

Základy umělé inteligence

CORE042: Data – odpověď na základní otázku života, vesmíru a vůbec...

4. přednáška

Michal Bozděch <michal.bozdech@fsps.muni.cz>

Katedra tělesné výchovy a společenských věd

Fakulta sportovních studií

Základy umělé inteligence

Definice

Umělá inteligence

- Artificial intelligence, AI

Jakákoliv technika, která umožňuje strojům myslet a rozhodovat se jako člověk, bez jeho zásahů

Narrow AI → Generativní AI → Super AI

Strojové učení

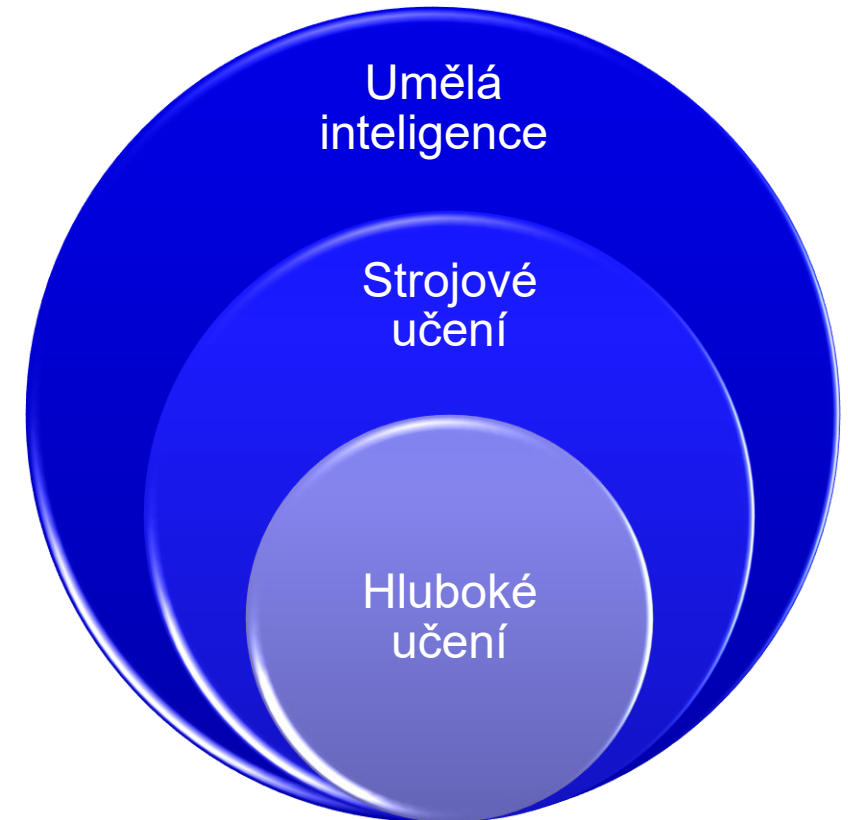
- Machine learning, ML

Pro naučení (např. vzorce chování) používá statistické techniky (algoritmy)

Hluboké učení

- Deep learning, DL





Skládající se z algoritmů, které umožňují softwaru trénovat se (přes několik vrstev), aby vykonával úkoly



Základy umělé inteligence

Nejpoužívanější typy programů/jazyka

- Python
- SQL
- Java
- R
- SAS
- C++
- TensorFlow
- MATLAB
- SPSS



MUNI

Základy umělé inteligence

Preference zaměstnavatelů

Minimálně bakalářský titul


Obor není důležitý

Online portfolio

Coursera, ukázka dovedností

Schopnost samoučení

Zkušenosti a znalosti z oblasti





Mobilní aplikace sledující pohybovou činnost

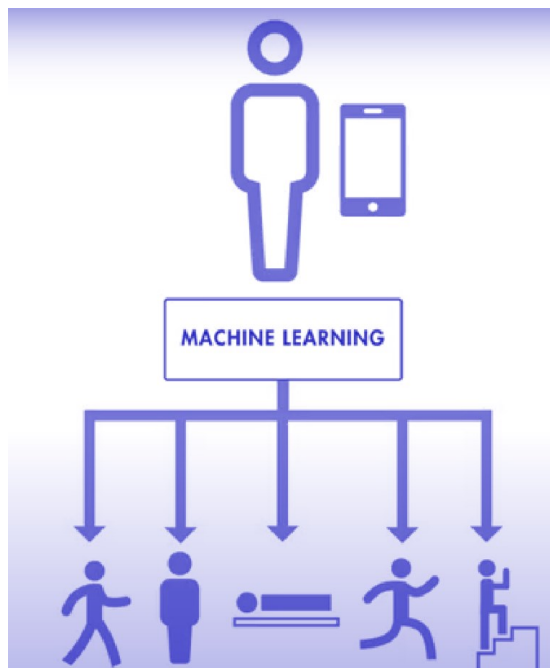
- S jakými typy dat pracujeme?
- Co chceme zjistit?
- Jak to chceme použít?
- ...





Základy umělé inteligence

Mobilní aplikace sledující pohybovou činnost (ukázka)



S jakými typy dat pracujete?

- *Senzory v mobilu (akcelerometr, gyroskop, ...)*

Co chcete zjistit?

- *Prováděnou činnost (chůze, běh, ležení, ...)*

Jak to chcete použít?

- *Sledování denní činnosti*

Základy umělé inteligence

Mobilní aplikace sledující pohybovou činnost (ukázka)

1. **Přístup** a nahrání dat
2. **Předzpracování** dat
3. **Odvodit** vlastnosti pomocí předzpracovaných dat
4. **Trénink** modelu
5. **Iterujte**, abyste našli nejlepší model
6. **Integrujte** nejlépe vytrénovaný model do produkčního systému






Základy umělé inteligence

Mobilní aplikace sledující pohybovou činnost (ukázka)

1. **Přístup** a nahrání dat: Typy dat ze senzorů (txt nebo CSV) do softwaru
2. **Předzpracování**
3. **Odvodit**
4. **Trénink**
5. **Iterujte**
6. **Integrujte**






Základy umělé inteligence

Mobilní aplikace sledující pohybovou činnost (ukázka)

1. **Přístup**
2. **Předzpracování dat:** Hledáme chybějící data nebo extrémní hodnoty (outliers), či vliv gravitace (pomocí signal processing techniques)
3. **Odvodit**
4. **Trénink**
5. **Iterujte**
6. **Integrujte**



Základy umělé inteligence

Mobilní aplikace sledující pohybovou činnost (ukázka)

1. **Přístup**

2. **Předzpracování**


3. **Odvodit vlastnosti pomocí předzpracovaných dat:**

4. **Trénink**

5. **Iterujte**

6. **Integrujte**

- Nejdůležitější část (raw data → informace)
- Množství sledovaných vlastností není omezené
- Pro některé vlastnosti existují vhodnější metody



Chůze

Běh






Základy umělé inteligence

Mobilní aplikace sledující pohybovou činnost (ukázka)

1. **Přístup**
2. **Předzpracování**
3. **Odvodit**
4. **Trénink modelu:**
5. **Iterujte**
6. **Integrujte**

Začít jednodušší technikou/modelem, která je rychlá a jednoduchá na interpretaci (Decision tree)





Základy umělé inteligence

Mobilní aplikace sledující pohybovou činnost (ukázka)

1. **Přístup**
2. **Předzpracování**
3. **Odvodit**
4. **Trénink modelu:**
5. **Iterujte**
6. **Integrujte**

Abychom zjistili jak dobře technika/model funguje použijeme klasifikační matici (confusion matrix)

Decision tree

Sitting	>99%	<1%			
Standing	<1%	99%	<1%		
Walking		<1%	>99%	<1%	
Running			1%	93%	5%
Dancing		<1%	<1%	40%	9%
	Sitting	Standing	Walking	Running	Dancing

