

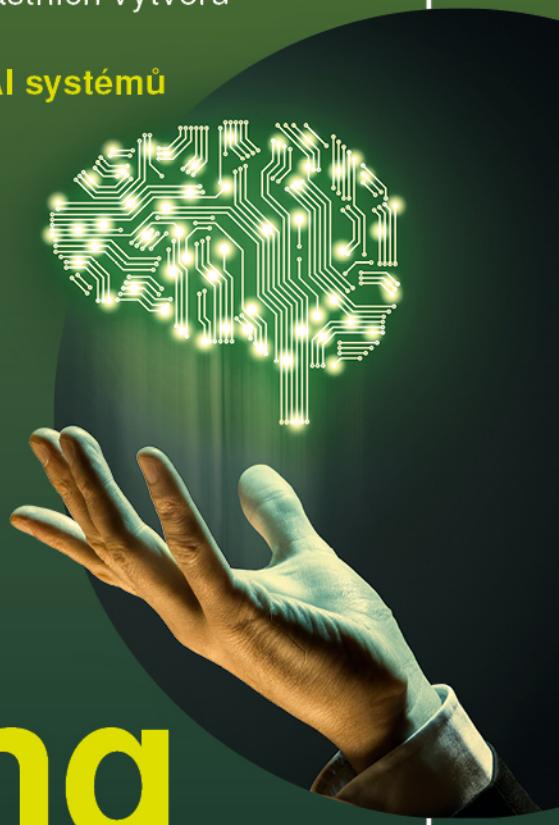
knihovna programátora

- Výklad základních principů hlubokého učení i pokročilých dovedností
- Tvorba systému hlubokého učení pro počítačové vidění, časové řady, text i generování vlastních výtvarů (například obrázků)
- **Způsob fungování moderních AI systémů typu ChatGPT**
- Popis rozdílů při spouštění programů na CPU, GPU a FPU
- Práce s webovým prostředím Collaboration, které umožňuje používat GPU a FPU na serveru

FRANÇOIS CHOLLET

Deep learning v jazyku Python

2., přepracované a rozšířené vydání

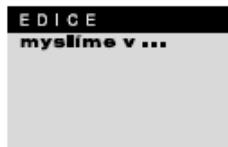


KNIHOVNY KERAS, TENSORFLOW



MANNING

GRADA



knihovna programátora

FRANÇOIS CHOLLET

Deep learning v jazyku Python

KNIHOVNY KERAS, TENSORFLOW

2., přepracované a rozšířené vydání

GRADA
Publishing

Upozornění pro čtenáře a uživatele této knihy

Všechna práva vyhrazena. Žádná část této tištěné či elektronické knihy nesmí být reprodukována a šířena v papírové, elektronické či jiné podobě bez předchozího písemného souhlasu nakladatele.

Neoprávněné užití této knihy bude **trestně stíhanou**.

François Chollet

Deep Learning v jazyku Python

Knihovny Keras, TensorFlow

2., přepracované a rozšířené vydání

Přeloženo z anglického originálu knihy Françoise Cholleta Deep Learning with Python, vydaného v roce 2021 nakladatelstvím Manning Publications Co, Spojené státy americké.

Authorized translation of the English edition © 2021 Manning Publications.
This translation is published and sold by permission of Manning Publications,
the owner of all rights to publish and sell the same.
All rights reserved.

Vydala Grada Publishing, a.s.
U Průhonu 22, Praha 7
obchod@grada.cz, www.grada.cz
tel.: +420 234 264 401
jako svou 8701. publikaci

Přeložil: Rudolf Pecinovský
Odpovědný redaktor: Petr Somogyi
Návrh vnitřního layoutu a zlom: Rudolf Pecinovský
Počet stran 528
První vydání, Praha 2023
Vytiskla TISKÁRNA V RÁJI, s.r.o., Pardubice

© Grada Publishing, a.s., 2023
Cover Design © Grada Publishing, a. s., 2023
Cover Photo © Depositphotos/Jirsak

Názvy produktů, firem apod. použité v knize mohou být ochrannými známkami nebo registrovanými ochrannými známkami příslušných vlastníků.

ISBN 978-80-271-7081-4 (pdf)
ISBN 978-80-271-5133-2 (print)

Stručný obsah

| | |
|--|------------|
| Stručný obsah | 5 |
| Podrobný obsah..... | 6 |
| Předmluva..... | 14 |
| Poděkování..... | 16 |
| O knize | 17 |
| O autorovi | 21 |
| O obálce | 22 |
| Kapitola 1 Co je hluboké učení | 24 |
| Kapitola 2 Než začneme: matematické stavební bloky neuronových sítí..... | 51 |
| Kapitola 3 Úvod do Keras a TensorFlow | 93 |
| Kapitola 4 Začínáme s neuronovými sítěmi: Klasifikace a regrese | 121 |
| Kapitola 5 Základy strojového učení | 148 |
| Kapitola 6 Univerzální pracovní postup strojového učení..... | 181 |
| Kapitola 7 Ponořme se do práce s Keras..... | 201 |
| Kapitola 8 Úvod do hlubokého učení pro počítačové vidění..... | 233 |
| Kapitola 9 Pokročilé hluboké učení pro počítačové vidění | 270 |
| Kapitola 10 Hluboké učení pro časové řady | 313 |
| Kapitola 11 Hluboké učení pro text..... | 343 |
| Kapitola 12 Generativní hluboké učení | 402 |
| Kapitola 13 Osvědčené postupy pro reálný svět..... | 453 |
| Kapitola 14 Závěry..... | 474 |
| Příloha A Terminologický slovník..... | 512 |
| Rejstřík | 523 |

