


O'REILLY®

Sztuczna inteligencja i uczenie maszynowe dla programistów

Praktyczny przewodnik
po sztucznej inteligencji



Helion 

Laurence Moroney
Przedmowa: Andrew Ng

Tytuł oryginału: AI and Machine Learning for Coders: A Programmer's Guide to Artificial Intelligence

Tłumaczenie: Jacek Janusz

ISBN: 978-83-283-7850-6

© 2021 Helion S.A.

Authorized Polish translation of the English edition AI and Machine Learning For Coders ISBN 9781492078197 © 2021 Laurence Moroney

This translation is published and sold by permission of O'Reilly Media, Inc., which owns or controls all rights to publish and sell the same.

Polish edition copyright © 2021 by Helion S.A.
All rights reserved.

All rights reserved. No part of this book may be reproduced or transmitted in any form or by any means, electronic or mechanical, including photocopying, recording or by any information storage retrieval system, without permission from the Publisher.

Wszelkie prawa zastrzeżone. Nieautoryzowane rozpowszechnianie całości lub fragmentu niniejszej publikacji w jakiegokolwiek postaci jest zabronione. Wykonywanie kopii metodą kserograficzną, fotograficzną, a także kopiowanie książki na nośniku filmowym, magnetycznym lub innym powoduje naruszenie praw autorskich niniejszej publikacji.

Wszystkie znaki występujące w tekście są zastrzeżonymi znakami firmowymi bądź towarowymi ich właścicieli.

Autor oraz wydawca dołożyli wszelkich starań, by zawarte w tej książce informacje były kompletne i rzetelne. Nie biorą jednak żadnej odpowiedzialności ani za ich wykorzystanie, ani za związane z tym ewentualne naruszenie praw patentowych lub autorskich. Autor oraz wydawca nie ponoszą również żadnej odpowiedzialności za ewentualne szkody wynikłe z wykorzystania informacji zawartych w książce.

Helion S.A.
ul. Kościuszki 1c, 44-100 Gliwice
tel. 32 231 22 19, 32 230 98 63
e-mail: helion@helion.pl
WWW: <http://helion.pl> (księgarnia internetowa, katalog książek)

Dodatkowe materiały do książki można znaleźć pod adresem:
<https://ftp.helion.pl/przyklady/szinum.zip>

Drogi Czytelniku!
Jeżeli chcesz ocenić tę książkę, zajrzyj pod adres
<http://helion.pl/user/opinie/szinum>
Możesz tam pisać swoje uwagi, spostrzeżenia, recenzję.

Printed in Poland.

- [Kup książkę](#)
- [Poleć książkę](#)
- [Oceń książkę](#)

- [Księgarnia internetowa](#)
- [Lubię to! » Nasza społeczność](#)

Spis treści

Słowo wstępne	13
---------------------	----

Przedmowa	15
-----------------	----

Część I. Tworzenie modeli

1. Wprowadzenie do biblioteki TensorFlow	21
--	----

Czym jest uczenie maszynowe?	21
------------------------------	----

Ograniczenia programowania tradycyjnego	23
---	----

Od programowania do uczenia	25
-----------------------------	----

Czym jest TensorFlow?	27
-----------------------	----

Użycie platformy TensorFlow	28
-----------------------------	----

Instalowanie platformy TensorFlow za pomocą języka Python	29
---	----

Użycie platformy TensorFlow w środowisku PyCharm	30
--	----

Użycie platformy TensorFlow w środowisku Google Colab	32
---	----

Pierwsze kroki z uczeniem maszynowym	34
--------------------------------------	----

Czego nauczyła się sieć?	39
--------------------------	----

Podsumowanie	39
--------------	----

2. Wprowadzenie do widzenia komputerowego	41
---	----

Rozpoznawanie elementów odzieży	41
---------------------------------	----

Dane: Fashion MNIST	42
---------------------	----

Neurony widzenia komputerowego	43
--------------------------------	----

Projektowanie sieci neuronowej	45
--------------------------------	----

Cały kod programu	46
-------------------	----

Trenowanie sieci neuronowej	48
-----------------------------	----

Analiza wyników modelu	49
------------------------	----

Trenowanie przez dłuższy czas — nadmierne dopasowanie	49
---	----

Zakończenie trenowania	50
------------------------	----

Podsumowanie	51
--------------	----

3. Bardziej zaawansowane zagadnienie: wykrywanie cech w obrazach	53
Konwolucje	53
Pooling	55
Implementacja konwolucyjnych sieci neuronowych	57
Analiza sieci konwolucyjnej	59
Tworzenie konwolucyjnej sieci neuronowej rozróżniającej konie i ludzi	61
Zbiór danych Horses or Humans	61
Klasa ImageDataGenerator z pakietu Keras	62
Architektura konwolucyjnej sieci neuronowej przetwarzającej zbiór Horses or Humans	64
Tworzenie zbioru walidacyjnego	66
Testowanie obrazów ze zbioru Horse or Human	67
Generowanie dodatkowych obrazów	70
Uczenie transferowe	73
Klasyfikowanie wieloklasowe	77
Regularyzacja dropout	80
Podsumowanie	83
 4. Korzystanie za pomocą biblioteki TensorFlow Datasets z publicznie dostępnych zbiorów danych	 85
Pierwsze kroki z TFDS	86
Użycie biblioteki TFDS z modelami Keras	88
Wczytywanie określonych wersji	90
Użycie funkcji mapowania do generowania sztucznych danych	91
Użycie biblioteki TensorFlow Addons	91
Korzystanie z niestandardowych podzbiorów	92
Czym jest TFRecord?	93
Użycie procesu ETL do zarządzania danymi w TensorFlow	96
Optymalizacja fazy wczytywania	97
Zrównoleglenie procesu ETL w celu poprawy wydajności trenowania	98
Podsumowanie	100
 5. Wprowadzenie do przetwarzania języka naturalnego	 101
Zamiana języka na liczby	101
Pierwsze kroki z tokenizacją	102
Zamiana zdań na sekwencje	103
Usuwanie słów nieinformatywnych i porządkowanie tekstu	106
Obsługa realnych źródeł danych	108
Pobieranie tekstu za pomocą biblioteki TensorFlow Datasets	108
Pobieranie tekstów z plików CSV	111
Pobieranie tekstów z plików JSON	113
Podsumowanie	116