Základy umělé inteligence

Mobilní aplikace sledující pohybovou činnost (ukázka)



1. Přístup
2. Předzpracování
3. Odvodit
4. Trénink modelu:
5. Iterujte
6. Integrujte

Abychom zjistili jak dobře technika/model funguje použijeme klasifikační matici (confusion matrix)

Decision tree

Sitting	>99%	<1%			
Standing	<1%	99%	<1%		
Walking		<1%	>99%	<1%	
Running			1%	93%	5%
Dancing		<1%	<1%	40%	56%
	Sitting	Standing	Walking	Running	Dancing

Multiclass Support Vector Machine

Sitting	>99%	<1%			
Standing	<1%	>99%	<1%		
Walking		<1%	>99%		
Running			<1%	98%	2%
Dancing			1%	3%	96%
	Sitting	Standing	Walking	Running	Dancing

Základy umělé inteligence


Mobilní aplikace sledující pohybovou činnost (ukázka)

1. **Přístup**
2. **Předzpracování**
3. **Odvodit**
4. **Trénink**
5. **Iterujte, abyste našli nejlepší model:**
6. **Integrujte**

Pokud model nerozpozná rozdíly mezi tancem a během musíme zdokonalit model

(a) *jednodušší* model (vyhnout se overfitting)

(b) přidání *komplexnost* za účelem zvýšení přesnosti (kombinace dvou vlastnosti)




Základy umělé inteligence



1. **Přístup**
2. **Předzpracování**
3. **Odvodit**
4. **Trénink**
5. **Iterujte**
6. **Integrujte nejlépe vytrénovaný model do produkčního systému:**





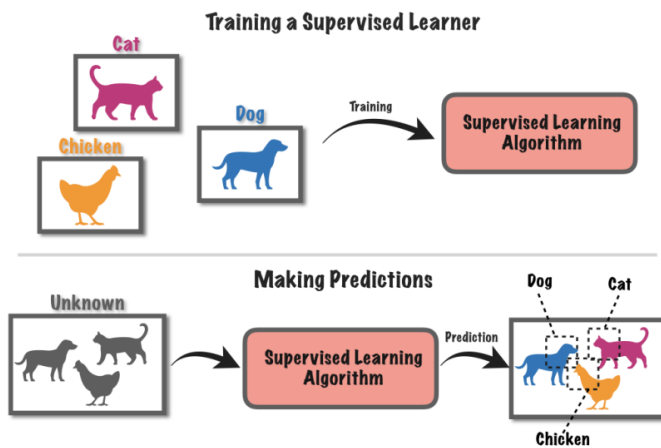


Základy umělé inteligence

Typy strojového učení



Supervised learning

- učení pod dozorem





Unsupervised learning

- učení bez dozoru



Reinforcement learning

- zpětnovazební učení



Základy umělé inteligence

Přehled klasifikace vybraných technik

Učení pod dozorem

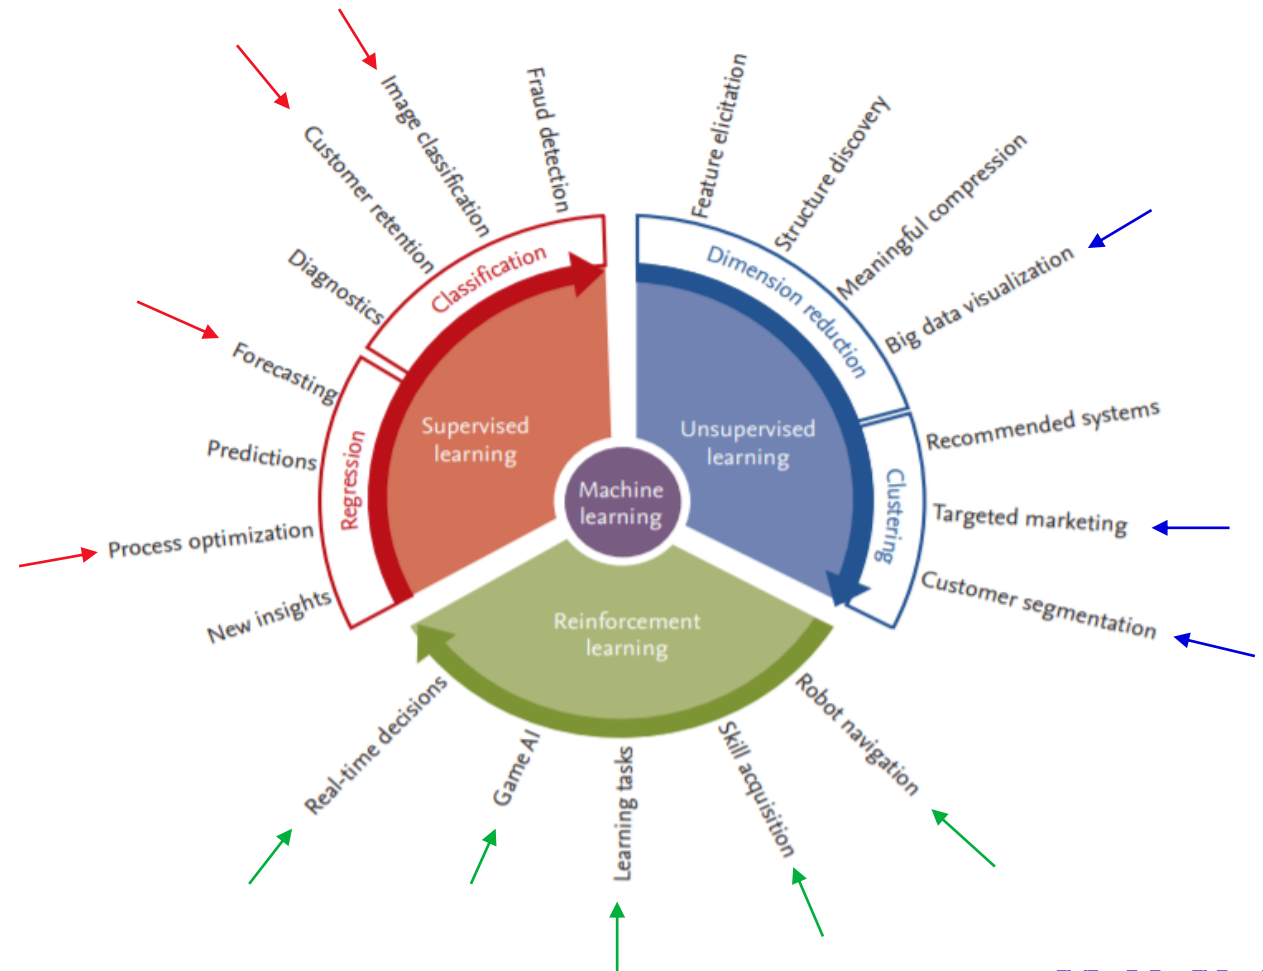
- Klasifikační
 - Klasifikace obrázku (příklad 1)
 - Udržení zákazníků (příklad 2)
- Regresní
 - Předpovídání (příklad 3)
 - Optimalizace procesu (příklad 4)

Učení bez dozoru

- Redukce dimenzí
 - Big data vizualizace (příklad 5)
- Shlukování
 - Cílený marketing (příklad 6)
 - Segmentace zákazníků (příklad 7)