Podrobný obsah

| | |
|---|----|
| Stručný obsah | 5 |
| Podrobný obsah..... | 6 |
| Předmluva..... | 14 |
| Poděkování | 16 |
| O knize | 17 |
| Komu je kniha určena | 17 |
| O kódu18 | |
| Diskusní fórum liveBook..... | 19 |
| Použité typografické konvence..... | 19 |
| Odbočka – podšeděný blok..... | 20 |
| O autorovi | 21 |
| O obálce | 22 |
| Kapitola 1 Co je hluboké učení | 24 |
| 1.1 Umělá inteligence, strojové učení a hluboké učení..... | 24 |
| 1.1.1 Umělá inteligence (artificial intelligence)..... | 25 |
| 1.1.2 Strojové učení..... | 26 |
| 1.1.3 Učení se pravidel a reprezentaci z dat | 28 |
| 1.1.4 Hloubka v hlubokém učení..... | 30 |
| 1.1.5 Pochopení toho, jak hluboké učení funguje, ve třech krocích | 32 |
| 1.1.6 Čeho hluboké učení dosud dosáhlo..... | 34 |
| 1.1.7 Nevěřte krátkodobému humbuku | 35 |
| 1.1.8 Příslib AI | 36 |
| 1.2 Před hlubokým učením: stručná historie strojového učení | 37 |
| 1.2.1 Pravděpodobnostní modelování..... | 38 |
| 1.2.2 Rané neuronové sítě | 38 |
| 1.2.3 Jádrové metody (kernel methods)..... | 38 |
| 1.2.4 Rozhodovací stromy, náhodné lesy a stroje na posílení gradientu..... | 40 |
| 1.2.5 Zpět k neuronovým sítím | 41 |
| 1.2.6 Co dělá hluboké učení odlišným | 42 |
| 1.2.7 Krajinu moderního strojového učení | 43 |
| 1.3 Proč hluboké učení? Proč teď? | 45 |
| 1.3.1 Hardware | 45 |
| 1.3.2 Data..... | 46 |
| 1.3.3 Algoritmy | 47 |
| 1.3.4 Nová vlna investic | 48 |
| 1.3.5 Demokratizace hlubokého učení | 49 |
| 1.3.6 Vydrží to? | 49 |
| Kapitola 2 Než začneme: matematické stavební bloky neuronových sítí..... | 51 |
| 2.1 První pohled na neuronovou síť | 52 |
| 2.2 Reprezentace dat pro neuronové sítě | 56 |
| 2.2.1 Skaláry (tenzory nultého řádu, 0D tenzory) | 56 |

| | |
|---|-----|
| 2.2.2 Vektory (tenzory 1. řádu, 1D tenzory) | 57 |
| 2.2.3 Matice (tenzory 2. řádu, 2D tenzory) | 57 |
| 2.2.4 Tenzory tří a vícedimenzionální | 57 |
| 2.2.5 Klíčové atributy | 58 |
| 2.2.6 Manipulace s tenzory v <i>NumPy</i> | 59 |
| 2.2.7 Pojem dávek dat..... | 60 |
| 2.2.8 Příklady datových tenzorů v reálném světě..... | 60 |
| 2.2.9 Vektorová data | 61 |
| 2.2.10 Časové řady nebo sekvenční data | 61 |
| 2.2.11 Obrazová data | 62 |
| 2.2.12 Video data | 62 |
| 2.3 Nástroje neuronových sítí: tenzorové operace..... | 63 |
| 2.3.1 Elementové operace (element-wise operations) | 64 |
| 2.3.2 Vysílání (broadcasting) | 65 |
| 2.3.3 Tenzorový součin | 66 |
| 2.3.4 Změna tvaru (přetváření) tenzoru (tensor reshaping) | 69 |
| 2.3.5 Geometrická interpretace tenzorových operací | 69 |
| 2.3.6 Geometrická interpretace hlubokého učení..... | 73 |
| 2.4 Motor neuronových sítí: optimalizace založená na gradientu..... | 73 |
| 2.4.1 Co je derivace? | 75 |
| 2.4.2 Derivace tenzorové operace: gradient | 76 |
| 2.4.3 Stochastický gradientní sestup..... | 77 |
| 2.4.4 Zřetězení derivací: algoritmus zpětného šíření | 80 |
| Pravidlo řetězu..... | 81 |
| Automatická derivace s výpočetními grafy | 81 |
| GradientTape v TensorFlow | 86 |
| 2.5 Ohlédnutí za naším prvním příkladem..... | 86 |
| 2.5.1 Reimplementace prvního příkladu od nuly v TensorFlow | 88 |
| Jednoduchá třída NaiveDense | 88 |
| Jednoduchá sekvenční třída | 89 |
| Generátor dávek..... | 89 |
| 2.5.2 Běh jednoho tréninkového kroku | 90 |
| 2.5.3 Úplný trénovací cyklus | 91 |
| 2.5.4 Vyhodnocení modelu..... | 91 |
| 2.6 Shrnutí kapitoly..... | 92 |
| Kapitola 3 Úvod do Keras a TensorFlow | 93 |
| 3.1 Co je TensorFlow | 93 |
| 3.2 Co je Keras | 94 |
| 3.3 Keras a TensorFlow: stručná historie | 96 |
| 3.4 Nastavení pracovního prostoru pro hluboké učení..... | 96 |
| 3.4.1 Notebooky Jupyter: preferovaný způsob provádění experimentů s hlubokým učením | 97 |
| 3.4.2 Používání laboratoře Colaboratory | 98 |
| První kroky s Colaboratory | 98 |
| Instalace balíčků pomocí PIP | 100 |
| Použití běhového prostředí GPU | 100 |
| 3.5 První kroky s TensorFlow | 101 |
| 3.5.1 Konstantní tenzory a proměnné | 101 |
| 3.5.2 Operace s tenzory: provádění matematických operací v TensorFlow | 104 |
| 3.5.3 Druhý pohled na API GradientTape | 104 |
| 3.5.4 Souhrnný příklad: lineární klasifikátor v čistém TensorFlow | 105 |
| 3.6 Anatomičeské neuronové sítě: pochopení základních rozhraní Keras API..... | 110 |
| 3.6.1 Vrstvy: základní kameny hlubokého učení | 110 |
| Layer – základní třída vrstvy v Keras..... | 111 |
| Automatické odvozování tvaru: vytváření vrstev za běhu | 112 |
| 3.6.2 Od vrstev k modelům | 113 |