6. Programowa analiza emocji za pomocą osadzeń	117
Ustalanie znaczenia słów	117
Prosty przykład: względne znaczenie słów	117
Przykład bardziej zaawansowany: użycie wektorów	118
Osadzenia w bibliotece TensorFlow	119
Tworzenie detektora sarkazmu przy użyciu osadzania	120
Zmniejszanie nadmiernego dopasowania w modelach językowych	122
Stosowanie modelu do klasyfikowania zdań	132
Wizualizacja osadzeń	133
Korzystanie ze wstępnie wytrenowanych osadzeń przy użyciu TensorFlow Hub	135
Podsumowanie	137
7. Użycie rekurencyjnych sieci neuronowych do przetwarzania języka naturalnego	139
Podstawy rekurencji	139
Zastosowanie rekurencji w przetwarzaniu języka naturalnego	142
Tworzenie klasyfikatora tekstu przy użyciu rekurencyjnych sieci neuronowych	144
Łączenie warstw LSTM	146
Użycie wstępnie wytrenowanych osadzeń w rekurencyjnych sieciach neuronowych	150
Podsumowanie	156
8. Użycie biblioteki TensorFlow do generowania tekstu	157
Zamiana sekwencji na sekwencje wejściowe	158
Tworzenie modelu	161
Generowanie tekstu	163
Prognozowanie następnego słowa	163
Łączenie prognoz w celu generowania tekstu	164
Poszerzenie zbioru danych	165
Zmiana architektury modelu	166
Ulepszenie danych	167
Kodowanie oparte na znakach	170
Podsumowanie	171
9. Sekwencje i dane szeregów czasowych	173
Wspólne atrybuty szeregów czasowych	174
Tendencja	174
Sezonowość	174
Autokorelacja	175
Szum	176
Metody prognozowania szeregów czasowych	176
Prosta metoda prognozowania jako punkt odniesienia	176
Pomiar dokładności prognozy	178

Metoda bardziej zaawansowana: wykorzystanie średniej ruchomej	179
Ulepszenie metody wykorzystującej średnią ruchomą	180
Podsumowanie	181
10. Tworzenie modeli uczenia maszynowego do prognozowania sekwencji	183
Tworzenie okna zbioru danych	184
Tworzenie okna zbioru danych szeregu czasowego	186
Tworzenie sieci DNN i jej trenowanie w celu dopasowania do danych sekwencji	187
Ocena wyników działania sieci DNN	189
Analiza ogólnej prognozy	190
Dostrajanie współczynnika uczenia	191
Dostrajanie hiperparametrów za pomocą narzędzia Keras Tuner	193
Podsumowanie	196
11. Użycie metod konwolucyjnych i rekurencyjnych w modelowaniu sekwencji	197
Użycie konwolucji z danymi sekwencyjnymi	197
Kodowanie konwolucji	198
Eksperymentowanie z hiperparametrami warstwy Conv1D	201
Korzystanie z danych pogodowych NASA	203
Odczytywanie danych GISS w Pythonie	204
Używanie sieci RNN do modelowania sekwencji	205
Korzystanie z większego zbioru danych	207
Użycie innych metod rekurencyjnych	210
Użycie dropoutu	210
Użycie dwukierunkowych sieci RNN	213
Podsumowanie	214

Część II. Używanie modeli

12. Wprowadzenie do TensorFlow Lite	217
Czym jest TensorFlow Lite?	217
Przykład: utworzenie modelu i przekonwertowanie go do formatu TensorFlow Lite	219
Krok 1. — zapisanie modelu	220
Krok 2. — konwersja i zapamiętanie modelu	220
Krok 3. — wczytanie modelu TFLite i alokacja tensorów	221
Krok 4. — przeprowadzenie prognozy	222
Przykład: wykorzystanie uczenia transferowego	
w klasyfikatorze obrazów i jego konwersja na format TensorFlow Lite	223
Krok 1. — utworzenie i zapisanie modelu	223
Krok 2. — konwersja modelu do formatu TensorFlow Lite	225
Krok 3. — optymalizacja modelu	226
Podsumowanie	228