Zpětnovazební učení

- *Překvapení*




Základy umělé inteligence

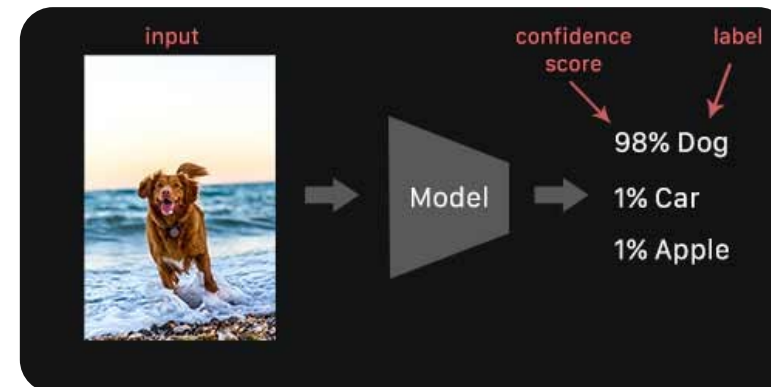
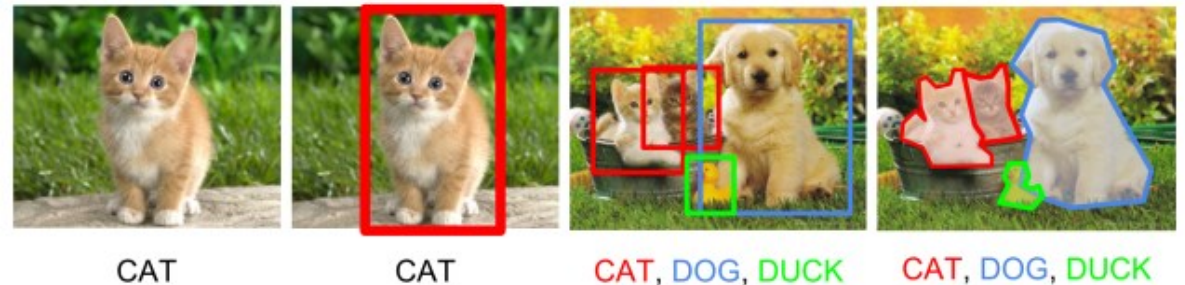
(1) Učení pod dozorem

Klasifikace obrázku

- Učí AI jak detekovat objekty na obrázku na základě jejich jedinečných vlastností



Klasifikace




Základy umělé inteligence

(1) Učení pod dozorem

Klasifikace

Udržení zákazníků

- Měří zákazníkovo loajalitu
aby neodcházel ke konkurenci, nebo
ho udržet v kontaktu s danou značkou




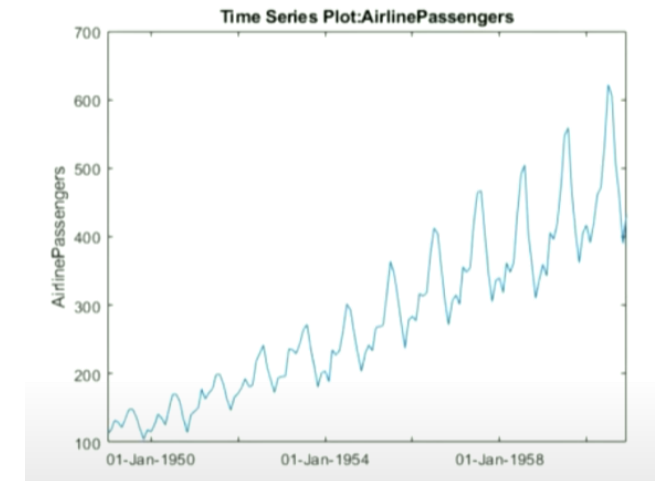
Základy umělé inteligence

(1) Učení pod dozorem

Regrese

Předpovídání (Forecasting)

- Chronologické testování/data
- Předpovídání nabídky a poptávky
- Vyrovnání sezónních výkyvů
- Uber vs. Události
koncerty, svátky, sportovní události, počasí = obchodní rozhodnutí



Základy umělé inteligence


(1) Učení pod dozorem

Regrese


Optimalizace procesu (Process Optimization)

– Cíl: najít nejlepší způsob

Požitek



Teplota (C / F)



Základy umělé inteligence


(2) Učení bez dozoru

Cílený marketing

- Poskytuje informace a pobídky

Shlukování (Clustering)

Proč se mi ukazují tyto reklamy?




Základy umělé inteligence

(2) Učení bez dozoru

Shlukování (Clustering)

Segmentace zákazníků

- Hlubší poznání zákazníků/segmentů pro prodejce
- Target (Andrew Pole) vs. Naštvaný otec