| | |
|--|------------|
| 3.6.3 Krok „překlad“: konfigurace procesu učení..... | 115 |
| 3.6.4 Výběr ztrátové funkce | 117 |
| 3.6.5 Porozumění metodě <code>fit()</code> | 117 |
| 3.6.6 Monitorování ztrát a metrik na validačních datech..... | 118 |
| 3.6.7 Odvození: použití modelu po tréninku..... | 119 |
| 3.7 Shrnutí kapitoly..... | 120 |
| Kapitola 4 Začínáme s neuronovými sítěmi: Klasifikace a regrese | 121 |
| Glosář klasifikace a regrese..... | 121 |
| 4.1 Klasifikace filmových recenzí: příklad binární klasifikace..... | 123 |
| 4.1.1 Databáze IMDB..... | 123 |
| 4.1.2 Příprava dat..... | 124 |
| 4.1.3 Sestavení modelu | 125 |
| Co jsou aktivační funkce a proč jsou potřebné | 128 |
| 4.1.4 Ověření vašeho přístupu | 128 |
| 4.1.5 Použití vycvičeného modelu k vytváření předpovědí na nových datech | 131 |
| 4.1.6 Další experimenty | 132 |
| 4.1.7 Shrnutí | 132 |
| 4.2 Klasifikace zpravidlostí: příklad klasifikace do více tříd..... | 133 |
| 4.2.1 Soubor dat <i>Reuters</i> | 133 |
| 4.2.2 Příprava dat..... | 134 |
| 4.2.3 Sestavení modelu | 135 |
| 4.2.4 Ověření vašeho přístupu | 136 |
| 4.2.5 Generování predikcí pro nová data | 138 |
| 4.2.6 Jiný způsob zacházení se štítky a ztrátou | 138 |
| 4.2.7 Důležitost dostatečně velkých mezivrstev | 139 |
| 4.2.8 Další experimenty | 139 |
| 4.2.9 Shrnutí | 139 |
| 4.3 Predikce cen nemovitostí: příklad regrese | 140 |
| 4.3.1 Soubor údajů o cenách bydlení v Bostonu | 140 |
| 4.3.2 Příprava dat..... | 141 |
| 4.3.3 Sestavení modelu | 141 |
| 4.3.4 Ověření vašeho přístupu použitím k-násobné validace | 142 |
| 4.3.5 Generování předpovědí na nových datech | 146 |
| 4.3.5 Shrnutí | 146 |
| 4.4 Shrnutí kapitoly..... | 147 |
| Kapitola 5 Základy strojového učení | 148 |
| 5.1 Zobecnění: cíl strojového učení..... | 148 |
| 5.1.1 Přeúčení a podučení | 149 |
| Zašuměná trénovací data | 149 |
| Nejednoznačné rysy..... | 151 |
| Vzácné rysy a falešné korelace | 151 |
| 5.1.2 Povaha zobecnění v hlubokém učení..... | 154 |
| Hypotéza o mnohotvárnosti | 155 |
| Interpolace jako zdroj zobecnění | 156 |
| Proč hluboké učení funguje | 157 |
| Trénovací data jsou nejdůležitější..... | 158 |
| 5.2 Vyhodnocování modelů strojového učení | 160 |
| 5.2.1 Trénovačí, validační a testovací sady | 160 |
| Jednoduchá validace a odebraných datech (simple hold-out validation) | 161 |
| K-násobné křížová validace | 162 |
| Opakována k-násobná validace s promícháním | 163 |
| 5.2.2 Překonání základní referenční úrovně | 163 |
| 5.2.2 Věci, které je třeba mít na paměti | 164 |
| 5.3 Zlepšení odpovědí modelu | 165 |
| 5.3.1 Ladění klíčových parametrů gradientního sestupu | 165 |
| 5.3.2 Využití lepších předloh architektury..... | 166 |

