

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 kódu ¹⁸	
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 učení: 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 Krajina 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 učení	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	Anatomie 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 zpravodajství: 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	Přeučení 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	Trénovací, validační a testovací sady	160
	Jednoduchá validace na odebraných datech (simple hold-out validation)	161
	K-násobné křížová validace.....	162
	Opakovaná 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 Vyvinutí modelu	189
6.2.1 Příprava dat	189
Vektorizace.....	190
Normalizace hodnot.....	190
Zpracování chybějících hodnot	190
6.2.2 Výběr hodnotícího protokolu.....	191
6.2.3 Překonání základní referenční úrovně.....	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 <i>Keras</i>	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 <code>Model</code>	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 Pamatujte: 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 <code>TensorBoard</code>	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	Předzpracování 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 opakované 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	Hlubkově oddělitelné konvoluce	289
	Koevoluce hardwaru, softwaru a algoritmů.....	290
9.3.5	Složení: mini model podobný Xception	292
9.4	Interpretace toho, co se CNN naučí	294
9.4.1	Vizualizace mezilehlých 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 <i>Keras</i>	329
10.4	Pokročilé využití rekurentních neuronových sítí	333
10.4.1	Použití rekurentního dropoutu v boji proti přeučení	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 ptáčích 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 <i>TextVectorization</i>	350
	Použití vrstvy <i>TextVectorization</i> v datovodu <i>tf.data</i> 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 <i>IMDB</i>	354
11.3.2	Zpracování slov jako sady: přístup sada slov (<i>Bag-of-Words approach</i>)	356
	Jednotlivá slova s binárním kódováním (1-gramy, unigramy)	357
	Bigramy (2-gramy) s binárním kódováním	359
	Bigramy s kódováním <i>TF-IDF</i>	360
	Porozumění normalizaci <i>TF-IDF</i>	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 Embedding	367
	Porozumění výplním a maskování	368
	Použití předem natrénovaných slovních vnoření	370
11.4	Architektura Transformátor	372
11.4.1	Porozumění sebezpozornosti	373
	Zobecněná sebezpozornost: model dotaz-klíč-hodnota	376
11.4.2	Pozornost více hlav (<i>multi-head attention</i>)	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.....	407
	Příprava dat.....	408
	Model založený na transformátoru sekvence-sekvenci	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 autoenkodérů.....	431
12.4.1	Vzorkování z latentních prostorů obrazů.....	431
12.4.2	Koncepční vektory pro úpravy obrázků.....	432
12.4.3	Variační autoenkodéry	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 síť	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.....	454
	Používání KerasTuneru	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 dtype	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 tf.data	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 pojmů	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 síťové 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 inteligence.....	491
14.2.5	Šplhání po spektru zobecnění.....	492
14.3	Nastavení směru k větší obecnosti umělé inteligence.....	493
14.3.1	O důležitosti stanovení správného cíle: pravidlo zkratky	493
14.3.2	Nový cíl	495
14.4	Zavádění inteligence: 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 opakované 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