ukázka modelu učeného od začátku na malých datech: klasifikace psů a koček

Pozorování

- přesnost na testovacích datech je okolo 70%, problém je s přeúčením

Na příkladu si ukážeme další techniky

- augmentace dat
- přenesené učení (transfer learning, feature extraction)
- fine-tuning

Augmentace dat

- různé (náhodné) transformace obrazu (rotace, posun, zrcadlení, zešikmení, měna rozlišení, změna jasu a kontrastu, oříznutí, přidání šumu, blur, kombinace)
- v Kerasu implementujeme pomocí speciální vrstvy



Zdroj :

<https://matlabacademy.mathworks.com/details/deep-learning-onramp/deeplearning>

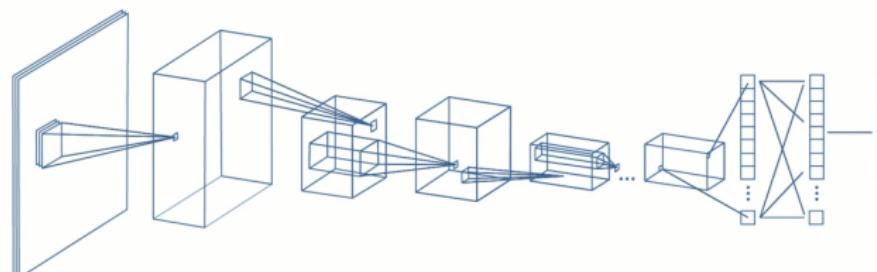
Augmentace dat - oblíbené varianty

	ResNet-50	Mixup [48]	Cutout [3]	CutMix
Image				
Label	Dog 1.0	Dog 0.5 Cat 0.5	Dog 1.0	Dog 0.6 Cat 0.4

Zdroj : Yun et all., CutMix: Regularization Strategy to Train Strong Classifiers with Localizable Features, <https://arxiv.org/pdf/1905.04899>

Přenesené učení (transfer learning)

- naučený model klasifikuje do 1000 tříd:

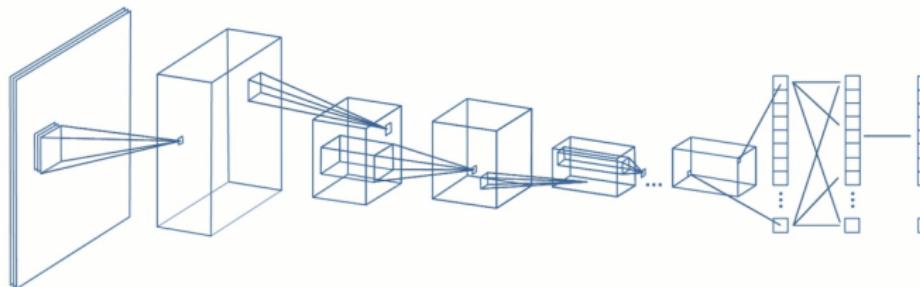


Zdroj :

<https://matlabacademy.mathworks.com/details/deep-learning-onramp/deeplearning>

Přenesené učení (transfer learning)

- je třeba klasifikovat do trochu jiných tříd:



Zdroj :

<https://matlabacademy.mathworks.com/details/deep-learning-onramp/deeplearning>

Přenesené učení (transfer learning)

Předučené modely:

- <https://keras.io/api/applications/>
- oblíbené modely konvolučních neuronových sítí
 - VGG16
 - MobileNet
 - ResNet
 - ...
- váhy jsou buď náhodně inicializované, nebo jsou sítě předučené, typicky na ImageNet

ImageNet Large-Scale Visual Recognition Challenge (ILSVRC, 2010-2017)

Datová sada ImageNet

- 16 milionů barevných obrázků z 20 tisíc kategorií
- soutěž odstartovala boom konvolučních neuronových sítí v rozpoznávání obrazu

