

# Co jsme probírali minule

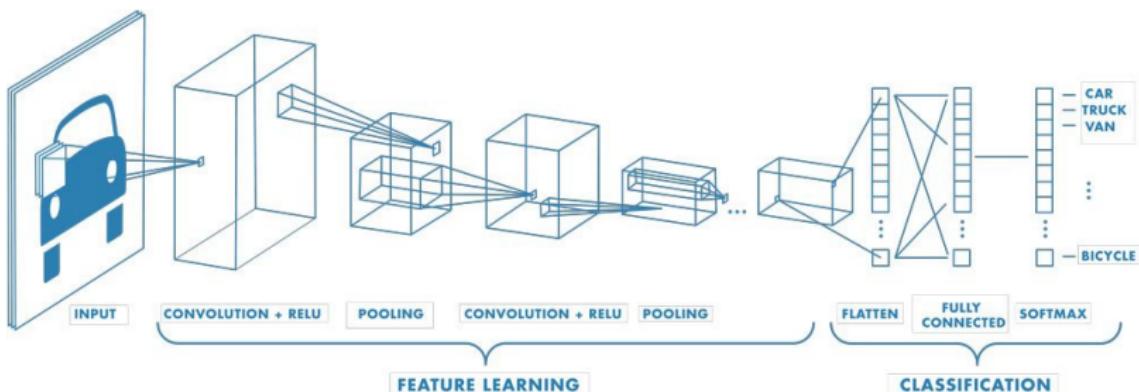
## Úvod do konvolučních neuronových sítí

- ① Operace konvoluce
- ② Konvoluční vrstva
- ③ Architektura konvoluční neuronové sítě
- ④ Známé modely konvolučních neuronových sítí (úvod)

## Dnes

- Známé modely konvolučních neuronových sítí (dokončení)
- Učení konvolučních neuronových sítí: přenesené učení, regularizace, předzpracování dat
- Varianty a aplikace konvolučních neuronových sítí (jen přehled)

# Architektura konvoluční neuronové sítě



## Části konvoluční neuronové sítě

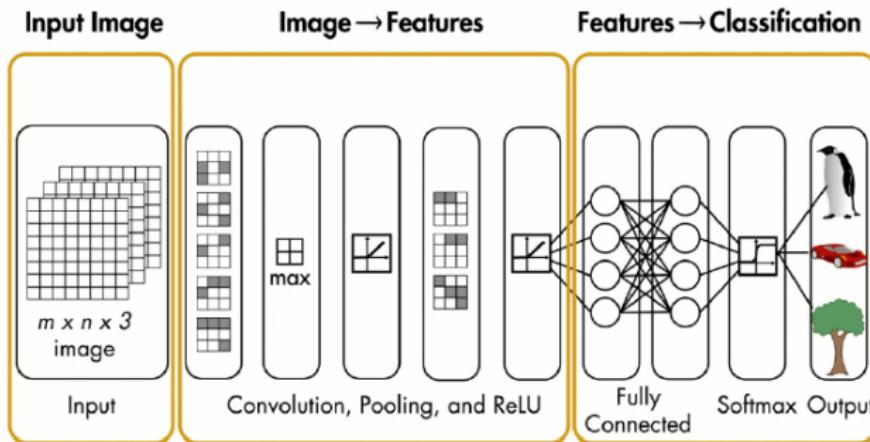
- Konvoluční vrstvy pro extrakci příznaků
- Flattening vrstva - převede data na vektor čísel
- Vrstevnatá neuronová síť pro klasifikaci

Zdroj :

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



# 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>

# Učení konvoluční neuronové sítě

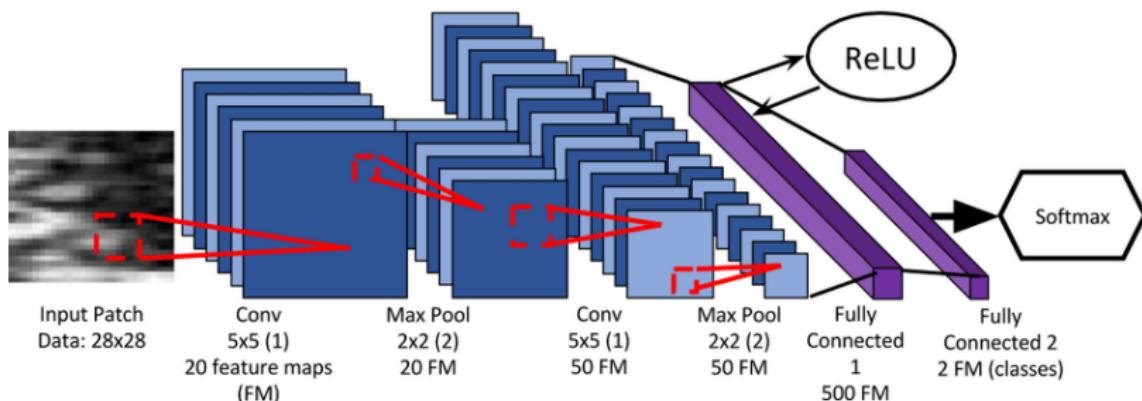
- nějaká varianta algoritmu zpětného šíření (např. SGD)
- mini-batch učení, model potřebuje k naučení větší množství dat
- velké množství parametrů

## Jak zvolit vhodnou architekturu v praxi?

- neoptimalizujeme počet vrstev a neuronů
- vybereme z dostupné literatury topologii osvědčenou pro daný typ problému

# LeNet 5

- jedna z původních architektur (Yann LeCun, 1998), poměrně jednoduchá



Zdroj obrázku: M. H. Yap et al., "Automated Breast Ultrasound Lesions Detection Using Convolutional Neural Networks," in IEEE Journal of Biomedical and Health Informatics, vol. 22, 2018.