| | |
|---|------------|
| 5.3.3 Zvyšování kapacity modelu | 167 |
| 5.4 Zlepšení zobecnění..... | 169 |
| 5.4.1 Kurátorství datových sad | 169 |
| 5.4.2 Inženýrství rysů..... | 170 |
| 5.4.3 Včasné zastavení | 171 |
| 5.4.4 Regularizace modelu..... | 172 |
| Zmenšení velikosti sítě | 172 |
| Přidání regularizace vah | 175 |
| Přidání dropout | 177 |
| 5.5 Shrnutí kapitoly..... | 179 |
| Kapitola 6 Univerzální pracovní postup strojového učení..... | 181 |
| Poznámka k etice | 182 |
| 6.1 Definice úkolu | 183 |
| 6.1.1 Rámcový popis problému..... | 183 |
| 6.1.2 Shromáždění souboru dat | 185 |
| Investice do infrastruktury pro anotaci dat..... | 186 |
| Pozor na nereprezentativní údaje | 186 |
| Problém zkreslení výběru vzorku..... | 187 |
| 6.1.3 Porozumění datům..... | 188 |
| 6.1.4 Zvolte si měřítko úspěchu | 189 |
| 6.2 Využití modelu | 189 |
| 6.2.1 Příprava dat | 189 |
| Vektorizace..... | 190 |
| Normalizace hodnot..... | 190 |
| Zpracování chybějících hodnot | 190 |
| 6.2.2 Výběr hodnoticího protokolu..... | 191 |
| 6.2.3 Překonání základní referenční úrovni..... | 191 |
| Výběr správné ztrátové funkce..... | 192 |
| 6.2.4 Rozšíření: vývoj modelu, který se přizpůsobí | 193 |
| 6.2.5 Regularizace a vyladění modelu | 193 |
| 6.3 Nasazení modelu | 194 |
| 6.3.1 Vysvětlete svou práci zúčastněným stranám a stanovte očekávání..... | 194 |
| 6.3.2 Odeslání odvozovacího modelu..... | 195 |
| Nasazení modelu jako REST API | 195 |
| Nasazení modelu v zařízení | 196 |
| Nasazení modelu v prohlížeči | 197 |
| Optimalizace odvozovacího (inferenčního) modelu | 198 |
| 6.3.3 Sledování modelu „v divočině“ | 198 |
| 6.3.4 Udržujte svůj model..... | 199 |
| 6.4 Shrnutí kapitoly..... | 199 |
| Kapitola 7 Ponořme se do práce s Keras..... | 201 |
| 7.1 Spektrum pracovních postupů..... | 202 |
| 7.2 Různé způsoby vytváření modelů Keras..... | 202 |
| 7.2.1 Sekvenční model..... | 203 |
| 7.2.2 Funkcionální API..... | 205 |
| Jednoduchý příklad | 205 |
| Modely s více vstupy a výstupy | 207 |
| Trénování modelu s více vstupy a výstupy | 208 |
| Síla funkcionálního API: přístup k propojení vrstev | 209 |
| 7.2.3 Definice potomků třídy Model | 211 |
| Přepsání předchozího příkladu jako modelu s podtřídou | 211 |
| Pozor: co modely s podtřídou nepodporují..... | 213 |
| 7.2.4 Míchání a kombinování různých součástí..... | 213 |
| 7.2.5 Pamatuje: pro danou práci používejte správný nástroj..... | 214 |
| 7.3 Použití vestavěných trénovacích a vyhodnocovacích cyklů..... | 215 |
| 7.3.1 Psaní vlastních metrik | 216 |