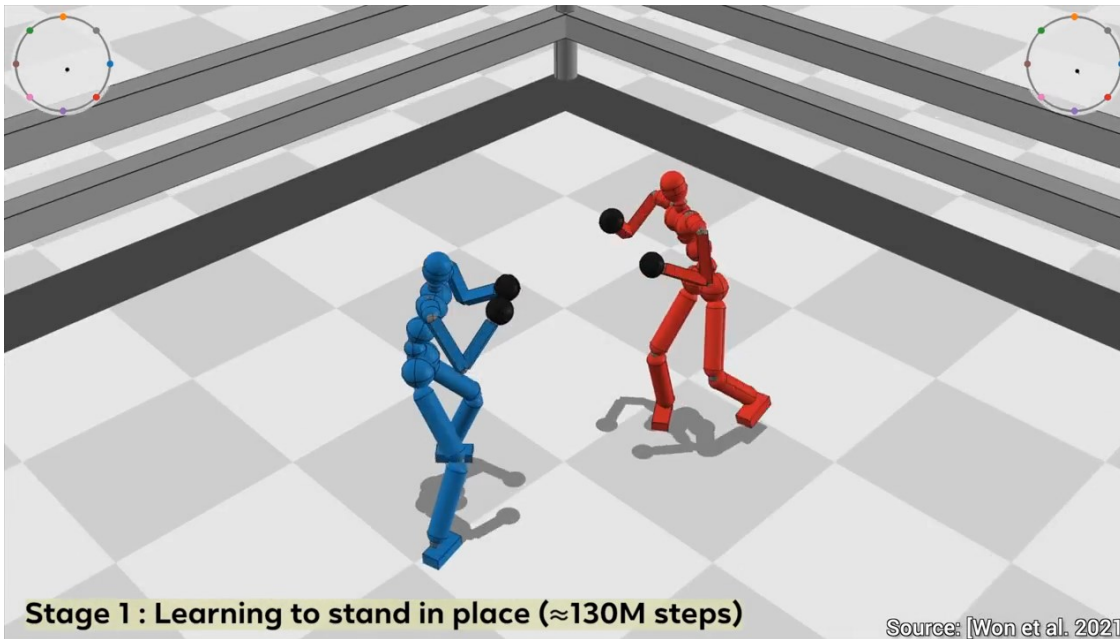
Základy umělé inteligence

(3) Zpětnovazební učení

Učení se nových dovedností

Simulace boxu

- Naučili se stát na místě
 - Přibližně 130milionů pokusů




Základy umělé inteligence

(3) Zpětnovazební učení

Učení se nových dovedností

Simulace boxu



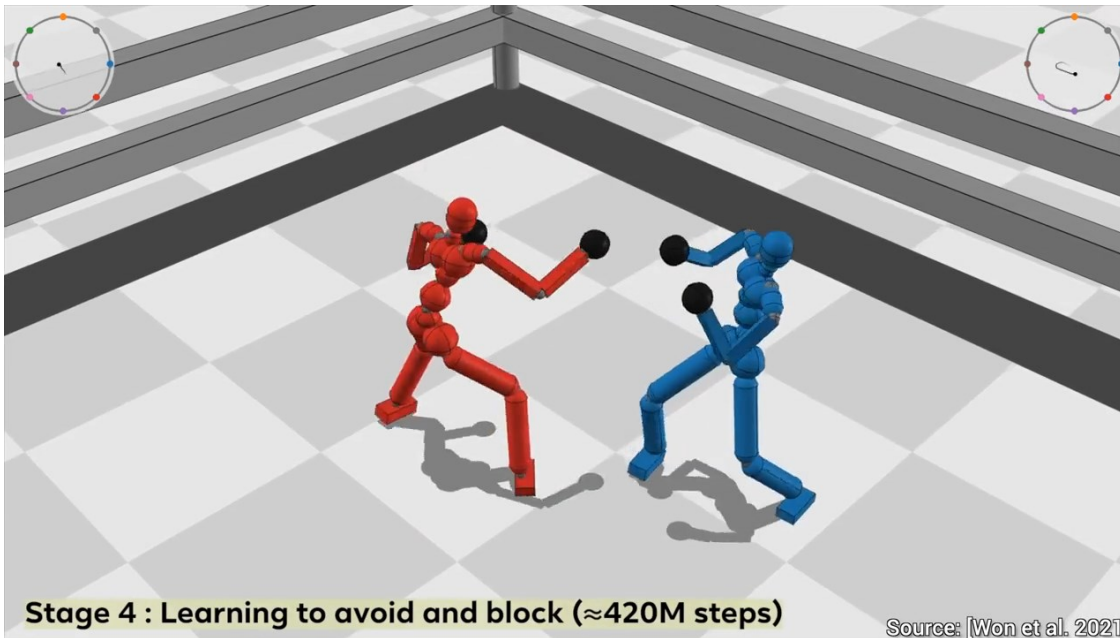
- Naučili se pohybovat
- První kontakt (odměna)
 - Přibližně 250milionů pokusů

Základy umělé inteligence

(3) Zpětnovazební učení

Učení se nových dovedností

Simulace boxu




- Naučili se dát ránu
- Vyhnout se kontaktu
- Přidat sílu do úderu
 - Přibližně 420milionů pokusů

Základy umělé inteligence

(3) Zpětnovazební učení

Učení se nových dovedností

Simulace boxu



– Finální boj


– Vstupní data: MoCap, 90sec

Základy umělé inteligence

(3) Zpětnovazební učení

Učení se nových dovedností


Simulace šermu



– Finální boj

Základy umělé inteligence

(3) Zpětnovazební učení



Učení se nových dovedností


– Zadání:

- Červený hledají modré
- Modrý nesmí být viděni červenými

– Chaos prvních pár milionů pokusů

Základy umělé inteligence

(3) Zpětnovazební učení



Učení se nových dovedností


– Zadání:

- Červený hledají modré
- Modrý nesmí být viděni červenými

- Modrý se naučili zablokovat červené pomocí krabice

Základy umělé inteligence

(3) Zpětnovazební učení



Učení se nových dovedností

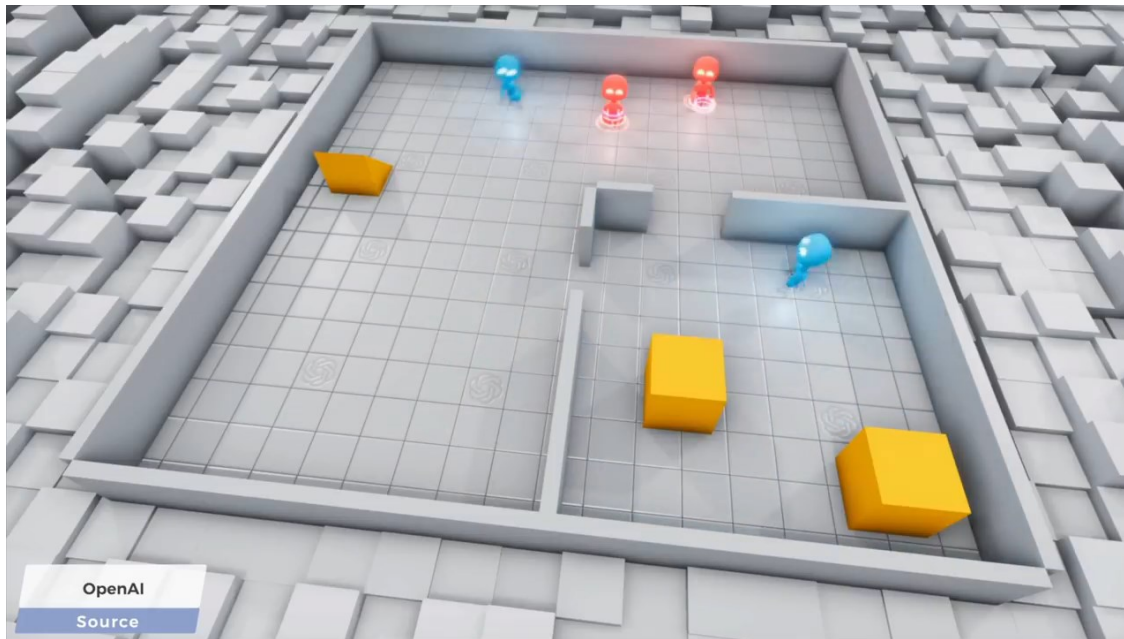
– Zadání:

- Červený hledají modré
- Modrý nesmí být viděni červenými

– Červený začali používat rampu

Základy umělé inteligence

(3) Zpětnovazební učení



Učení se nových dovedností

– Zadání:

- Červený hledají modré
- Modrý nesmí být viděni červenými

- Modrý zjistili, že červený jsou aktivováno později a mají čas schovat rampu

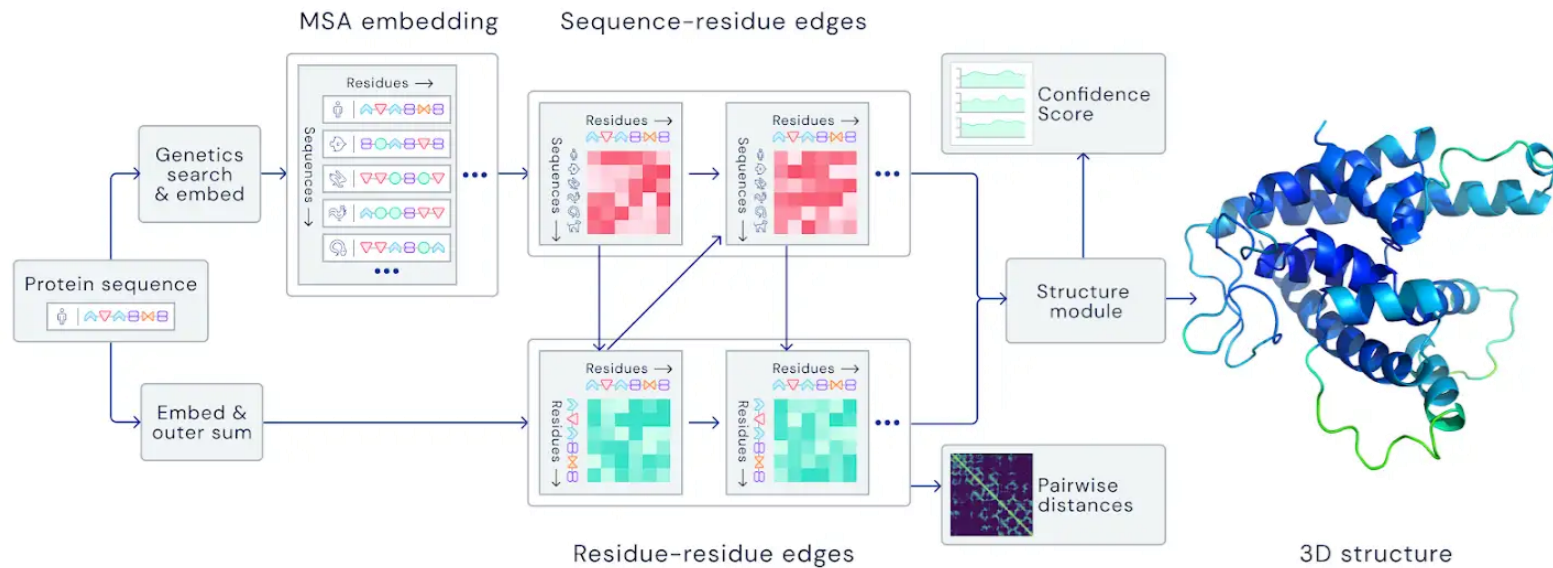
Základy umělé inteligence

(3) Zpětnovazební učení

Bonus

AlphaFold (DeepMind)