# LeNet 5

## Datová sada MNIST

- Oblíbená benchmarková datová sada pro porovnávání různých modelů (přesnost klasifikace)  
<http://yann.lecun.com/exdb/mnist/>
- 60000 označkovaných trénovacích obrázků ručně psaných číslic, 10000 testovacích (od jiných lidí)
- obrázky 28x28, vycentrované a normalizované na danou velikost
- LeNet 5 dosáhla na MNIST chyby 0,8%

0 0 0 0 0 0 0 0 0  
1 1 1 1 1 1 1 1  
2 2 2 2 2 2 2 2  
3 3 3 3 3 3 3 3  
4 4 4 4 4 4 4 4  
5 5 5 5 5 5 5 5  
6 6 6 6 6 6 6 6  
7 7 7 7 7 7 7 7  
8 8 8 8 8 8 8 8

# 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

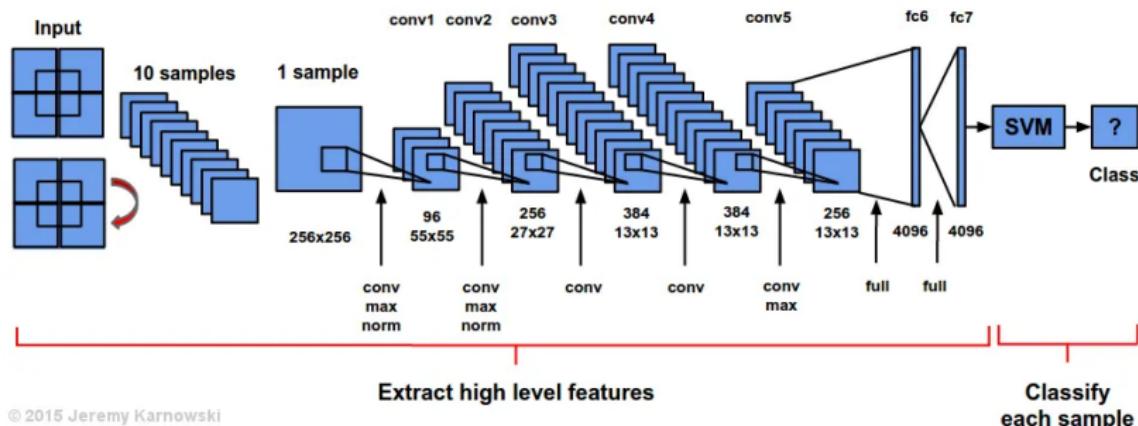


Zdroj obrázku:

[https://cs.stanford.edu/people/karpathy/cnnembed/cnn\\_embed\\_full\\_1k.jpg](https://cs.stanford.edu/people/karpathy/cnnembed/cnn_embed_full_1k.jpg)

# AlexNet

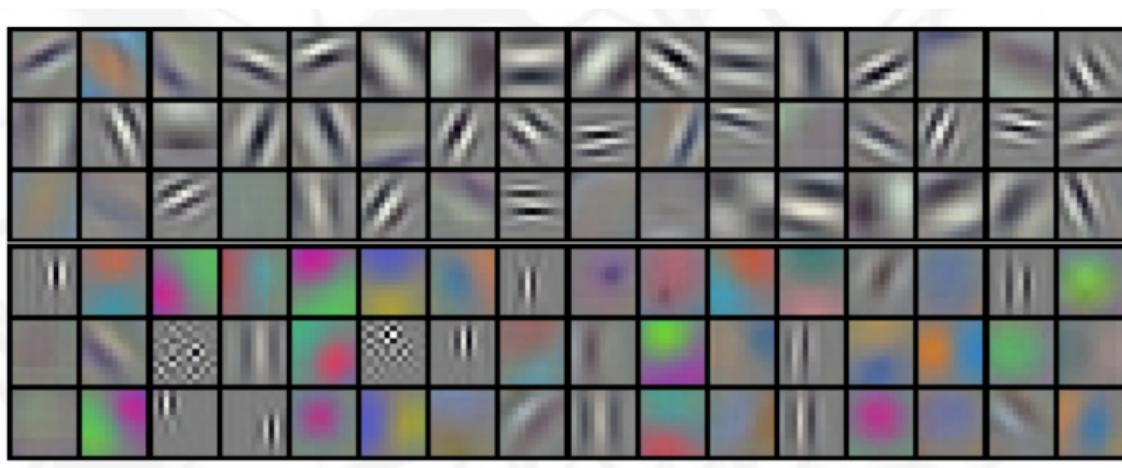
- Alex Krizhevsky, Ilya Sutskever, and Geoffrey Hinton (vítěz soutěže ILSVRC 2012 - úspěšnost 84,7 % v top-5),
- již výrazně složitější (61M parametrů, 2 GPU 5-6 dnů)



Zdroj obrázku: <https://medium.com/@jkarnows/alexnet-visualization-35577e5dc1a>

# AlexNet

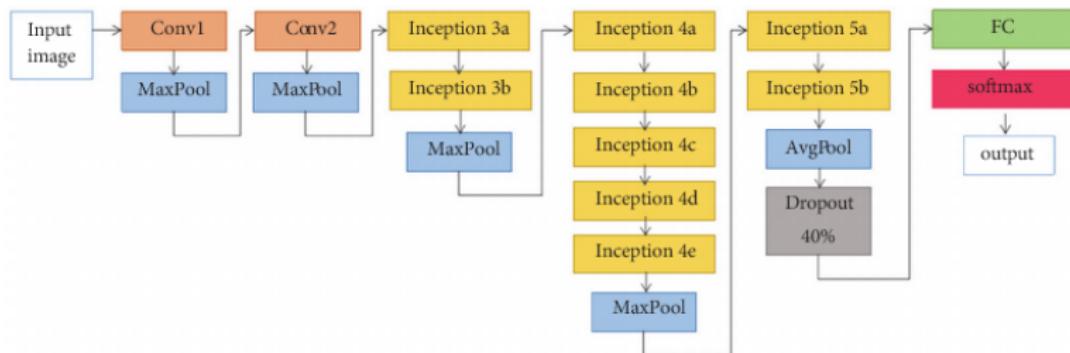
- 96 filtrů  $11 \times 11 \times 3$  v první konvoluční vrstvě u AlexNet



Zdroj obrázku: Alex Krizhevsky et al.: "ImageNet Classification with Deep Convolutional Neural Networks", Figure 3