| | |
|---|------------|
| 7.3.2 Použití zpětných volání..... | 217 |
| Zpětná volání <code>EarlyStopping</code> a <code>ModelCheckpoint</code> | 218 |
| 7.3.3 Psaní vlastních zpětných volání | 219 |
| 7.3.4 Monitorování a vizualizace pomocí TensorBoard..... | 221 |
| 7.4 Psaní vlastních školicích a hodnoticích cyklů..... | 223 |
| Další druhy učení..... | 224 |
| 7.4.1 Školení versus odvozování | 225 |
| 7.4.2 Použití metrik na nízké úrovni..... | 226 |
| 7.4.3 Kompletní cyklus školení a hodnocení | 226 |
| 7.4.4 Zrychlete pomocí funkce <code>tf.function</code> | 228 |
| 7.4.5 Využití funkce <code>fit()</code> s vlastním trénovacím cyklem | 229 |
| 7.5 Shrnutí kapitoly..... | 231 |
| Kapitola 8 Úvod do hlubokého učení pro počítačové vidění | 233 |
| 8.1 Úvod do konvolučních neuronových sítí – CNN..... | 234 |
| 8.1.1 Konvoluční operace | 236 |
| Porozumění hraničním efektům a vycpávkám..... | 239 |
| Porozumění konvolučním krokům..... | 240 |
| 8.1.2 Operace sdružování dle maxima (max pooling)..... | 241 |
| 8.2 Trénování CNN od nuly na malé sadě dat | 243 |
| 8.2.1 Význam hlubokého učení pro úlohy s malými daty..... | 243 |
| 8.2.2 Stažení dat..... | 244 |
| Stažení datové sady Kaggle v nástroji Google Colaboratory | 245 |
| 8.2.3 Sestavení modelu..... | 247 |
| 8.2.4 Předpracování dat | 249 |
| Porozumění objektům <code>Dataset</code> frameworku TensorFlow | 249 |
| 8.2.5 Použití rozšíření dat (data augmentation)..... | 253 |
| 8.3 Použití předtrénované CNN | 256 |
| 8.3.1 Extrakce rysů | 257 |
| Rychlá extrakce rysů bez rozšíření dat..... | 261 |
| Extrakce rysů s rozšířením dat | 263 |
| 8.3.2 Jemné doladění předtrénovaného modelu | 265 |
| 8.4 Shrnutí kapitoly..... | 268 |
| Kapitola 9 Pokročilé hluboké učení pro počítačové vidění | 270 |
| 9.1 Tři základní úlohy počítačového vidění | 270 |
| 9.2 Příklad segmentace obrazu | 272 |
| 9.3 Moderní vzory architektury CNN | 280 |
| 9.3.1 Modularita, hierarchie a opakování použití | 281 |
| O významu ablačních studií ve výzkumu hlubokého učení..... | 283 |
| 9.3.2 Zbytková připojení (residual connections) | 283 |
| 9.3.3 Dávková normalizace | 287 |
| 9.3.4 Hloubkově oddělitelné konvoluce | 289 |
| Koevoluce hardwaru, softwaru a algoritmu | 290 |
| 9.3.5 Složení: mini model podobný Xception | 292 |
| 9.4 Interpretace toho, co se CNN naučí | 294 |
| 9.4.1 Vizualizace mezilehých aktivací | 294 |
| 9.4.2 Vizualizace filtrů CNN | 300 |
| Rozdíl mezi <code>model.predict(x)</code> a <code>model(x)</code> | 302 |
| 9.4.3 Zobrazení teplotních map aktivací třídy | 306 |
| 9.5 Shrnutí kapitoly..... | 312 |
| Kapitola 10 Hluboké učení pro časové řady | 313 |
| 10.1 Různé druhy úloh časových řad | 313 |
| 10.2 Příklad předpovědi teploty..... | 314 |
| Vždy hledejte v datech periodicitu | 317 |
| 10.2.1 Příprava dat..... | 317 |
| Porozumění <code>timeseries_dataset_from_array()</code> | 318 |

| | |
|--|------------|
| 10.2.2 Základní referenční úroveň bez strojového učení..... | 320 |
| 10.2.3 Vyzkoušejme základní model strojového učení | 321 |
| 10.2.4 Vyzkoušejme 1D konvoluční model..... | 323 |
| 10.2.5 První rekurentní základní referenční úroveň | 325 |
| 10.3 Porozumění rekurentním neuronovým sítím | 326 |
| 10.3.1 Rekurentní vrstvy v Keras | 329 |
| 10.4 Pokročilé využití rekurentních neuronových sítí | 333 |
| 10.4.1 Použití rekurentního dropoutu v boji proti přeucení..... | 334 |
| Výkonnost RNN za běhu | 335 |
| 10.4.2 Stohování rekurentních vrstev | 336 |
| 10.4.3 Použití obousměrných RNN | 337 |
| 10.4.4 Pokračujme ještě dále | 340 |
| Trhy a strojové učení | 341 |
| 10.5 Shrnutí kapitoly..... | 341 |
| Kapitola 11 Hluboké učení pro text..... | 343 |
| 11.1 Zpracování přirozeného jazyka: z ptačí perspektivy | 343 |
| 11.2 Příprava textových dat | 345 |
| 11.2.1 Standardizace textu | 346 |
| 11.2.2 Dělení textu (tokenizace)..... | 347 |
| Porozumění N-gramům a sadám slov | 348 |
| 11.2.3 Indexování slovní zásoby | 348 |
| 11.2.4 Použití vrstvy <code>TextVectorization</code> | 350 |
| Použití vrstvy <code>TextVectorization</code> v datovodu <code>tf.data</code> nebo jako součást modelu | 352 |
| 11.3 Dva přístupy k reprezentaci skupin slov: sady a posloupnosti | 354 |
| 11.3.1 Příprava dat recenzí filmů na IMDB | 354 |
| 11.3.2 Zpracování slov jako sady: přístup sada slov (Bag-of-Words approach) | 356 |
| Jednotlivá slova s binárním kódováním (1-gramy, unigramy) | 357 |
| Bigramy (2-gramy) s binárním kódováním | 359 |
| Bigramy s kódováním TF-IDF | 360 |
| Porozumění normalizaci TF-IDF | 361 |
| Export modelu, který zpracovává nezpracované řetězce | 362 |
| 11.3.3 Zpracování slov jako sekvence: přístup sekvenčního modelu | 363 |
| První praktický příklad | 363 |
| Porozumění slovním vnořením | 365 |
| Učení vkládání slov pomocí vrstvy <code>Embedding</code> | 367 |
| Porozumění výplním a maskování | 368 |
| Použití předem natrénovaných slovních vnoření | 370 |
| 11.4 Architektura Transformátor | 372 |
| 11.4.1 Porozumění sebepozornosti | 373 |
| Zobecněná sebepozornost: model dotaz-klíč-hodnota | 376 |
| 11.4.2 Pozornost více hlav (multi-head attention) | 377 |
| 11.4.3 Transformátor | 378 |
| Ukládání vlastních vrstev | 380 |
| Použití pozičního kódování k opětovnému vložení informací o pořadí | 383 |
| Všechno dohromady: transformátor pro klasifikaci textu | 384 |
| 11.4.4 Kdy použít sekvenční modely místo modelů typu „sada slov“? | 385 |
| 11.5 Nad rámec klasifikace textu: učení sekvence na sekvenci | 386 |
| 11.5.1 Příklad strojového překladu | 387 |
| 11.5.2 Učení sekvence na sekvenci pomocí RNN | 390 |
| 11.5.3 Učení sekvence na sekvenci pomocí Transformátoru | 395 |
| Dekodér Transformátoru | 396 |
| Vše dohromady: Transformátor pro strojový překlad | 398 |
| 11.6 Shrnutí kapitoly..... | 401 |
| Kapitola 12 Generativní hluboké učení | 402 |
| 12.1 Generování textu | 404 |
| 12.1.1 Stručná historie generativního hlubokého učení pro generování sekvencí..... | 404 |