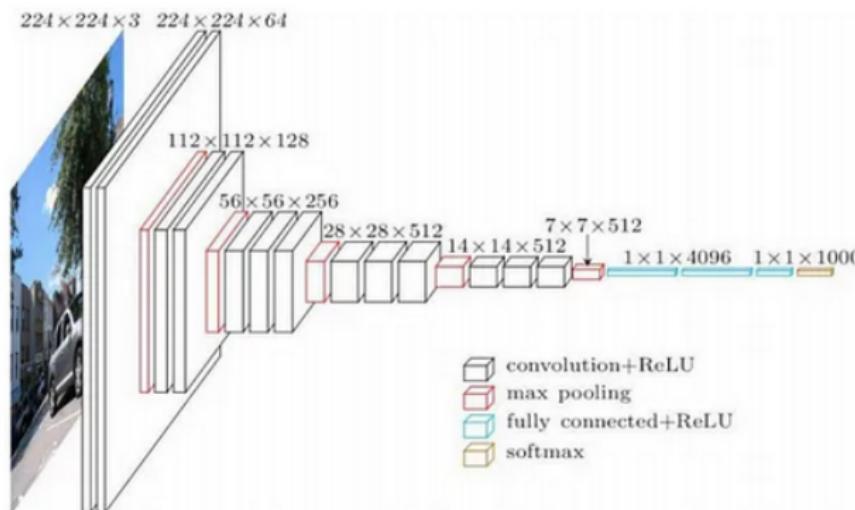


Zdroj obrázku:

https://cs.stanford.edu/people/karpathy/cnnembed/cnn_embed_full_1k.jpg

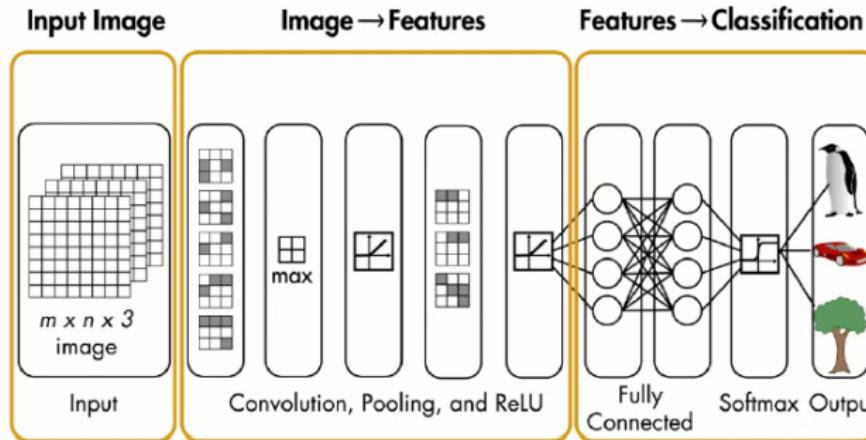
VGGNet

Karen Simonyan a Andrew Zisserman, 2014, rodina modelů (např. VGG16, VGG19)



Zdroj obrázku:

Architektura konvoluční neuronové sítě



Části konvoluční neuronové sítě

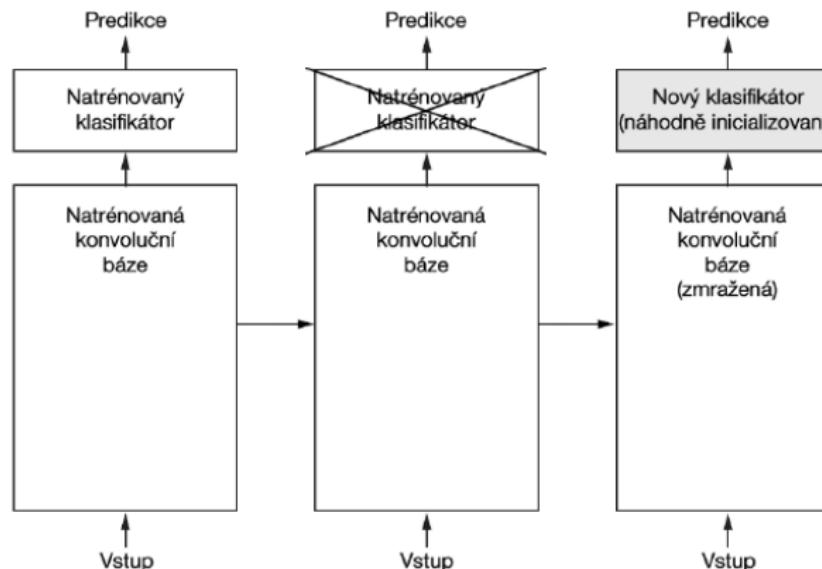
- Konvoluční vrstvy pro extrakci příznaků
- Flattening vrstva - převede data na vektor čísel
- Vrstevnatá neuronová síť pro klasifikaci

Zdroj :

<https://matlabacademy.mathworks.com/details/deep-learning-onramp/deeplearning>

Přenesené učení (transfer learning)

- nahradíme klasifikační část neuronové sítě (nebo jen její vrchní část) novou verzí a naučíme ji na nových datech (váhy předchozích vrstev zafixujeme)



Přenesené učení

- data je třeba převést na požadovanou velikost a typicky do RGB



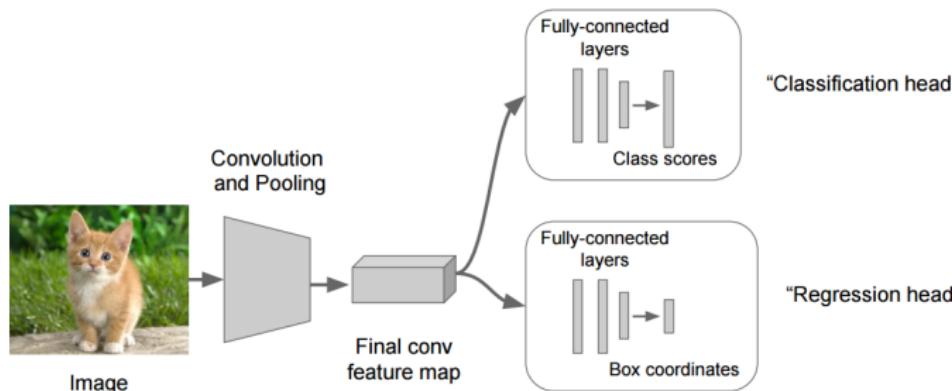
- při přeneseném učení obvykle volíme malý parametr učení

Přenesené učení a finetining

- model naučený s pomocí přeneseného učení můžeme dále vylepšit pomocí finetuning-u
 - ① nejprve aplikujeme přenesené učení (váhy mimo klasifikační část zafixujeme)
 - ② pak aplikujeme finetuning na část konvolučních vrstev (s velmi malým parametrem učení - ideálně začneme s hodnotou, na které končil původní model)
 - ③ můžeme použít regularizaci

Přenesené učení - rozšíření

- klasifikační část neuronové sítě (tj. „hlavu“) můžeme nahradit jinou hlavou a použít naučené příznaky pro řešení jiné úlohy nad stejnými (nebo jinými) daty
 - jiná klasifikační úloha
 - regresní úloha
 - detekce objektů
 - popisy k obrázkům,...



Přenesené učení - omezení

- přenesené učení se hodí, pokud chce naučit model na podobných datech (obecný model → konkrétnější model)
- nelze použít, pokud by bylo třeba změnit vstupní vrstvy
 - větší počet kanálů (např. rentgenový snímek apod.)
 - rozdílná úroveň abstrakce
 - úplně jiná data
- někdy nezbývá než učit model od začátku

příklad: fotografie ramene rozšířená o rentgen a MRI



<https://radiopaedia.org/cases/normal-shoulder-mri>