# GoogLeNet (Inception v1), 2014

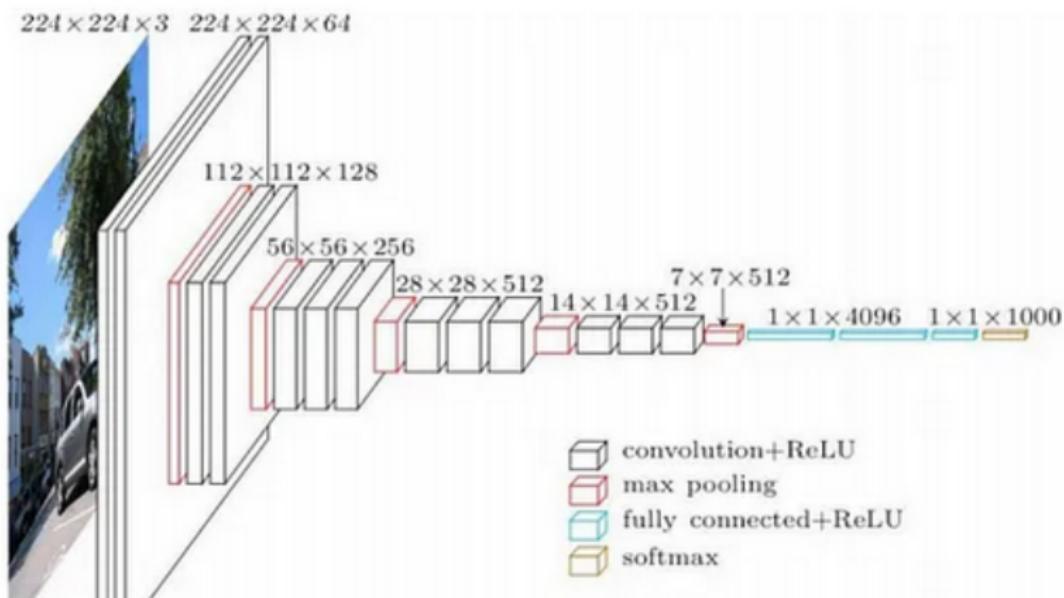
- vitěz soutěže ILSVRC 2014 - úspěšnost 93,33 % v top-5



Zdroj obrázku: Zhang, Keke et. al.'s: Can Deep Learning Identify Tomato Leaf Disease?. Advances in Multimedia. 2018.

# VGGNet

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



## Další populární architektury

- ResNet (Residual Network, 2015) - zavádí skip connections (řeší problém tiché pošty), vítěz ILSVRC 2015
- Inception v2, v3 (2015, 2016)
- DenseNet: (Gao Huang, 2016)
- MobileNet (Google, 2017), EfficientNet (2019)- úspora výpočetních prostředků
- NASNet (Neural Architecture Search Network, 2017) - model se naučil vhodnou architekturu sám, genetické algoritmy, reinforcement learning
- EfficientNet, 2019
- SqueezeNet
- ...

## Další populární benchmarkové datové sady

### CIFAR-10, CIFAR-100

<https://www.cs.toronto.edu/~kriz/cifar.html>

- CIFAR-10: 60000 barevných obrázků, 10 tříd (auta, psi, lodě,...)
- CIFAR-100: 100 tříd
- malé obrázky, dataseta populární pro rychlé testování a porovnání modelů

### COCO (Common Objects in Context)

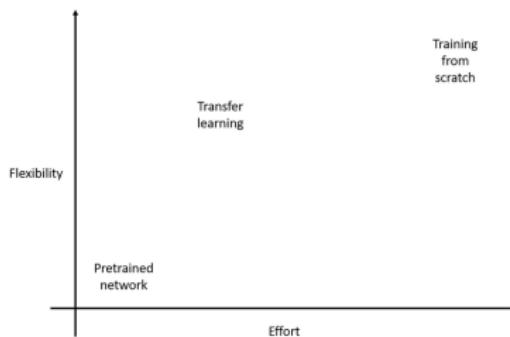
- detekce objektů, segmentace a popis obrázků

COCO 2020 Panoptic Segmentation Task



# Možnosti vytvoření a učení konvolučních neuronových sítí

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

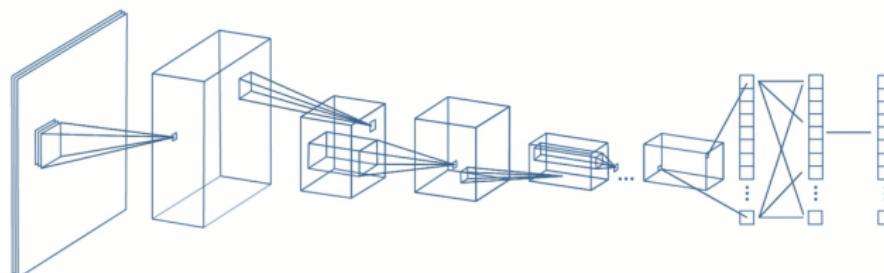


Zdroj :

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

## Přenesené učení (transfer learning)

- naučený model klasifikuje do 1000 tříd:

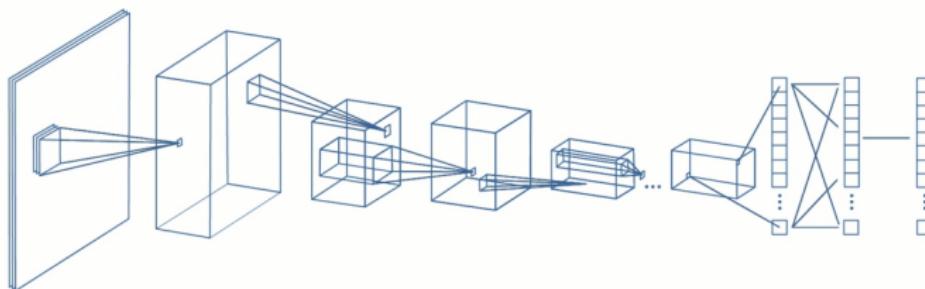


Zdroj :

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

## Přenesené učení (transfer learning)

- je třeba klasifikovat do trochu jiných tříd:

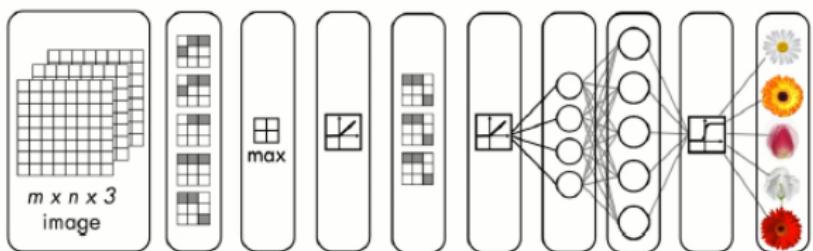
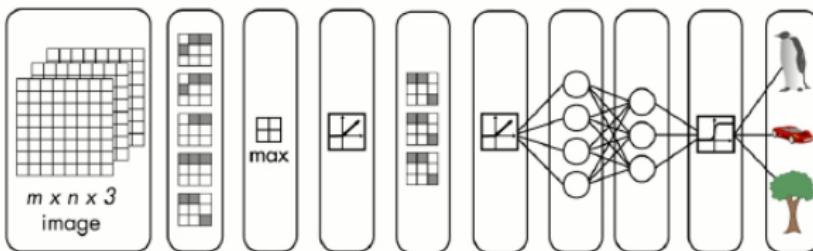


Zdroj :

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

# Přenesené učení (transfer learning)

- nahradíme klasifikační část neuronové sítě a naučíme ji na nových datech (váhy předchozích vrstev zafixujeme)

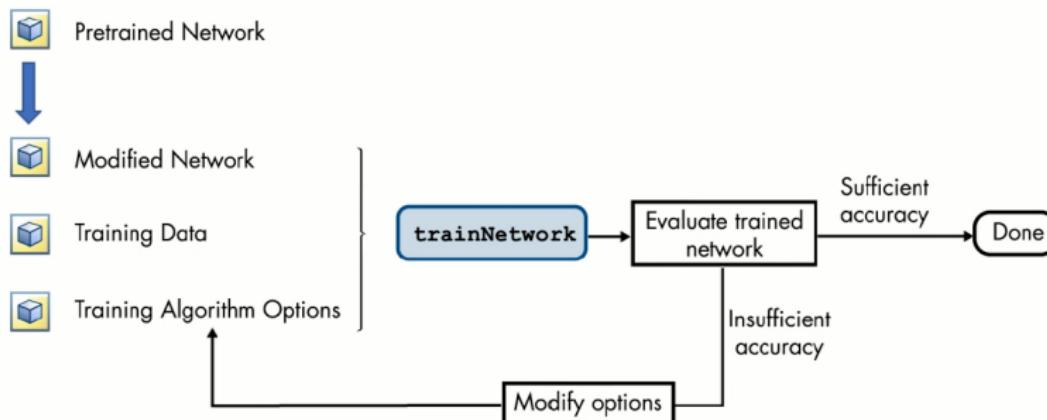


Zdroj :

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

# Přenesené učení (transfer learning)

Proces přeneseného učení je iterativní



Zdroj :

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

## Přenesené učení (transfer learning)

Lze využít celou řadu modelů předučených na ImageNet (popř. na jiných datových sadách, např. audio záznamy)

- AlexNet, 224x224x3
- GoogleNet, 227x227x3
- ResNet, 227x227x3
- ...

(podívejte se na další modely dostupné v Deep Network Designeru)

## Přenesené učení a předpracování dat

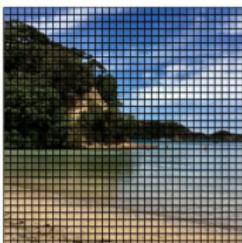
- data je třeba převést na požadovanou velikost (není možné měnit první vrstvu sítě!)



# Přenesené učení a předpracování dat

- data je třeba převést na požadovanou velikost (není možné měnit první vrstvu sítě!)

224



224

224



224

224



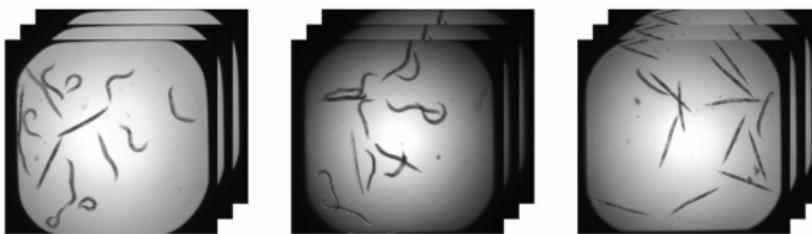
224

Zdroj :

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

# Přenesené učení a předpracování dat

- černobílé obrázky je třeba převést na 3 kanály

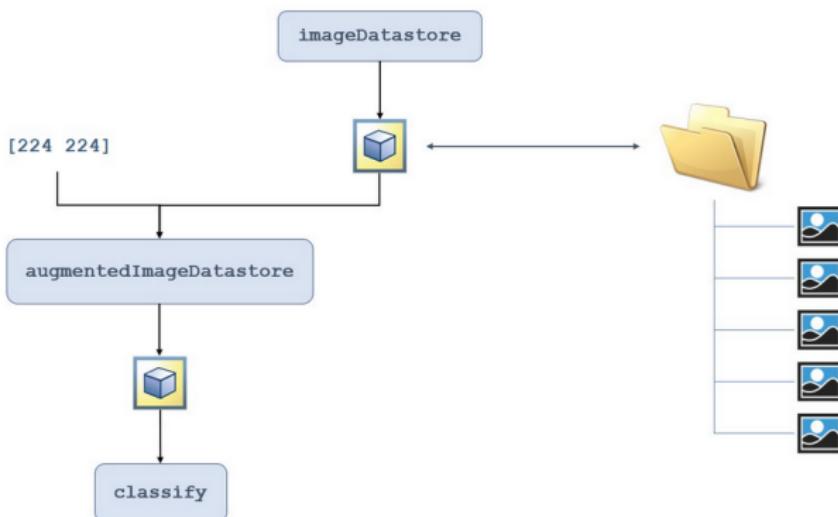


Zdroj :

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

## Přenesené učení a předpracování dat

- v Matlabu se o základní předzpracování dat postará rozšířený DataStore



Zdroj :

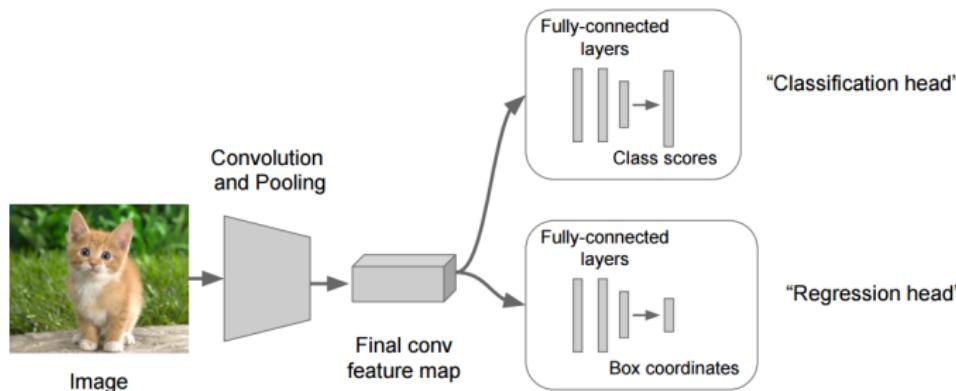
<https://matlabacademy.mathworks.com/details/deep-learning-onramp/deeplearning>

# 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 celý model (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
  - ...