13. Użycie TensorFlow Lite w systemie Android	229
Czym jest Android Studio?	229
Tworzenie pierwszej aplikacji opartej na TensorFlow Lite dla systemu Android	230
Krok 1. — utworzenie nowego projektu	230
Krok 2. — edycja pliku układu	231
Krok 3. — dodanie zależności TensorFlow Lite	234
Krok 4. — dodanie modelu TensorFlow Lite	235
Krok 5. — utworzenie kodu umożliwiającego użycie modelu TensorFlow Lite do wnioskowania	236
Coś więcej niż „Witaj, świecie!” — przetwarzanie obrazów	239
Przykładowe aplikacje wykorzystujące bibliotekę TensorFlow Lite	242
Podsumowanie	243
14. Użycie TensorFlow Lite w systemie iOS	245
Tworzenie pierwszej aplikacji TensorFlow Lite za pomocą Xcode	245
Krok 1. — utworzenie prostej aplikacji iOS	245
Krok 2. — dodanie bibliotek TensorFlow Lite do projektu	246
Krok 3. — utworzenie interfejsu użytkownika	247
Krok 4. — dodanie i zainicjalizowanie klasy odpowiedzialnej za operację prognozowania	251
Krok 5. — przeprowadzenie operacji prognozowania	253
Krok 6. — dodanie modelu do aplikacji	255
Krok 7. — dodanie logiki obsługującej interfejs użytkownika	255
Coś więcej niż „Witaj, świecie!” — przetwarzanie obrazów	258
Przykładowe aplikacje wykorzystujące bibliotekę TensorFlow Lite	260
Podsumowanie	261
15. Wprowadzenie do TensorFlow.js	263
Czym jest TensorFlow.js?	263
Instalowanie i używanie środowiska programistycznego Brackets	265
Tworzenie pierwszego modelu wykorzystującego bibliotekę TensorFlow.js	266
Tworzenie klasyfikatora irysów	269
Podsumowanie	273
16. Rozwiązywanie problemów z zakresu widzenia komputerowego za pomocą biblioteki TensorFlow.js	275
Uwagi dla programistów używających biblioteki TensorFlow dotyczące języka JavaScript	276
Tworzenie konwolucyjnej sieci neuronowej za pomocą języka JavaScript	277
Stosowanie wywołań zwrotnych do wizualizacji	279
Trenowanie za pomocą zbioru MNIST	281
Przeprowadzanie wnioskowania dla obrazów przy użyciu biblioteki TensorFlow.js	285
Podsumowanie	286

17. Konwersja modeli z Pythona do JavaScriptu i ponowne ich użycie	287
Konwersja modeli z Pythona do JavaScriptu	287
Użycie przekonwertowanych modeli	289
Użycie wcześniej przekonwertowanych modeli	291
Podsumowanie	299
18. Wykorzystanie uczenia transferowego w języku JavaScript	301
Uczenie transferowe przy użyciu biblioteki MobileNet	301
Krok 1. — pobranie modelu MobileNet i identyfikacja warstw do użycia	302
Krok 2. — utworzenie własnej architektury modelu, w której danymi wejściowymi są dane wyjściowe MobileNet	303
Krok 3. — uzyskanie i sformatowanie danych	306
Krok 4. — przeprowadzenie trenowania modelu	311
Krok 5. — przeprowadzenie wnioskowania za pomocą modelu	312
Uczenie transferowe przy użyciu repozytorium TensorFlow Hub	313
Użycie modeli z portalu TensorFlow.org	316
Podsumowanie	318
19. Wdrażanie modeli za pomocą usługi TensorFlow Serving	321
Czym jest TensorFlow Serving?	321
Instalowanie systemu TensorFlow Serving	324
Instalacja przy użyciu Dockera	324
Bezpośrednia instalacja w systemie Linux	325
Tworzenie i udostępnianie modelu	326
Konfigurowanie serwera	329
Podsumowanie	331
20. Sztuczna inteligencja a etyka, uczciwość i prywatność	333
Uczciwość w procesie programowania	334
Uczciwość w procesie uczenia maszynowego	337
Narzędzia związane z kwestiami uczciwości	338
What-If	338
Facets	340
Uczenie federacyjne	341
Krok 1. — identyfikacja dostępnych urządzeń, które można wykorzystać do trenowania	342
Krok 2. — identyfikacja odpowiednich urządzeń, które można wykorzystać do trenowania	342
Krok 3. — zainstalowanie modelu, który będzie używać zbioru treningowego	343

Krok 4. — zwrócenie wyników trenowania do serwera	344
Krok 5. — zainstalowanie modelu głównego w urządzeniach	344
Bezpieczna agregacja w uczeniu federacyjnym	345
Uczenie federacyjne przy użyciu TensorFlow Federated	346
Zasady firmy Google dotyczące sztucznej inteligencji	347
Podsumowanie	348

Użycie rekurencyjnych sieci neuronowych do przetwarzania języka naturalnego


Z rozdziału 5. wiesz, w jaki sposób tekst można przekształcać na ciągi tokenów. Po zamianie zdań na tensory, składające się z liczb, można je następnie wprowadzić do sieci neuronowej. W kolejnym rozdziale przeanalizowaliśmy osadzenia, które pozwalały zestawiać słowa o podobnym znaczeniu, aby umożliwić określanie rodzaju emocji. Z sukcesem wdrożyliśmy pomysł w praktyce poprzez zbudowanie klasyfikatora sarkazmu. Nie wzięliśmy jednak pod uwagę tego, że zdania nie są po prostu zbiorami niezależnych od siebie słów. Kolejność, w jakiej pojawiają się słowa, ma często bardzo wielki wpływ na znaczenie zdania. Na przykład przymiotniki mogą modyfikować znaczenie rzeczowników, obok których się pojawiają. Samo słowo „blue” może nie mieć znaczenia emocjonalnego, podobnie zresztą jak „sky”. Gdy je jednak połączysz, aby uzyskać wyrażenie „blue sky”, pojawia się wyraźny oddźwięk emocjonalny, który jest zwykle pozytywny. Niektóre rzeczowniki mogą wpływać na inne, na przykład „rain cloud”, „writing desk” czy „coffee mug”.

Aby wziąć pod uwagę takie związki, należy uwzględnić *rekurencję* w architekturze modelu. W tym rozdziale przeanalizujemy różne rozwiązania. Dowiesz się, w jaki sposób model może zdobyć wiedzę o kolejności słów, a dzięki temu lepiej zrozumieć tekst. W tym celu wykorzystamy **rekurencyjną sieć neuronową** (RNN).