- AI program
- Predikce struktury proteinů pokud chybí data




Základy umělé inteligence

(3) Zpětnovazební učení

- Herní AI
- Rozhodovací algoritmus
 - Navigace
 - Obchodování na burze
 - Zdravotnictví (data – diagnostika)
- Učení se novým dovednostem
 - Jazykový překladáč
 - Optimalizace práce (automatizace)
- Přizpůsobování dané situaci
 - Autopilot v autech
 - Automatické parkování
 - Zdravotnictví (diagnostika – akce)

Použití



Základy umělé inteligence

(3) Zpětnovazební učení

– Robotika →

Propojení strojového učení

3D počítačové grafiky

Fyzikální simulace

Motion capture technologie (MoCap)

Použití



Základy umělé inteligence

(3) Zpětnovazební učení

Použití


– Robotika →

Propojení strojového učení

3D počítačové grafiky

Fyzikální simulace

Motion capture technologie (MoCap)



Základy umělé inteligence

(3) Zpětnovazební učení

Použití

– Robotika →


Propojení strojového učení

3D počítačové grafiky

Fyzikální simulace

Motion capture technologie (MoCap)

Humanoid



Základy umělé inteligence

(3) Zpětnovazební učení

Použití

– Robotika →




Propojení strojového učení

3D počítačové grafiky

Fyzikální simulace

Motion capture technologie (MoCap)

Humanoid



Základy umělé inteligence

(3) Zpětnovazební učení

– Robotika →

Propojení strojového učení

3D počítačové grafiky

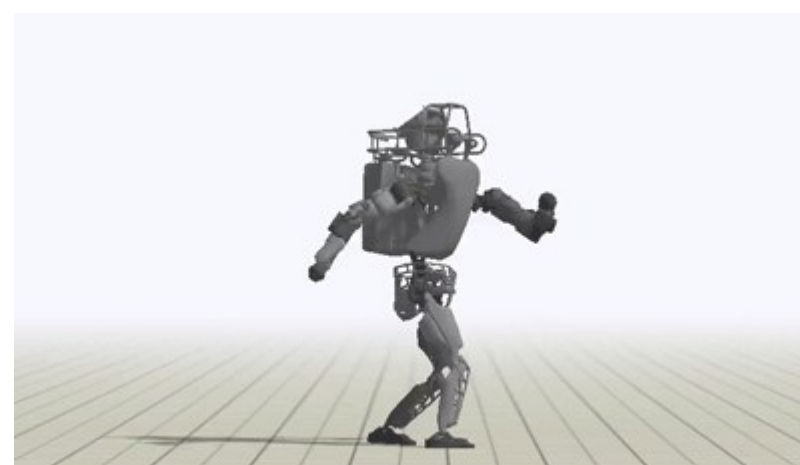
Fyzikální simulace

Motion capture technologie (MoCap)

Humanoid



Použití



Základy umělé inteligence

(3) Zpětnovazební učení

Použití

– Neuralink (E. Musk)

- Makak dostane banánové smoothie, když pomocí joysticku dopraví *kolečko* do *čtverečku*




Základy umělé inteligence

(3) Zpětnovazební učení

Použití

– Neuralink (E. Musk)

- Makak dostane banánové smoothie, když pomocí joysticku dopraví *kolečko* do *čtverečku*
- Po několika minutách se však joystick vypne a on ovládá kuličku pomocí *implantovaného chipu* v hlavě, který po několika minutách kalibraci dokáže v reálném čase (pomocí neuronových vln) *předpovídat* pomocí outputu z chipu chtějí *pohyb kurzoru*



Základy umělé inteligence

(3) Zpětnovazební učení

– Neuralink (E. Musk)

- Makak dostane banánové smoothie, když pomocí joysticku dopraví *kolečko* do *čtverečku*
- Po několika minutách se však joystick vypne a on ovládá kuličku pomocí *implantovaného chipu* v hlavě, který po několika minutách kalibraci dokáže v reálném čase (pomocí neuronových vln) *předpovídat* pomocí outputu z chipu *chtění pohyb kurzoru*
- Lidé s paralýzou (tetraplegikyci) mohou použít mobil, počítat, či se pohybovat

Použití

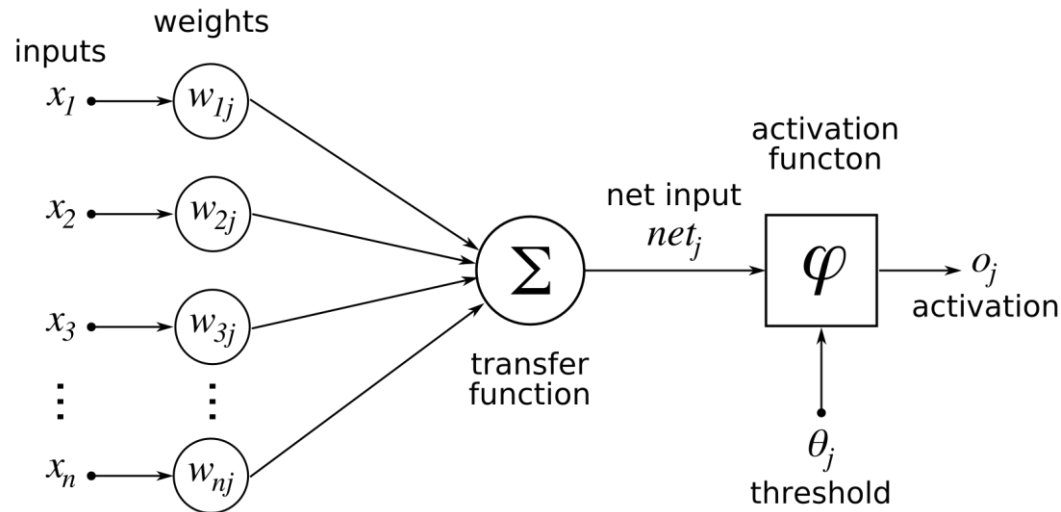
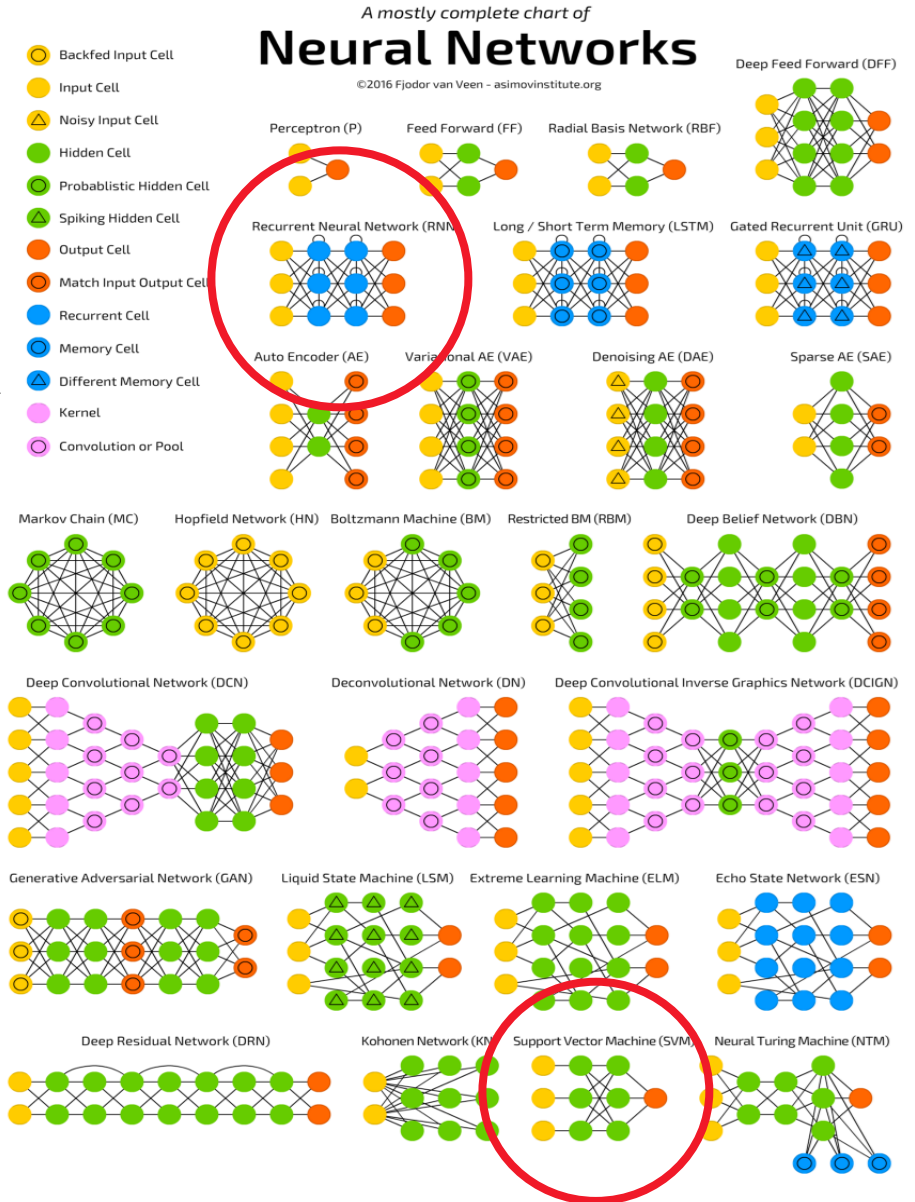