## 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>

# Konvoluční neuronová síť a regularizace

- konvoluční sítě mohou být náchylné k přeúčení (obzvlášt' pokud použijeme přenesené učení a nebo finetuning a máme k dispozici jen poměrně malé množství dat)
- učení může být dost pomalé  
→ regularizační techniky

# Konvoluční neuronová síť a regularizace

## Regularizační techniky rozšiřující model

- early stopping
- L2-regularizace

$$E_n = \beta E + (1 - \beta) \frac{1}{2} \|\vec{w}\|_2^2 = \beta E + (1 - \beta) \sum_i w_i^2$$

- dropout (zhuštěný ensemble learning)
- normalizace

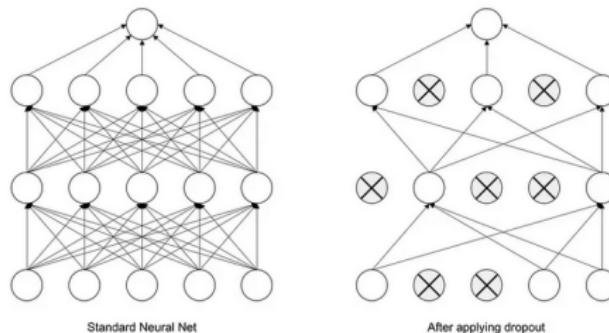
## Regularizace a data

- augmentace (rozšíření) dat

## Konvoluční neuronová síť a regularizace

## Dropout

- spočívá v náhodném vypínání (deaktivování) některých skrytých neuronů během učení
  - při testování jsou všechny neurony aktivované
  - má smysl u plně propojených vrstev
  - přidává se speciální dropout vrstva

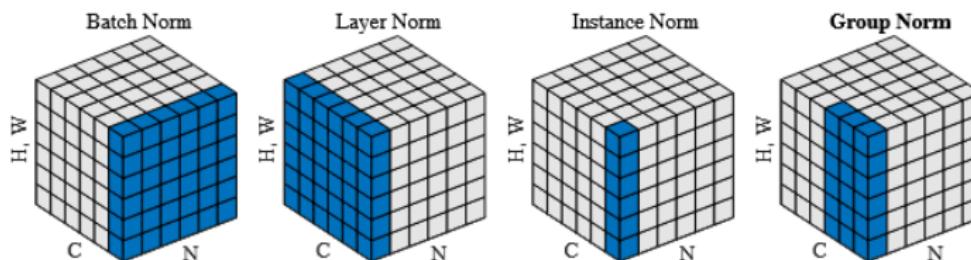


Srivastava, Nitish, et al. "Dropout: a simple way to prevent neural networks from overfitting". JMLR 2014

# Konvoluční neuronová síť a regularizace

## Normalizace vstupů jednotlivých vrstev

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

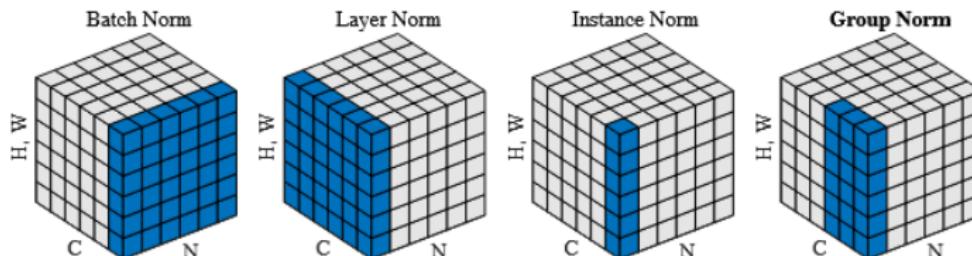


Wu, Y., et al. "Group Normalization", <https://arxiv.org/pdf/1803.08494.pdf>

# Konvoluční neuronová síť a regularizace

## Normalizace vstupů jednotlivých vrstev

- implementováno pomocí přidání další vrstvy (např. zakonvoluční vrstvu)
- rychlejší učení, menší citlivost na inicializaci vah
- obdobná technika: **weight normalization**
- robustnost k šumu v datech (nahradí Dropout)
- nevhodné pro rekurentní síť



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

# Konvoluční neuronová síť a regularizace

## Augmentace dat

- různé (náhodné) transformace obrazu (rotace, posun, zrcadlení, zešikmení, měna rozlišení, změna jasu a kontrastu, oříznutí, přidání šumu, blur, kombinace)

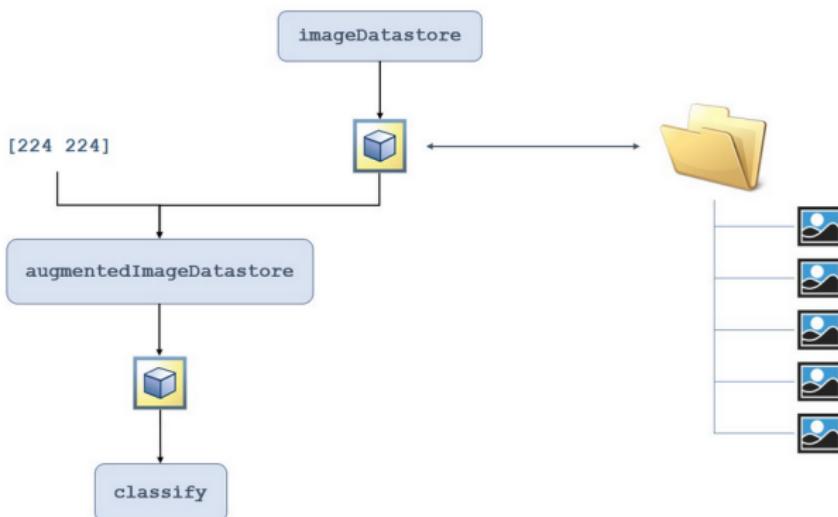


Zdroj :