Podstawy rekurencji

Aby zrozumieć, na czym polega działanie rekurencji, zastanówmy się najpierw nad ograniczeniami modeli zaprezentowanymi do tej pory w książce. Sposób tworzenia modelu przedstawiłem na rysunku 7.1. Dostarczasz dane i etykiety oraz definiujesz architekturę modelu, który uczy się reguł dopasowujących dane do etykiet. Reguły są dostępne w postaci interfejsu API, który zwraca prognozowane etykiety dla przyszłych danych.


Jak widać, dane do modelu są dostarczane hurtowo. Nie został podjęty żaden wysiłek, aby zrozumieć kolejność, w jakiej się one pojawiają. Oznacza to, że znaczenie słów „blue” i „sky” jest identyczne w zdaniach takich jak „Today I am blue, because the sky is gray” i „Today I am happy, and there’s a beautiful blue sky”. Czytelnicy, którzy znają język angielski, od razu zauważyli różnicę w użyciu tych słów, ale model z zaprezentowaną wcześniej architekturą tak naprawdę widzi to samo.



Rysunek 7.1. Wysokopoziomowy schemat tworzenia modelu

Jak można rozwiązać ten problem? Najpierw zbadajmy naturę rekurencji, a dzięki temu będziemy mogli zrozumieć, jak działa podstawowa sieć RNN.


Przyjrzyjmy się słynnemu ciągowi Fibonacciego. Jeśli o nim nie słyszałeś, na rysunku 7.2 możesz zobaczyć kilka początkowych liczb tego ciągu.



Rysunek 7.2. Kilka pierwszych liczb ciągu Fibonacciego

Pomysł polega na tym, że każda kolejna liczba jest sumą dwóch liczb ją poprzedzających. Jeśli zaczniemy od liczb 1 i 2, następną będzie $1 + 2$, czyli 3. W dalszej kolejności otrzymamy $2 + 3$, czyli 5, $3 + 5$, a więc 8, itd.


Nasze działania można zaprezentować w sposób graficzny na rysunku 7.3.



Rysunek 7.3. Graficzna reprezentacja ciągu Fibonacciego

Jaki widać, do funkcji przekazujemy liczby 1 i 2, a na wyjściu otrzymujemy 3. Przenosimy drugi parametr (2) do następnego kroku i wprowadzamy go do funkcji wraz z wartością wyjściową z poprzedniego (3). W wyniku otrzymujemy liczbę 5, którą przekazujemy do funkcji razem z drugim parametrem z poprzedniego kroku (3), aby uzyskać wartość 8. Proces ten trwa w nieskończoność, a każda kolejna operacja zależy od wcześniejszych. Można powiedzieć, że wartość 1 pokazana w lewym górnym rogu rysunku w pewien sposób „przetrwa” cały proces. Będzie zawarta w liczbie 3, która zostanie podana do funkcji drugiej, następnie w liczbie 5, która zostanie przekazana do funkcji trzeciej, itd. W ten sposób pewien fragment wartości 1 zostanie zachowany w całej sekwencji, chociaż jej wpływ na ogólny wynik będzie oczywiście niewielki.


W podobny sposób działa neuron rekurencyjny. Na rysunku 7.4 przedstawiłem typowy schemat połączeń w neuronie wykorzystującym rekurencję.



Rysunek 7.4. Neuron rekurencyjny

W pewnym przedziale czasowym wartość x (zazwyczaj oznaczana jako x_t) zostaje przekazana do funkcji F . W wyniku tej operacji w tym samym przedziale czasowym otrzymujemy wartość wyjściową y (zwykle oznaczaną jako y_t). Funkcja zwraca również wartość, która jest przekazywana do następnego kroku (przedstawiona na rysunku jako strzałka prowadząca od funkcji F do samej siebie).

Opis stanie się bardziej zrozumiały, jeśli przyjrzymy się, w jaki sposób neurony rekurencyjne współpracują ze sobą w kolejnych przedziałach czasowych (rysunek 7.5).



Rysunek 7.5. Działanie neuronów rekurencyjnych w kolejnych przedziałach czasowych


Dostarczywszy neuronowi wartości x_0 , uzyskujemy wynik y_0 oraz wartość, która jest przekazywana dalej. Jest ona używana w następnym kroku razem z wartością x_1 , powodując utworzenie wyniku y_1 i wartości, która ponownie zostanie dalej przekazana. W kolejnym kroku używamy jej razem z x_2 , dzięki czemu tworzymy y_2 oraz wartość przekazywaną, itd. Proces ten jest podobny do tego, który wcześniej zaprezentowałem w przypadku rozwiązywania ciągu Fibonacciego. Warto o nim pamiętać, gdy chcemy sobie przypomnieć, jak działa rekurencyjna sieć neuronowa.

Zastosowanie rekurencji w przetwarzaniu języka naturalnego

Wiesz już, że rekurencyjna sieć neuronowa pozwala na obsługę kontekstu sekwencji w kolejnych przedziałach czasowych. W dalszej części książki pokażę, że sieci RNN rzeczywiście są używane do modelowania sekwencji. Korzystanie z tak prostej rekurencyjnej sieci neuronowej, jaka została przedstawiona na rysunkach 7.4 i 7.5, wiąże się jednak z pewnym problemem, który można przeoczyć. Jak już wspomniałem w przypadku ciągu Fibonacciego, poziom przekazywanego kontekstu będzie z czasem maleć. Wpływ wartości wynikowej otrzymanej z neuronu w kroku 1. jest ogromny, w kroku 2. maleje, w kroku 3. jest jeszcze mniejszy itd. Jeśli więc mamy zdanie typu „Today has a beautiful blue <coś>”, wówczas słowo „blue” będzie miało silny wpływ na kolejny wyraz — możemy się domyślić, że prawdopodobnie będzie nim „sky”. Co się stanie jednak z kontekstem, który wynika z wcześniejszego fragmentu zdania? Weźmy na przykład zdanie „I lived in Ireland, so in high school I had to learn how to speak and write <coś>”.