V roce 2022 byly zahájili klinické testy na lidech

Základy umělé inteligence


Přehled neuronových sítí

Přehled nejpoužívanějších neuronových sítí



Základy umělé inteligence

Neuronová síť (NN)




$$Z = \text{Bias} + W_1X_1 + W_2X_2 + \dots + W_nX_n$$

$$Z = W_0 + W_1X_1 + W_2X_2 + \dots + W_nX_n$$

- Z: symbol pro grafického znázornění NN/ANN/DNN
- W_i : beta koeficient / váha (weight)
- X_i : Vstupní proměnný (Input) / nezávislá proměnní (IV)
- W_0 : Bias / intercept
- Y: výstupní proměnná (output) / prediktivní hodnota

Základy umělé inteligence

Neuronová síť (NN)



1. Treninková data / data set
2. Výpočet ztrát (loss) nebo chyb (error term)
3. Testovací data

$$Z = \text{Bias} + W_1X_1 + W_2X_2 + \dots + W_nX_n$$

$$Z = W_0 + W_1X_1 + W_2X_2 + \dots + W_nX_n$$



$$N_1 = W_{11}X_1 + W_{12}X_2 + W_{13}X_3 + W_{14}X_4 + W_{10}$$

$$N_2 = W_{21}X_1 + W_{22}X_2 + W_{23}X_3 + W_{24}X_4 + W_{20}$$

$$N_3 = W_{31}X_1 + W_{32}X_2 + W_{33}X_3 + W_{34}X_4 + W_{30}$$

$$N_4 = W_{41}X_1 + W_{42}X_2 + W_{43}X_3 + W_{44}X_4 + W_{40}$$

$$N_5 = W_{51}X_1 + W_{52}X_2 + W_{53}X_3 + W_{54}X_4 + W_{50}$$



$$O_1 = WO_{11} * N_5 + WO_{12} * N_6 + WO_{13} * N_7 + WO_{10}$$

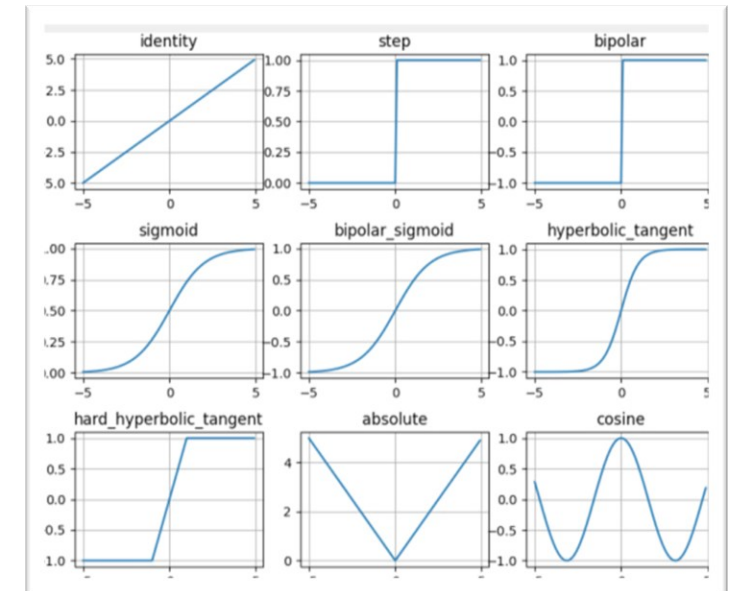
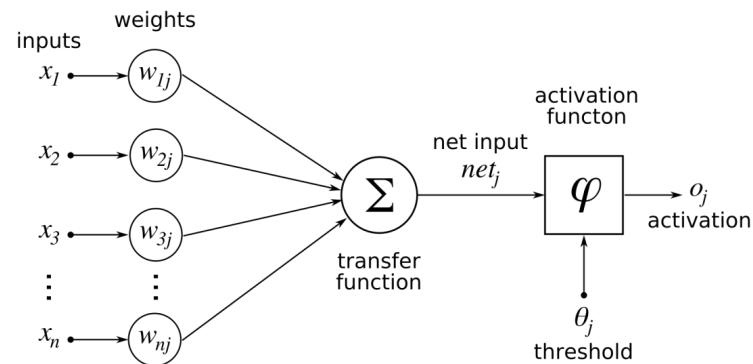

$$O_2 = WO_{21} * N_5 + WO_{22} * N_6 + WO_{23} * N_7 + WO_{20}$$

Základy umělé inteligence

Neuronová síť (NN)