| | |
|--|-------------------|
| 12.1.2 Jak generujete sekvenční data? | 405 |
| 12.1.3 Význam strategie výběru vzorků | 406 |
| 12.1.4 Implementace generování textu pomocí Keras..... Příprava dat..... Model založený na transformátoru sekvence-sekvenci..... | 407 408 409 |
| 12.1.5 Zpětné volání pro generování textu se vzorkováním s proměnnou teplotou | 411 |
| 12.1.6 Závěrečné shrnutí | 415 |
| 12.2 DeepDream..... | 415 |
| 12.2.1 Implementace DeepDream v Keras | 416 |
| 12.2.2 Závěrečné shrnutí | 422 |
| 12.3 Přenos neuronového stylu | 423 |
| 12.3.1 Ztráta obsahu..... | 424 |
| 12.3.2 Ztráta stylu | 424 |
| 12.3.3 Přenos neuronového stylu v Keras | 425 |
| 12.3.4 Závěrečné shrnutí | 431 |
| 12.4 Generování obrazů pomocí variačních autoenkovodérů..... | 431 |
| 12.4.1 Vzorkování z latentních prostorů obrazů..... | 431 |
| 12.4.2 Koncepční vektory pro úpravy obrázků..... | 432 |
| 12.4.3 Variační autoenkovodéry..... | 433 |
| 12.4.4 Implementace VAE pomocí Keras | 436 |
| 12.4.5 Závěrečné shrnutí | 441 |
| 12.5 Úvod do generativních soupeřících sítí..... | 442 |
| 12.5.1 Schematická implementace GAN | 443 |
| 12.5.2 Sada triků | 444 |
| 12.5.3 Získání souboru dat CelebA..... | 445 |
| 12.5.4 Diskriminátor | 446 |
| 12.5.5 Generátor | 447 |
| 12.5.6 Soupeřící sítí' | 448 |
| 12.5.7 Závěrečné shrnutí | 451 |
| 12.6 Shrnutí kapitoly..... | 452 |
| Kapitola 13 Osvědčené postupy pro reálný svět..... | 453 |
| 13.1 Využití vašich modelů na maximum | 454 |
| 13.1.1 Optimalizace hyperparametrů..... Používání KerasTuneru | 454 455 |
| Maximalizace a minimalizace cíle optimalizace | 457 |
| Umění vytvořit správný vyhledávací prostor | 460 |
| Budoucnost ladění hyperparametrů: automatizované strojové učení..... | 460 |
| 13.1.2 Kombinování modelů | 461 |
| 13.2 Rozšiřování školení modelů | 463 |
| 13.2.1 Zrychlení tréninku na GPU se smíšenou přesností | 464 |
| Porozumění přesnosti reálných čísel | 464 |
| Poznámka ke kódování reálných čísel | 465 |
| Pozor na výchozí hodnoty <code>dtype</code> | 466 |
| Trénink se smíšenou přesností v praxi | 467 |
| 13.2.2 Školení s více grafickými procesory | 467 |
| Získání dvou nebo více GPU | 468 |
| Synchronní školení s jedním hostitelem a více zařízeními | 468 |
| Tipy pro výkon <code>tf.data</code> | 469 |
| 13.2.3 Trénování TPU | 470 |
| Použití TPU přes Google Colab | 470 |
| Pozor na úzká místa I/O | 472 |
| Využití slučování kroků ke zlepšení využití TPU | 472 |
| 13.3 Shrnutí kapitoly..... | 472 |
| Kapitola 14 Závěry..... | 474 |
| 14.1 Přehled klíčových pojmu..... | 474 |
| 14.1.1 Různé přístupy k AI | 475 |