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

# Augmentace dat

- v Matlabu se o základní předzpracování dat postará rozšířený DataStore

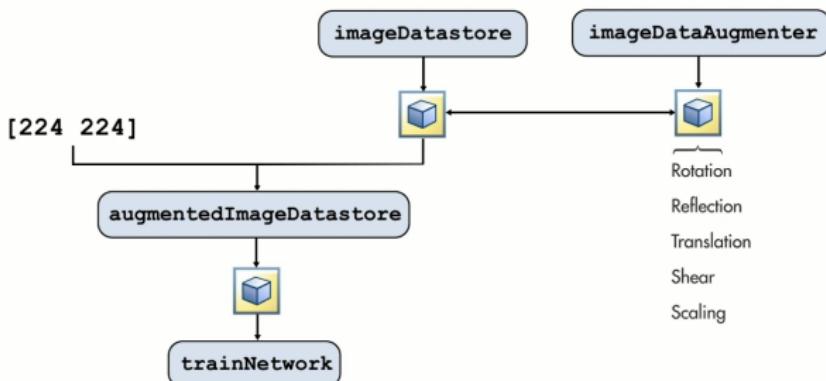


Zdroj :

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

# Augmentace dat

- v Matlabu se o základní předzpracování dat postará rozšířený DataStore

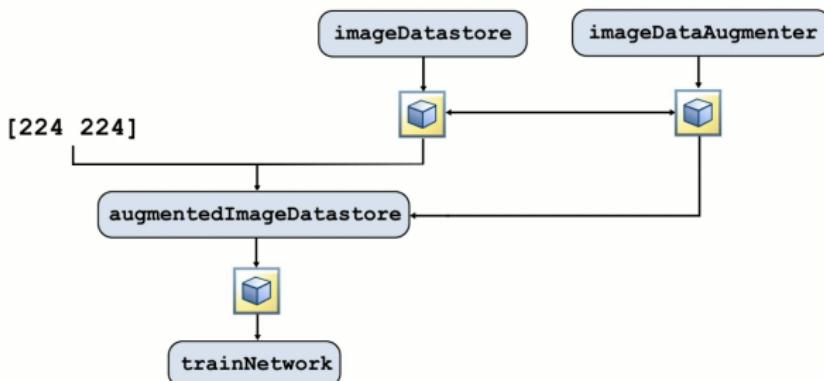


Zdroj :

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

# Augmentace dat

- v Matlabu se o základní předzpracování dat postará rozšířený DataStore



Zdroj :

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

# Výhody a nevýhody konvolučních neuronových sítí

- ušité na míru datům, která jsou uspořádaná do mřížky
- invariance vůči posunutí, velikosti, odstínu,...
- robustní k šumu v datech
- výpočetně náročné učení, vyžaduje velké množství dat, GPU
- nebezpečí přeúčení → regularizace
- adversarial examples

# Konvoluční neuronové sítě - implementační detaily

- obvykle stačí velikost filtru  $3 \times 3$
- často se kombinuje  $2 \times 2$  max-pooling spolu s tím, že se v každé vrstvě zdvojnásobuje počet kanálů
- pokud použijeme více konvolučních vrstev, nepotřebujeme větší počet plně propojených vrstev
- mezi regularizačními technikami je nejoblíbenější batch normalizace spolu s (mírnou) L2-regularizací na konvolučních vrstvách

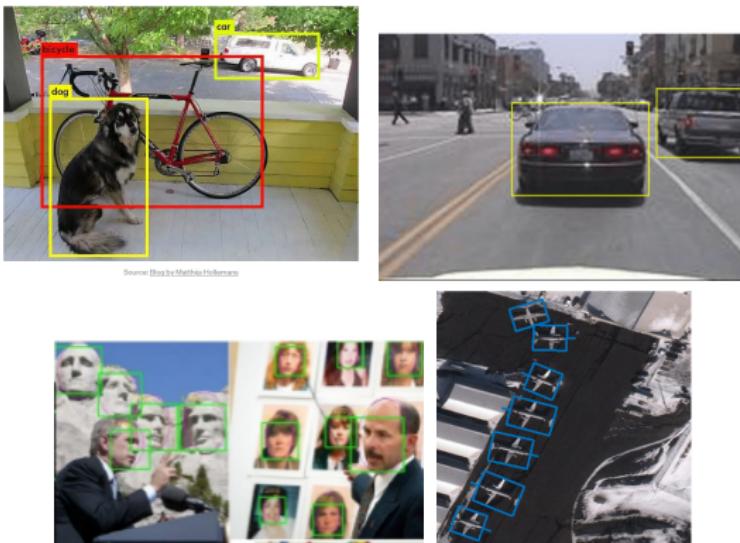
# Aplikace konvolučních neuronových sítí

- klasifikace obrázků
- detekce objektů - místo klasifikační části detekční hlava
- segmentace obrazu
- analýza videa
- sekvenční data (časové řady - 1D konvoluce, audio data, přirozený jazyk)

**Příklad regrese: predikce sklonu číslic**



# Aplikace konvolučních neuronových sítí - detekce objektů



Zdroj : <https://matlabacademy.mathworks.com>

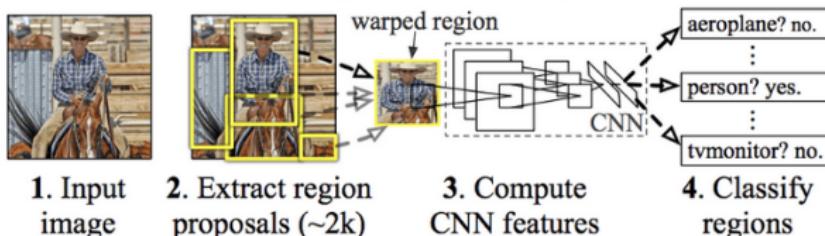
Triantafyllidou, D. et all: A Fast Deep Convolutional Neural Network for Face Detection in Big Visual Data.