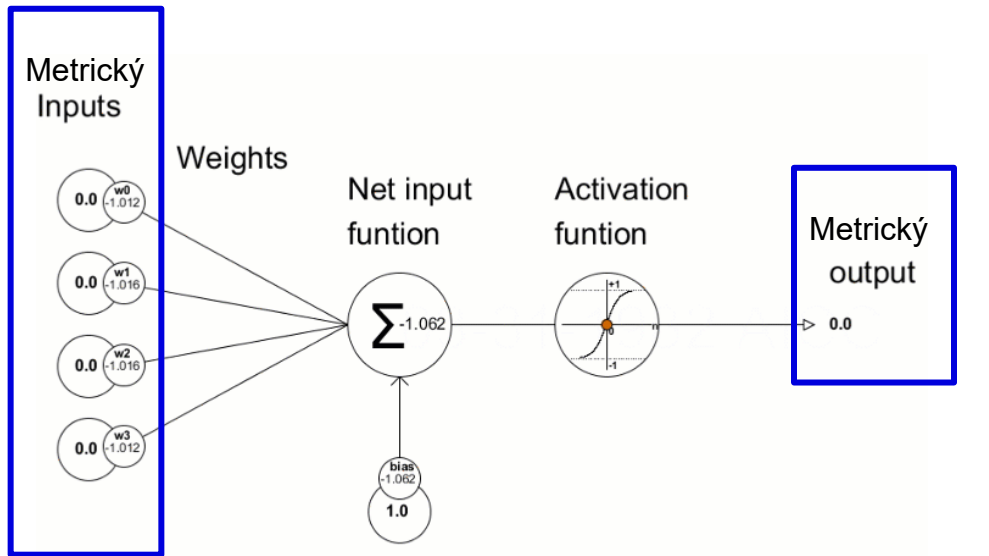
Transfer $f(x)$: převádí vstupní (inputs) signál na výstupní (output)

Aktivační $f(x)$: stanovuje prahovou hodnotu (threshold), kdy se signál spustí




Základy umělé inteligence

Neuronová síť (NN)



MqI5.com



Gfycat.com

Dvě skryté vrstvy

=

DNN

MUNI

Základy umělé inteligence

Praktická ukázka

- Dostupný software na MU
 - IBM SPSS (v.28.0.0)
Neuronová síť
 - MatLab (R2021b)
Machine Learning Toolbox

Inet.muni.cz → login (učo, primární heslo) → Provozní služby → Software → nabídka softwaru

Základy umělé inteligence

Praktická ukázka

- Dostupný software na MU
 - IBM SPSS (v.28.0.0)
Neuronová síť
- Dotazníkové šetření
 - Téma: Covid-19 a intenzita zatížení
 - 7800 respondentů

Model Summary

Training	Cross Entropy Error	3356,957
	Percent Incorrect Predictions	31,1%
	Stopping Rule Used	1 consecutive step(s) with no decrease in error ^a
	Training Time	0:00:00,86
Testing	Cross Entropy Error	1448,894
	Percent Incorrect Predictions	30,2%

Dependent Variable: Prodělal/a

a. Error computations are based on the testing sample.

Základy umělé inteligence

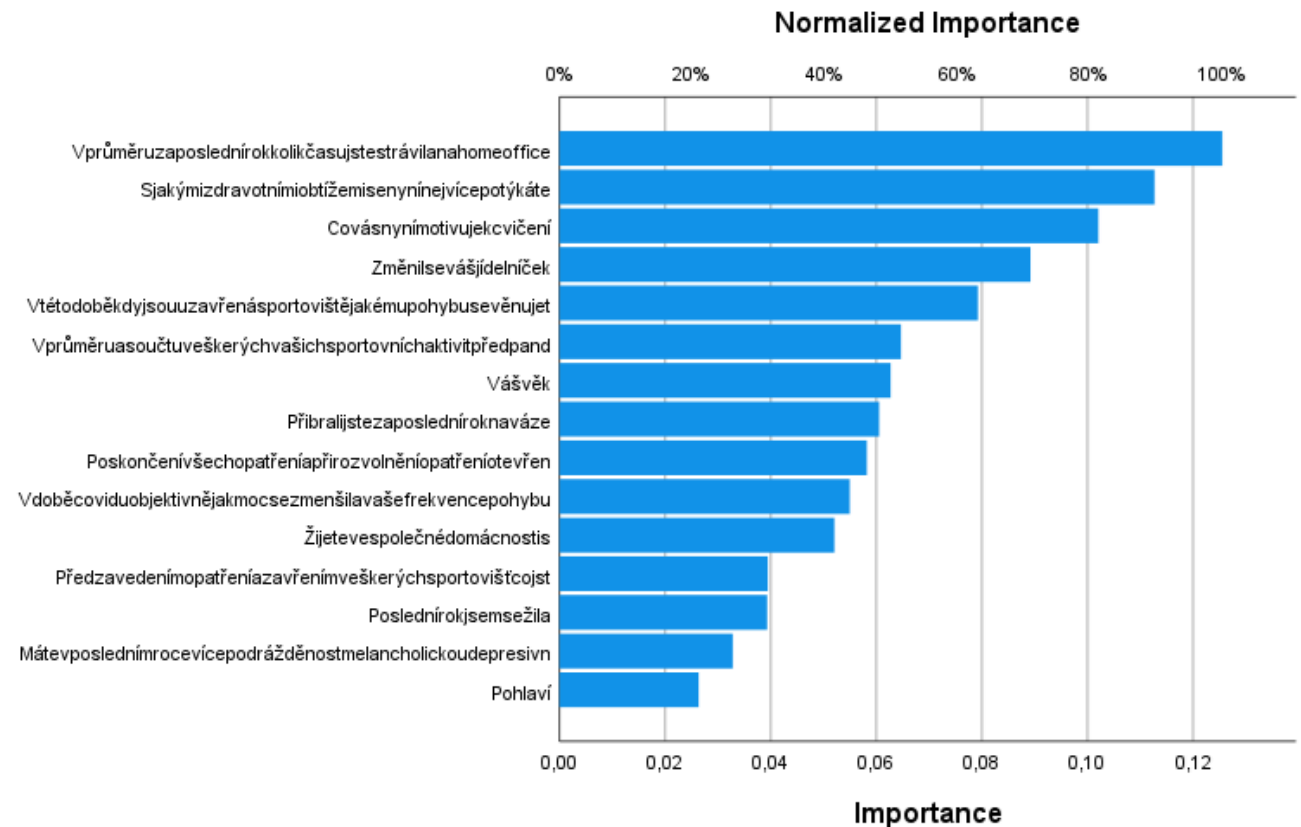
Praktická ukázka

– Dostupný software na MU

- IBM SPSS (v.28.0.0)
Neuronová síť

– Dotazníkové šetření

- Téma: Covid-19 a intenzita zatížení
- 7800 respondentů



Základy umělé inteligence

Praktická ukázka

– Dostupný software na MU

- IBM SPSS (v.28.0.0)
Neuronová síť

– Korelačně-prediktivní studie

- Téma: Predikce pořadí týmu nejvyšší české fotbalové ligy
- 2190 vzorků

Model Summary

Training	Cross Entropy Error	3237,647
	Percent Incorrect Predictions	88,2%
	Stopping Rule Used	1 consecutive step(s) with no decrease in error ^a
	Training Time	0:00:00,39
Testing	Cross Entropy Error	1469,155
	Percent Incorrect Predictions	91,9%


Dependent Variable: Kon. pořadí

a. Error computations are based on the testing sample.