| | |
|--|------------|
| 14.1.2 Čím je hluboké učení v oblasti strojového učení výjimečné | 475 |
| 14.1.3 Jak uvažovat o hlubokém učení..... | 476 |
| 14.1.4 Klíčové podpůrné technologie | 477 |
| 14.1.5 Univerzální pracovní postup strojového učení..... | 478 |
| 14.1.6 Klíčové sítové architektury..... | 479 |
| Hustě propojené sítě | 480 |
| CNN (konvoluční neuronové sítě) | 481 |
| RNN | 482 |
| Transformátory | 482 |
| 14.1.7 Prostor možností | 483 |
| 14.2 Omezení hlubokého učení | 485 |
| 14.2.1 Riziko antropomorfizace modelů strojového učení | 486 |
| 14.2.2 Automaty vs. inteligentní agenti | 488 |
| 14.2.3 Lokální generalizace vs. extrémní generalizace | 489 |
| 14.2.4 Účel intelligence..... | 491 |
| 14.2.5 Šplhání po spektru zobecnění | 492 |
| 14.3 Nastavení směru k větší obecnosti umělé intelligence..... | 493 |
| 14.3.1 O důležitosti stanovení správného cíle: pravidlo zkratky | 493 |
| 14.3.2 Nový cíl | 495 |
| 14.4 Zavádění intelligence: chybějící ingredience | 497 |
| 14.4.1 Inteligence jako citlivost na abstraktní analogie | 497 |
| 14.4.2 Dva póly abstrakce | 498 |
| Analogie zaměřená na hodnoty (value-centric analogy) | 499 |
| Analogie zaměřená na program (program-centric analogy)..... | 500 |
| Poznávání jako kombinace obou druhů abstrakce | 501 |
| 14.4.3 Chybějící polovina obrázku | 501 |
| 14.5 Budoucnost hlubokého učení | 502 |
| 14.5.1 Modely jako programy | 503 |
| 14.5.2 Spojení hlubokého učení a syntézy programů | 504 |
| Integrace modulů hlubokého učení a algoritmických modulů do hybridních systémů | 505 |
| Využití hlubokého učení k vyhledávání programů..... | 506 |
| 14.5.3 Celoživotní učení a modulární opakování použití podprogramů | 507 |
| 14.5.4 Dlouhodobá vize | 508 |
| 14.6 Zůstaňte v obraze v rychle se vyvíjející oblasti | 509 |
| 14.6.1 Cvičení na reálných úlohách pomocí Kaggle | 510 |
| 14.6.2 Přečtěte si o nejnovějším vývoji na arXiv | 510 |
| 14.6.3 Prozkoumejte ekosystém Keras..... | 511 |
| 14.7 Závěrečné slovo..... | 511 |
| Příloha A Terminologický slovník..... | 512 |
| A.1 Používané zkratky | 512 |
| GRU | 513 |
| A.2 Řazený dle anglických termínů | 513 |
| A.3 Řazený dle českých termínů | 518 |
| Rejstřík | 523 |

Předmluva

Držíte-li tuto knihu v ruce, jste si asi vědomi mimořádného pokroku, jehož hluboké učení pro oblast umělé inteligence v nedávné době dosáhlo. Za pouhých pět let jsme se od téměř nepoužitelného počítačového vidění a zpracování přirozeného jazyka dostali až k vysoce výkonným systémům nasazeným ve velkém měřítku v produktech, které používáme každý den.

Důsledky tohoto náhlého pokroku zasahují téměř do všech odvětví. Hluboké učení již uplatňujeme v rozsáhlé škále důležitých problémů v tak odlišných oblastech, jako je lékařské zobrazování, zemědělství, autonomní řízení, vzdělávání, prevence katastrof a výroba.

Přesto se domnívám, že hluboké učení je stále v počátcích. Zatím využilo jen malou část svého potenciálu. Postupem času se dostane do všech oblastí, kde může pomoci – tato transformace bude trvat několik desetiletí.

Abychom mohli začít používat technologii hlubokého učení na všechny problémy, které by mohla vyřešit, musíme ji zpřístupnit co největšímu počtu lidí, včetně těch, kteří nejsou odborníky: tedy i lidem, kteří nejsou výzkumníky nebo postgraduálními studenty. Aby hluboké učení dosáhlo plného potenciálu, musíme ho radikálně zdemokratizovat.

Domnívám, že nyní jsme na vrcholu historického přechodu, kdy hluboké učení opouští vědecké laboratoře a výzkumná či vývojová oddělení velkých technologických společností a stává se všudypřítomnou součástí sady nástrojů každého vývojáře, ne nepodobně trajektorii vývoje webových stránek na konci 90. let. Téměř každý si nyní může pro svou firmu nebo komunitu vytvořit webové stránky nebo webovou aplikaci, k jejichž vytvoření by v roce 1998 potřeboval malý tým inženýrů specialistů. V nepříliš vzdálené budoucnosti bude moci kdokoli s nápadem a základními dovednostmi v oblasti kódování vytvářet inteligentní aplikace, které se budou učit z dat.