W miejscu szablonu „<coś>” należy oczywiście wstawić słowo „Gaelic”, ale wynika to z odpowiedniego kontekstu, którym jest słowo „Ireland” znajdujące się na samym początku zdania. Abyśmy zatem wiedzieli, czym należy zastąpić szablon „<coś>”, musimy wymyślić sposób na zachowanie bardziej odległego kontekstu. Pamięć krótkotrwała sieci RNN musi więc zostać wydłużona, w związku z czym wynaleziono lepszą architekturę zwaną **długą pamięcią krótkotrwałą** (LSTM).


Chociaż nie będę wchodził w szczegóły związane z działaniem podstawowej architektury LSTM, na rysunku 7.6 zaprezentowałem jej wysokopoziomowy schemat. Aby dowiedzieć się więcej o operacjach wewnętrznych, zapoznaj się z doskonałym wpisem na blogu Christophera Olaha (<https://oreil.ly/6KcFA>).



Rysunek 7.6. Wysokopoziomowy schemat architektury LSTM


Architektura LSTM usprawnia sposób działania podstawowej sieci RNN poprzez uwzględnienie „stanu komórki”, który umożliwia przekazywanie kontekstu nie tylko pomiędzy bezpośrednio występującymi po sobie krokami, ale przez całą ich sekwencję. Biorąc pod uwagę to, że mamy do czynienia z neuronami, dzięki takiemu rozwiązaniu sieć z czasem nauczy się kontekstu.

Ważną cechą architektury LSTM jest to, że może działać w dwóch kierunkach. Informację można przetwarzać w przedziałach czasowych zarówno do przodu, jak i do tyłu, dzięki czemu sieć może poznać kontekst na dwa sposoby. Spójrz na rysunek 7.7, aby się zapoznać z wysokopoziomowym schematem rozwiązania.



Rysunek 7.7. Wysokopoziomowy schemat dwukierunkowej architektury LSTM

Sieć wykonuje ewaluację, poczynając od kroku 0., a kończąc na kroku *maksymalna_liczba_kroków*, jak również odwrotnie — od *maksymalnej_liczby_kroków* do kroku 0. W każdym przedziale czasowym wynikiem y jest połączenie przejścia „do przodu” i „wstecz”. Odpowiedni schemat można zobaczyć na rysunku 7.8.



Rysunek 7.8. Działanie dwukierunkowej architektury LSTM

Założmy, że każdy neuron w danym przedziale czasowym będzie oznaczony symbolem F0, F1, F2 itd. Na rysunku pokazałem kierunki przetwarzania, więc obliczenia dla neuronu F1 w przypadku przejścia do przodu oznaczyłem jako F1(->), a wstecz jako (-<)F1. Aby uzyskać wartość y dla określonego przedziału czasowego, sumowane są elementarne wyniki. Również stan komórki jest dwukierunkowy.

Takie rozwiązanie może być naprawdę przydatne do zarządzania kontekstem w zdaniach. W przypadku zdania „I lived in Ireland, so in high school I had to learn how to speak and write <coś>” szablon „<coś>” został zamieniony na słowo „Gaelic” po wykryciu słowa kontekstowego „Ireland”. A gdyby było odwrotnie? Weźmy zdanie „I lived in <kraj>, so in high school I had to learn how to speak and write Gaelic”. Analizując je od tyłu, możemy się dowiedzieć, czym powinien zostać zastąpiony szablon „<kraj>”. Korzystanie z dwukierunkowych architektur LSTM może być bardzo przydatne podczas wykrywania emocji w tekście (z rozdziału 8. dowiesz się, że są one również naprawdę niesamowite podczas generowania tekstów!).

Oczywiście architektury LSTM, a w szczególności dwukierunkowe, są skomplikowane, więc należy oczekiwać, że ich trenowanie będzie przebiegać wolno. W takim przypadku warto zainwestować w procesory graficzne (a przynajmniej skorzystać ze środowiska Google Colab).

Tworzenie klasyfikatora tekstu przy użyciu rekurencyjnych sieci neuronowych

W rozdziale 6. podczas eksperymentowania utworzyliśmy przy użyciu osadzeń klasyfikator dla zbioru danych Sarcasm. Słowa przed agregacją były przekształcane w wektory, a następnie wprowadzane do warstw gęstych w celu klasyfikowania. Podczas korzystania z warstwy RNN takiej jak LSTM nie wykonuje się agregacji, więc dane wyjściowe z warstwy osadzania można przekazywać bezpośrednio do warstwy rekurencyjnej. Jeśli chodzi o jej wymiar, jest on często równy wymiarowi warstwy osadzania. Nie jest to warunek konieczny, ale może być dobrym wyborem na początku. Jak pamiętasz, w rozdziale 6. wspomniałem, że wymiar osadzania jest często czwartym pierwiastkiem rozmiaru słownika. Podczas korzystania z sieci RNN ta reguła jest w wielu przypadkach ignorowana, ponieważ spowodowałaby, że rozmiar warstwy rekurencyjnej byłby zbyt mały.