Základy umělé inteligence

Praktická ukázka


- Dostupný software na MU
 - IBM SPSS (v.28.0.0)
Neuronová síť
- Korelačně-prediktivní studie
 - Téma: Predikce pořadí týmu nejvyšší české fotbalové ligy
 - 2190 vzorků



Základy umělé inteligence

Praktická ukázka

- Dostupný software na MU
 - IBM SPSS (v.28.0.0)
Neuronová síť
- Korelačně-prediktivní studie
 - Téma: Predikce pořadí týmu nejvyšší české fotbalové ligy
 - 2190 vzorků



Základy umělé inteligence

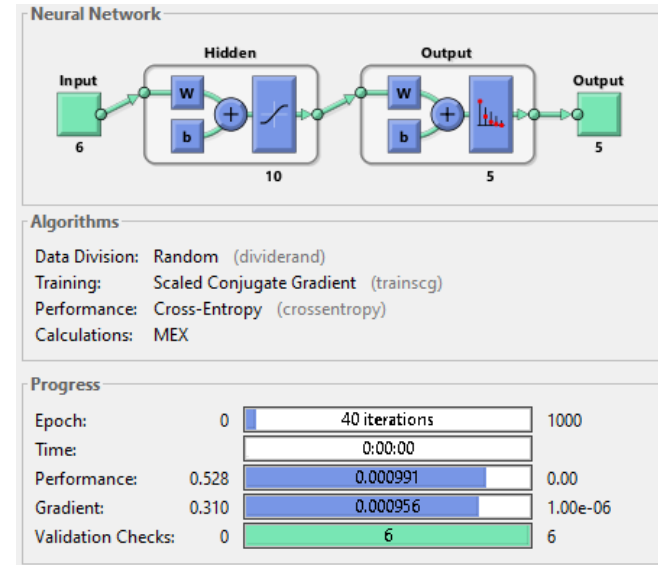
Praktická ukázka

– Dostupný software na MU

- MatLab (R2021b)
Machine Learning Toolbox

– Vývoj mobilní aplikace

- Hodnocení techniky lyžování pomocí mobilní aplikace




Results

	Samples	CE	%E
Training:	2355	2.76763e-0	2.97239e-1
Validation:	504	7.94254e-0	5.95238e-1
Testing:	504	7.89835e-0	3.96825e-1

Základy umělé inteligence

Praktická ukázka

- Dostupný software na MU
 - MatLab (R2021b)
Machine Learning Toolbox
- Vývoj mobilní aplikace
 - Hodnocení techniky lyžování pomocí mobilní aplikace



Základy umělé inteligence

Praktická ukázka

- Dostupný software na MU
 - MatLab (R2021b)
Machine Learning Toolbox
- Vývoj mobilní aplikace
 - Hodnocení techniky lyžování pomocí mobilní aplikace

Training Confusion Matrix

	1	2	3	4	5	
1	428 18.2%	1 0.0%	0 0.0%	1 0.0%	0 0.0%	99.5% 0.5%
2	0 0.0%	470 20.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	1045 44.4%	1 0.0%	4 0.2%	99.5% 0.5%
4	0 0.0%	0 0.0%	0 0.0%	196 8.3%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	209 8.9%	100% 0.0%
	100% 0.0%	99.8% 0.2%	100% 0.0%	99.0% 1.0%	98.1% 1.9%	99.7% 0.3%
	1	2	3	4	5	

Validation Confusion Matrix

	1	2	3	4	5	
1	105 20.8%	0 0.0%	2 0.4%	0 0.0%	0 0.0%	98.1% 1.9%
2	0 0.0%	88 17.5%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	0 0.0%	211 41.9%	0 0.0%	1 0.2%	99.5% 0.5%
4	0 0.0%	0 0.0%	0 0.0%	41 8.1%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	56 11.1%	100% 0.0%
	100% 0.0%	100% 0.0%	99.1% 0.9%	100% 0.0%	98.2% 1.8%	99.4% 0.6%
	1	2	3	4	5	

Test Confusion Matrix

	1	2	3	4	5	
1	105 20.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	1 0.2%	113 22.4%	0 0.0%	1 0.2%	0 0.0%	98.3% 1.7%
3	0 0.0%	0 0.0%	192 38.1%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	48 9.5%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	44 8.7%	100% 0.0%
	99.1% 0.9%	100% 0.0%	100% 0.0%	98.0% 2.0%	100% 0.0%	99.6% 0.4%
	1	2	3	4	5	





All Confusion Matrix

	1	2	3	4	5	
1	638 19.0%	1 0.0%	2 0.1%	1 0.0%	0 0.0%	99.4% 0.6%
2	1 0.0%	671 20.0%	0 0.0%	1 0.0%	0 0.0%	99.7% 0.3%
3	0 0.0%	0 0.0%	1448 43.1%	1 0.0%	5 0.1%	99.6% 0.4%
4	0 0.0%	0 0.0%	0 0.0%	285 8.5%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	309 9.2%	100% 0.0%
	99.8% 0.2%	99.9% 0.1%	99.9% 0.1%	99.0% 1.0%	98.4% 1.6%	99.6% 0.4%
	1	2	3	4	5	

Základy umělé inteligence



Praktická ukázka

- Dostupný software na MU
 - MatLab (R2021b)
Machine Learning Toolbox
- Vývoj mobilní aplikace
 - Hodnocení techniky lyžování pomocí mobilní aplikace



Základy umělé inteligence

Kam dál?



Základy umělé inteligence

Děkuji za pozornost

Prostor pro vaše dotazy



*Pozn.: při výrobě této prezentace nebyla použita žádná umělá inteligence
...možná.*

Základy umělé inteligence

Referenční seznam

- What is machine learning tutorial. https://encrypted-tbn0.gstatic.com/images?q=tbn:ANd9GcSzxcv3h8EYgsnuEKEsiDX97SHOZERFzk108TD-EnjdL_MDKNW5IuBAxJHgsHI5cK3II5g&usqp=CAU
- Ki-Jo Kim, K.-J., Tagkopoulos, I. (2019). Application of machine learning in rheumatic disease research. *Korean J Intern Med*, 34(4), 708-722. <https://doi.org/10.3904/kjim.2018.349>
- Boston Dynamics. (2020 December 29). Do You Love Me? [Video]. YouTube. <https://www.youtube.com/watch?v=fn3KWM1kuAw>
- Two Minute Papers. (2021 August 29). This AI Learned Boxing...With Serious Knockout Power! [Video]. Youtube. https://www.youtube.com/watch?v=SsJ_AusntiU
- Won, J., Gopinath, D., & Hodgins, J. (2021). Control strategies for physically simulated characters performing two-player competitive sports. *ACM Transactions on Graphics*, 40(4), 1-11.
- Two Minute Papers. (2021 August 22). DeepMind's AI Plays Catch...And So Much More! [Video]. YouTube. <https://www.youtube.com/watch?v=uuzow7TEQ1s>
- <https://www.videoman.gr/en/154235>
- DeepMind. (2021 July 27). Open-Ended Learning Leads to Generally Capable Agents. <https://storage.googleapis.com/deepmind-media/papers/Open-Ended%20Learning%20Leads%20to%20Generally%20Capable%20Agents/open-ended-learning-paper.pdf>
- Xue Bin (Jason) Peng. (2018 April 10). Towards a Virtual Stuntman. Berkeley artificial intelligence research. <https://bair.berkeley.edu/blog/2018/04/10/virtual-stuntman/>
- CNET Highlights. (2021 April 9). Watch Elon Musk's Neuralink monkey play video games with his brain [Video]. YouTube. <https://www.youtube.com/watch?v=2rXrGH52aoM>
- Van Veen F. (2017 March 31). Neural network zoo prequel: cells and layers. *The asimov institute*. <https://www.asimovinstitute.org/author/fjodorvanveen/>
- Chikazawa R. (n.d.). Types of Machine Learning. *Autify*. <https://blog.autify.com/machine-learning-in-software-testing>
- Nageswari, C. S., Kumar, M. V., Raveena, C., Sharma, J. S., & Devi, M. Y. (2021). An Identification and Classification of Thyroid Diseases Using Deep Learning Methodology. *Revista geintec-gestao inovacao e tecnologias*, 11(2), 2004-2015.
- Jumper, J., Evans, R., Pritzel, A., Green, T., Figurnov, M., Ronneberger, O., ... & Hassabis, D. (2021). Highly accurate protein structure prediction with AlphaFold. *Nature*, 596(7873), 583-589.