Když jsem v březnu 2015 vydal první verzi frameworku *Keras* pro hluboké učení, neměl jsem na mysli demokratizaci umělé inteligence. Již několik let jsem se zabýval výzkumem v oblasti strojového učení a vytvořil jsem *Keras*, aby mi pomohl při mých vlastních experimentech.

Od roku 2015 však do oblasti hlubokého učení vstoupily statisíce nováčků; mnozí z nich si *Keras* vybrali jako svůj nástroj. Když jsem sledoval, jak desítky chytrých lidí používají *Keras* nečekaným a efektivním způsobem, začal jsem se velmi zajímat o dostupnost a demokratizaci umělé inteligence. Uvědomil jsem si, že čím více se tyto technologie šíří, tím jsou užitečnější a cennější. Přístupnost se rychle stala cílem vývoje

Keras a během několika krátkých let dosáhla komunita vývojářů v tomto směru fantastických úspěchů. Dali jsme hluboké učení do rukou statisíců lidí, kteří ho následně používají k řešení problémů, jež byly donedávna považovány za neřešitelné.

Knihu, kterou držíte v ruce, je dalším krokem na cestě k zpřístupnění hlubokého učení co největšímu počtu lidí. *Keras* vždy potřeboval doprovodný kurz, který by se současně zabýval základy hlubokého učení, osvědčenými postupy a způsoby použití frameworku *Keras*.

V letech 2016 a 2017 jsem se snažil takový kurz vytvořit, což vedlo k první verzi této knihy, která vyšla v prosinci 2017. Rychle se stala bestsellerem v oblasti strojového učení, prodalo se jí přes 50 000 výtisků a byla přeložena do 12 jazyků.

Oblast hlubokého učení však rychle postupuje vpřed. Od prvního vydání došlo k mnoha důležitým změnám – objevilo se *TensorFlow 2*, vzrostla popularita architektury *Transformátor* a mnoho dalšího. A tak jsem se koncem roku 2019 rozhodl svou knihu aktualizovat.

Původně jsem si docela naivně myslel, že bude obsahovat zhruba 50 % nového obsahu, nakonec bude zhruba stejně dlouhá jako první vydání. V praxi se po dvou letech práce ukázalo, že je více než o třetinu delší a obsahuje asi 75 % nového obsahu. Spíše než o aktualizaci tedy jde o zcela novou knihu.

Napsal jsem ji s důrazem na to, aby koncepty hlubokého učení a jejich implementace byly co nejpřístupnější. Přitom jsem nemusel nic hloupě vysvětlovat, protože pevně věřím, že v hlubokém učení nejsou žádné obtížné myšlenky. Doufám, že pro vás bude tato kniha cenná a že vám umožní začít vytvářet inteligentní aplikace a řešit problémy, na kterých vám záleží.

Poznámka překladatele a redakce k názvu knihy: V předkládané publikaci se snažíme maximálně dodržovat českou terminologii, ale u názvu knihy jsme dali přednost anglickému termínu *deep learning*. Domníváme se, že je ve větším povědomí mezi čtenáři než jeho český ekvivalent *hluboké učení*.

Poděkování

Nejprve bych rád poděkoval komunitě *Keras* za to, že umožnila vznik této knihy. Za posledních šest let se *Keras* rozrostl na stovky přispěvatelů do open source a více než milion uživatelů. Díky vašim příspěvkům a zpětné vazbě se *Keras* stal tím, čím je dnes.

Z osobních důvodů bych rád poděkoval své ženě za její nekonečnou podporu při vývoji frameworku *Keras* a psaní této knihy.

Rád bych také poděkoval společnosti *Google* za podporu projektu *Keras*. Bylo fantastické, že *Keras* byl přijat jako vysokoúrovňové API frameworku *TensorFlow*. Hladká integrace mezi frameworky *Keras* a *TensorFlow* je velmi přínosná jak pro uživatele *TensorFlow*, tak pro uživatele *Keras*, a zpřístupňuje hluboké učení většině.

Chtěl bych rovněž poděkovat lidem z nakladatelství *Manning*, kteří se zasloužili o vznik této knihy: nakladateli Marjanu Baceovi a všem členům redakčního a produkčního týmu včetně Michaela Stephense, Jennifer Stoutové, Aleksandara Dragosavljeviče a mnoha dalších, kteří pracovali v zákulisí.

Velký dík patří technickým recenzentům: Billy O'Callaghan, Christian Weisstanner, Conrad Taylor, Daniela Zapata Riesco, David Jacobs, Edmon Begoli, Edmund Ronald, Ph.D., Hao Liu, Jared Duncan, Kee Nam, Ken Fricklas, Kjell Jansson, Milan Šarenac, Nguyen Cao, Nikos Kanakaris, Oliver Korten, Raushan Jha, Sayak Paul, Sergio Govoni, Shashank Polasa, Todd Cook a Vitor Vitanis – a všem dalším, kteří nám poslali zpětnou vazbu k návrhu knihy.

Po technické stránce patří zvláštní poděkování Frances Buontempo, technické redaktorce knihy, a Karstenu Strøbækovi, který se postaral o korektury.