# Aplikace konvolučních neuronových sítí - detekce objektů

## R-CNN (Region-based Convolutional Neural Network)

- ① obrázek je rozdělen na různé oblasti (ROI) pomocí algoritmu selektivního hledání
  - ② každá oblast je zvětšena na stejnou velikost a předložena předučené konvoluční neuronové síti (VGG-16 v původním článku).
  - ③ Nakonec jsou použity dvě hlavy': klasifikátor pro klasifikaci každé oblasti a regresor pro doladění jeho hranic.

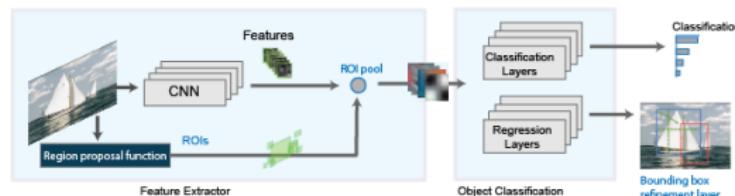
### R-CNN: *Regions with CNN features*



# Aplikace konvolučních neuronových sítí - detekce objektů

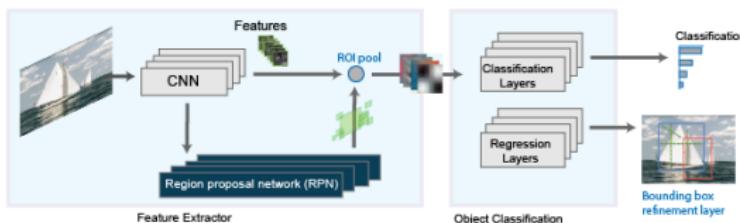
## varianta: fast R-RCNN

- rychlejší výpočet díky sdílení příznaků mezi oblastmi zájmu (ROI - region of interest)



## varianta: faster R-RCNN

- automatické rozpoznávání ROI uvnitř modelu



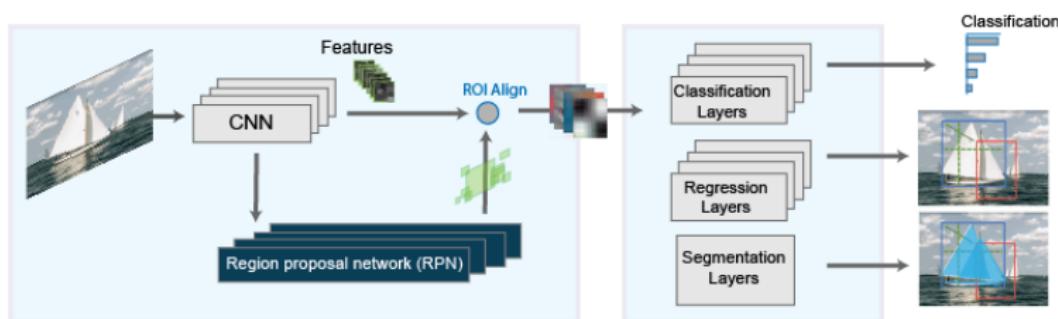
# Aplikace konvolučních neuronových sítí - segmentace obrazu



Zdroj : He et all., Mask R-CNN, 2017, Figure 2, <https://arxiv.org/abs/1703.06870>

# Aplikace konvolučních neuronových sítí - segmentace obrazu

- rozšíření Faster R-CNN o další větev pro přesnou segmentaci objektu na úrovni pixelů



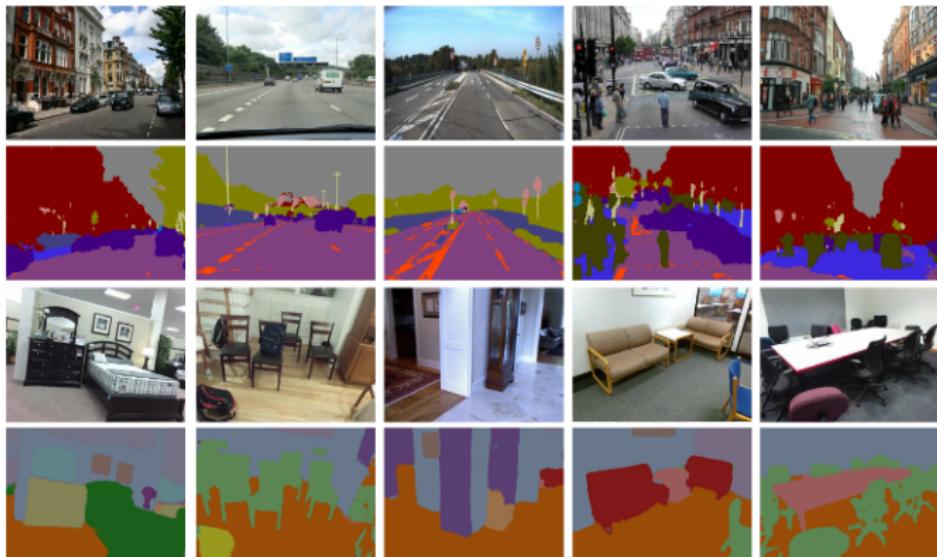
Zdroj : <https://www.mathworks.com/help/vision/ug/getting-started-with-mask-r-cnn-for-instance-segmentation.html>

# Aplikace konvolučních neuronových sítí - human pose estimation



Zdroj : He et all., Mask R-CNN, 2017, Figure 7, <https://arxiv.org/abs/1703.06870>

# Aplikace konvolučních neuronových sítí - sémantická segmentace

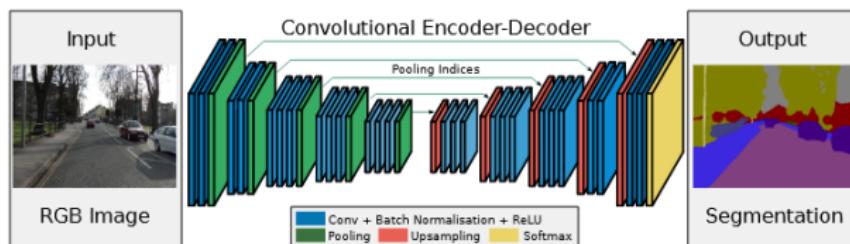


Zdroj : SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation <https://arxiv.org/pdf/1511.00561>