Zmodyfikujmy prostą architekturę modelu służącego do klasyfikowania sarkazmu, którą wykorzystywaliśmy w rozdziale 6., i użyjmy w niej dwukierunkowej warstwy LSTM:

```
model = tf.keras.Sequential([
    tf.keras.layers.Embedding(vocab_size, embedding_dim),
    tf.keras.layers.Bidirectional(tf.keras.layers.LSTM(embedding_dim)),
    tf.keras.layers.Dense(24, activation='relu'),
    tf.keras.layers.Dense(1, activation='sigmoid')
])
```

Funkcję straty i klasyfikator można zdefiniować za pomocą następującego kodu (zwróć uwagę, że współczynnik uczenia wynosi 0,00001, co jest równoważne $1e-5$):


```
adam = tf.keras.optimizers.Adam(learning_rate=0.00001,
                                  beta_1=0.9, beta_2=0.999, amsgrad=False)

model.compile(loss='binary_crossentropy',
              optimizer=adam, metrics=['accuracy'])
```

Spróbuj wyświetlić podsumowanie architektury modelu. Pamiętaj, że rozmiar słownika wynosi 20 000, a wymiar osadzania jest równy 64. W wyniku tego otrzymujemy 1 280 000 parametrów w warstwie osadzania, przy czym warstwa dwukierunkowa ma 128 neuronów (64 w przód, 64 wstecz):


Layer (type)	Output Shape	Param #
embedding_11 (Embedding)	(None, None, 64)	1280000
bidirectional_7 (Bidirection	(None, 128)	66048
dense_18 (Dense)	(None, 24)	3096
dense_19 (Dense)	(None, 1)	25
Total params: 1,349,169		
Trainableparams: 1,349,169		
Non-trainableparams: 0		

Na rysunku 7.9 pokazałem wyniki trenowania modelu przez 30 epok.



Rysunek 7.9. Wykres zmian dokładności modelu LSTM w ciągu 30 epok

Dokładność sieci dla danych treningowych szybko wzrasta do wartości powyżej 90%, jednak w przypadku danych walidacyjnych pozostaje na poziomie około 80%. Podobne wyniki otrzymywaliśmy już wcześniej. Na rysunku 7.10 widzimy, że wykresy strat rozeszły się po mniej więcej 15 epokach. W przypadku danych walidacyjnych wykres uległ spłaszczeniu, a strata, pomimo użycia 20 000 słów zamiast 2000, osiągnęła znacznie niższą wartość niż na wykresach z rozdziału 6.



Rysunek 7.10. Wykres zmian straty modelu LSTM w ciągu 30 epok

Użyliśmy tylko jednej warstwy LSTM. W kolejnym punkcie dowiesz się, w jaki sposób można łączyć ze sobą warstwy LSTM, a także sprawdzisz, jaki wpływ ma to rozwiązanie na dokładność klasyfikowania zbioru danych.

Łączenie warstw LSTM

Z poprzedniego punktu wiesz, że warstwę LSTM można umieścić po warstwie osadzania, aby ulepszyć klasyfikowanie zawartości zbioru danych Sarcasm. Warstwy LSTM można jednak układać jedną na drugiej. Takie rozwiązanie jest stosowane w wielu najnowocześniejszych modelach służących do przetwarzania języka naturalnego.

Układanie warstw LSTM w stos staje się całkiem prostą operacją przy użyciu biblioteki TensorFlow. Dodajesz je po prostu do modelu, tak jak w przypadku warstwy gęstej. Pamiętaj jedynie, że wszystkie warstwy oprócz ostatniej muszą mieć właściwość `return_sequences` równą `True`. Oto przykład:

```
model = tf.keras.Sequential([
    tf.keras.layers.Embedding(vocab_size, embedding_dim),
    tf.keras.layers.Bidirectional(tf.keras.layers.LSTM(embedding_dim, return_sequences=True)),
    tf.keras.layers.Bidirectional(tf.keras.layers.LSTM(embedding_dim)),
    tf.keras.layers.Dense(24, activation='relu'),
    tf.keras.layers.Dense(1, activation='sigmoid')
])
```

Ostatnia warstwa może również używać właściwości `return_sequences` o wartości `True`. W takim przypadku w celu klasyfikowania zwraca ona do warstw gęstych całe sekwencje zamiast pojedynczych wartości. Może to być przydatne podczas analizowania wyników, o czym napiszę później. Architektura modelu wygląda następująco:

Layer (type)	OutputShape	Param #
=====		
embedding_12 (Embedding)	(None, None, 64)	1280000

bidirectional_8 (Bidirection	(None, None, 128)	66048


bidirectional_9 (Bidirection	(None, 128)	98816

dense_20 (Dense)	(None, 24)	3096

dense_21 (Dense)	(None, 1)	25
=====		
Total params: 1,447,985		
Trainable params: 1,447,985		
Non-trainable params: 0		


Dodanie warstwy spowoduje, że pojawi się około 100 000 nowych parametrów, których sieć będzie się musiała nauczyć. Oznacza to wzrost o mniej więcej 8%. Może to więc spowolnić działanie sieci, ale koszt ten będzie stosunkowo niski, jeśli przyniesie rozsądne korzyści.

Po trenowaniu trwającym 30 epok uzyskaliśmy wynik przedstawiony na rysunku 7.11. Choć dokładność zbioru walidacyjnego od pewnego momentu się nie zmienia, wykres straty (rysunek 7.12) mówi coś zupełnie innego.



Rysunek 7.11. Wykres zmian dokładności w modelu używającym kilku warstw LSTM

Jak widać na rysunku 7.12, mimo że uzyskaliśmy całkiem niezłą dokładność, strata zbioru walidacyjnego szybko wzrosła, co jest wyraźnym znakiem nadmiernego dopasowania.



Rysunek 7.12. Wykres zmian straty w modelu używającym kilku warstw LSTM

Rosnąca dokładność i zmniejszanie się straty dla zbioru treningowego, a także względnie stała dokładność i drastyczny wzrost straty dla zbioru walidacyjnego oznaczają nadmierne dopasowanie. Jest to wynik zbyt wysokiego wyspecjalizowania się modelu w danych ze zbioru treningowego. Podobną sytuację mieliśmy już w przykładach z rozdziału 6. Biorąc pod uwagę jedynie wskaźnik dokładności bez uwzględniania straty, można łatwo wyciągnąć fałszywy wniosek, że model działa prawidłowo.

Optymalizacja modeli z wieloma warstwami LSTM


Z rozdziału 6. wiesz, że bardzo skuteczną metodą ograniczania nadmiernego dopasowania jest zmniejszanie współczynnika uczenia. Warto sprawdzić, czy takie rozwiązanie będzie miało pozytywny wpływ również na działanie rekurencyjnej sieci neuronowej.

Za pomocą poniższego kodu zmniejszamy wartość współczynnika uczenia o 20% — z 0,00001 do 0,000008:

```
adam = tf.keras.optimizers.Adam(learning_rate=0.000008,
    beta_1=0.9, beta_2=0.999, amsgrad=False)


model.compile(loss='binary_crossentropy',
    optimizer=adam, metrics=['accuracy'])
```

Wykres dokładności pokazałem na rysunku 7.13. Wygląda na to, że wyniki praktycznie nie uległy zmianie, chociaż krzywe (szczególnie w przypadku zbioru walidacyjnego) są trochę gładzsze.



Rysunek 7.13. Wpływ zmniejszonej wartości współczynnika uczenia na dokładność modelu z wieloma warstwami LSTM

Pierwszy rzut oka na rysunek 7.14 również sugeruje podobny, minimalny wpływ zmniejszonej wartości współczynnika uczenia na stratę. Wykresowi należy jednak dokładniej się przyjrzeć. Pomimo mniej więcej podobnego kształtu krzywej tempo wzrostu straty jest wyraźnie niższe: po 30 epokach strata wynosi około 0,6, podczas gdy przy wyższym współczynniku uczenia była bliska 0,8. Z pewnością warto więc poeksperymentować z modyfikacją hiperparametru współczynnika uczenia.



Rysunek 7.14. Wpływ zmniejszonej wartości współczynnika uczenia na stratę modelu z wieloma warstwami LSTM

Użycie dropoutu


Oprócz zmiany parametru współczynnika uczenia warto również rozważyć użycie opcji dropoutu w warstwach LSTM. Działa ona dokładnie tak samo jak w przypadku warstw gęstych — losowo wybrane neurony są pomijane, aby zmniejszyć ich negatywny wpływ na uczenie.

Dropout można włączyć w warstwie LSTM za pomocą odpowiedniego parametru. Oto przykład:

```
model = tf.keras.Sequential([
    tf.keras.layers.Embedding(vocab_size, embedding_dim),
    tf.keras.layers.Bidirectional(tf.keras.layers.LSTM(embedding_dim, return_sequences=True,
        dropout=0.2)),
    tf.keras.layers.Bidirectional(tf.keras.layers.LSTM(embedding_dim, dropout=0.2)),
    tf.keras.layers.Dense(24, activation='relu'),
    tf.keras.layers.Dense(1, activation='sigmoid')
])
```

Pamiętaj, że włączenie dropoutu znacznie spowolni proces trenowania. U mnie (używałem środowiska Colab) czas trenowania w przypadku pojedynczej epoki wzrósł z około 10 sekund aż do 180 sekund.

Wykres dokładności przedstawiłem na rysunku 7.15.




Rysunek 7.15. Wykres zmian dokładności w modelu LSTM wykorzystującym dropout

Jak widać na rysunku 7.15, zastosowanie dropoutu nie ma dużego wpływu na dokładność sieci, co jest jednak dobrym wynikiem! Zawsze przecież istnieje obawa, że zmniejszenie liczby aktywnych neuronów pogorszy działanie modelu. Widzimy jednak, że tak się nie stało.

Włączenie dropoutu ma jednak pozytywny wpływ na wartość straty, co przedstawiłem na rysunku 7.16.

Chociaż krzywe wyraźnie się rozdziwiają, znajdują się bliżej siebie niż poprzednio. Strata dla zbioru walidacyjnego stabilizuje się szybko w okolicach wartości 0,5. To znacznie lepiej niż w poprzednim modelu, w którym wynosiła 0,8. Jak pokazuje ten przykład, dropout to kolejne przydatne rozwiązanie, którego można użyć do poprawy wydajności sieci RNN opartych na warstwach LSTM.

Aby uniknąć nadmiernego dopasowania, warto pamiętać o powyżej przedstawionych metodach, a także o procedurach związanych z wstępnym przetwarzaniem danych, które omówiłem w rozdziale 6. Jest jednak jedno rozwiązanie, którego jeszcze nie przetestowaliśmy. Chodzi o określony rodzaj uczenia transferowego, w którym zamiast przeprowadzać żmudny proces trenowania wykorzystuje się wstępnie wytrenowane osadzenia dla słów.