# Aplikace konvolučních neuronových sítí - sémantická segmentace

## SegNet

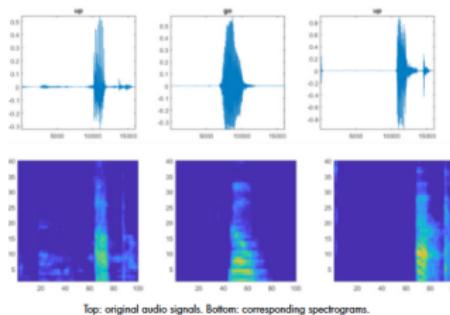
- enkodér-dekodér architektura
- enkodér: klasická CNN
- dekodér: obnovuje obrázek do původních rozměrů: transponované konvoluční vrstvy a unpooling vrstvy



Zdroj : SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation <https://arxiv.org/pdf/1511.00561.pdf>

## Další aplikace konvolučních neuronových sítí

- analýza videa - 3D CNN
- sekvenční data
  - audio data (např. převod na obrázek - vstupem je spektrogram)
  - časové řady - učení na historických datech, 1D konvoluce
  - zpracování přirozeného jazyka (např. je vstupem embedding matice)



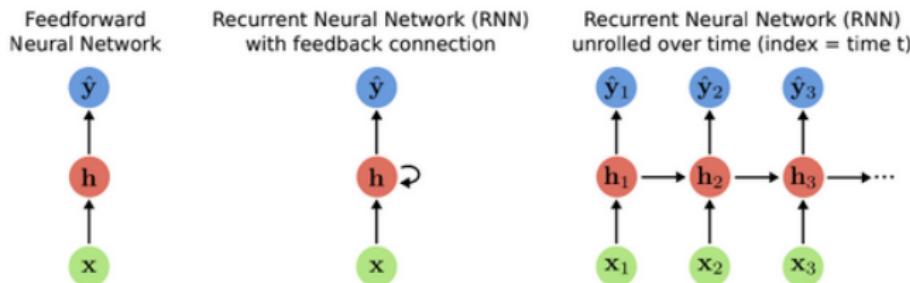
Zdroj : <https://www.mathworks.com/content/dam/mathworks/ebook/gated/deep-learning-practical-examples-ebook.pdf>

## Zajímavé odkazy

- vizualizace konvoluční neuronové sítě  
<https://poloclub.github.io/cnnexplainer/>
- Matlab onramp kurzy k hlubokému učení  
<https://matlabacademy.mathworks.com/#ai>  
<https://matlabacademy.mathworks.com/details/deep-learning-with-matlab/mldl>

# Rekurentní neuronová síť a zpracování posloupností

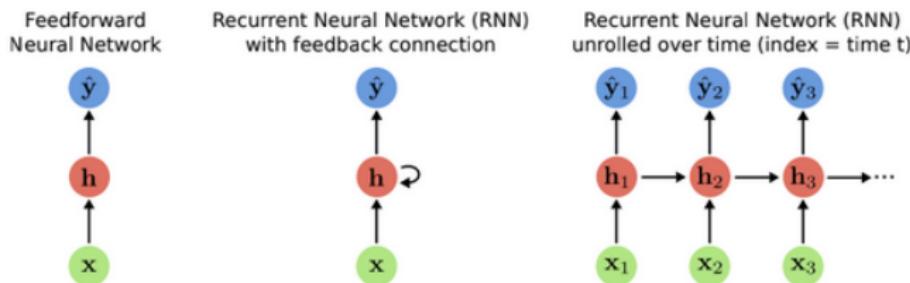
## Jednoduchá rekurentní síť



- myšlenka: neuron si udržuje svůj vnitřní stav:  $h_t = f_h(h_{t-1}, x_t)$
- výstup neuronu:  $y_t = f_y(h_t)$
- je možné zpracovat posloupnosti libovolné délky
- $f_y, f_h$  se v čase nemění

# Rekurentní neuronová síť a zpracování posloupností

## Jednoduchá rekurentní síť



- vnitřní stav:  $h_t = \tanh(W_h h_{t-1} + W_x x_t + b_h)$
- výstup neuronu:  $y_t = W_y h_t + b_y$
- obvyklá přenosová funkce je tanh
- váhy a prahy  $W, b$  se v čase nemění

# Rekurentní neuronová síť a zpracování posloupností

## Typy úloh nad sekvenčními daty

- one-to-one - např. obyčejná klasifikace
- many-to-one - např. klasifikace sentimentu, rozpoznání akce na videu
- one-to-many - např. vygenerovat slovní popis k obrázku
- many-to-many - strojový překlad, object tracking

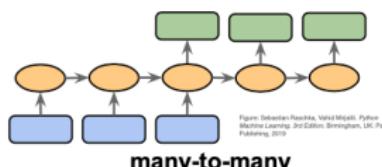
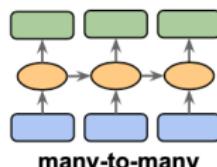
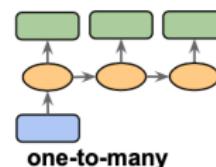
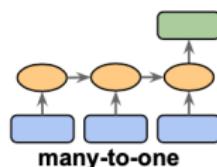
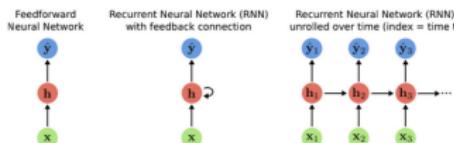


Figure: Sebastian Raschka, Vahid Mirjalili, Python Machine Learning, 3rd Edition, Birmingham, UK: Packt Publishing, 2019.

# Rekurentní neuronová síť a zpracování posloupností

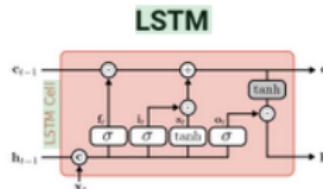
## Algoritmus učení: backpropagation through time (BPTT)



- pro celou sekvenci najednou

## Známé modely RNN

- LSTM (Long Short Term Memory)
- GRU (Gated recurrent unit)



Hochreiter, 1997