Rysunek 7.16. Wykres zmian straty w modelu LSTM wykorzystującym dropout

Użycie wstępnie wytrenowanych osadzeń w rekurencyjnych sieciach neuronowych

Do tej pory analizowaliśmy przykłady, w których zbiór treningowy zawierał wszystkie dostępne słowa. Za pomocą tego zbioru trenowaliśmy osadzenia, które przed przekazaniem ich do sieci gęstej musiały zostać zagregowane. Z tego rozdziału wiesz już, jak poprawić wyniki działania sieci RNN. Mogliśmy jednak używać jedynie słów oraz etykiet zawartych w zbiorze danych.

Wróćmy do rozdziału 4., w którym przeanalizowaliśmy uczenie transferowe. Co by się stało, gdybyśmy zamiast samodzielnie realizować proces uczenia użyli wcześniej wytrenowanych osadzeń, dla których została już wykonana ciężka praca polegająca na zamianie słów na sprawdzone wektory? Jednym z przykładów takiego rozwiązania jest model GloVe (Global Vectors for Word Representation) (<https://oreil.ly/4ENdQ>), opracowany przez Jeffreya Penningtona, Richarda Sochera i Christophera Manninga z Uniwersytetu Stanforda.

Na podstawie wstępnie wytrenowanych wektorów słów naukowcy stworzyli następujące zbiory danych:

- słownik zawierający 6 miliardów tokenów i 400 tysięcy słów, dostępny w 50, 100, 200 i 300 wymiarach, zawierający treści z Wikipedii i archiwum Gigaword;
- słownik zawierający 42 miliardy tokenów i 1,9 miliona słów, dostępny w 300 wymiarach, zawierający treści uzyskane po przeszukaniu internetu;
- słownik zawierający 840 miliardów tokenów i 2,2 miliona słów, dostępny w 300 wymiarach, zawierający treści uzyskane po przeszukaniu internetu;
- słownik zawierający 27 miliardów tokenów i 1,2 miliona słów, dostępny w 25, 50, 100 i 200 wymiarach, zawierający treści otrzymane po przeszukaniu Twittera z 2 miliardami tweetów.

Ponieważ wektory zostały już wstępnie wytrenowane, zamiast przeprowadzać uczenie od zera można ich w prosty sposób ponownie użyć w kodzie korzystającym z biblioteki TensorFlow. Najpierw należy pobrać bazę GloVe. Zdecydowałem się użyć danych Twittera z 27 miliardami tokenów i słownikiem zawierającym 1,2 miliona słów. Pobierane jest archiwum z 25, 50, 100 i 200 wymiarami.

Aby ułatwić przeprowadzenie testów, udostępniłem wersję 25-wymiarową. Za pomocą poniższego kodu możesz ją pobrać do środowiska Colab:

```
!wget --no-check-certificate \
  https://storage.googleapis.com/laurencemoroney-blog.appspot.com/glove.twitter.27B.25d.zip \
  -O /tmp/glove.zip
```

Jest to archiwum ZIP, więc możesz je rozpakować, aby uzyskać plik o nazwie *glove.twitter.27b.25d.txt*:

```
# Rozpakowywanie osadzeń GloVe
import os
import zipfile

local_zip = '/tmp/glove.zip'
zip_ref = zipfile.ZipFile(local_zip, 'r')
zip_ref.extractall('/tmp/glove')
zip_ref.close()
```

Każdy wpis w pliku jest słowem, po którym występują wytrenowane współczynniki wymiarów. Aby wczytać plik, należy utworzyć słownik, w którym kluczami będą słowa, a wartościami osadzenia. Oto odpowiedni kod:

```
glove_embeddings = dict()
f = open('/tmp/glove/glove.twitter.27B.25d.txt')
for line in f:
    values = line.split()
    word = values[0]
    coefs = np.asarray(values[1:], dtype='float32')
    glove_embeddings[word] = coefs
f.close()
```

Dzięki słownikowi możesz wyszukiwać współczynniki dla dowolnego słowa, używając go po prostu jako klucza. Na przykład aby się dowiedzieć, jakie osadzenia są związane ze słowem „frog”, możesz wykonać poniższą instrukcję:

```
glove_embeddings['frog']
```

Następnie, tak jak poprzednio, użyj tokenizera, aby uzyskać indeks słów dla zbioru zdań. Jednak teraz możesz utworzyć nową strukturę, która nazywa się *macierzą osadzania*. Dzięki niej można będzie użyć osadzeń ze zbioru GloVe (pobranych ze słownika *glove_embeddings*) jako wartości. Wyświetlmy kilka początkowych słów ze zbioru danych:

```
{ '<00V>': 1, 'new': 2, ... 'not': 5, 'just': 6, 'will': 7
```

Pierwszy wiersz w macierzy osadzania powinien więc zawierać współczynniki dla słowa '<00V>', następny dla słowa 'new' itd.

Macierz możesz utworzyć za pomocą następującego kodu:

```
embedding_matrix = np.zeros((vocab_size, embedding_dim))
for word, index in tokenizer.word_index.items():
    if index > vocab_size - 1:
        break
    else:
        embedding_vector = glove_embeddings.get(word)
        if embedding_vector is not None:
            embedding_matrix[index] = embedding_vector
```

Kod ten tworzy macierz przy użyciu dwóch parametrów równych rozmiarowi słownika i wymiarom osadzania. Następnie dla każdego elementu w indeksie słów tokenizera wyszukujesz współczynniki zawarte w słowniku `glove_embeddings` i dodajesz je do macierzy.

Możesz odpowiednio zmodyfikować warstwę osadzania, by używała wstępnie wytrenowanych osadzeń. W tym celu stosujesz parametr `weights`, a także określasz, by warstwa nie była trenowana, ustawiając parametr `trainable = False`:

```
model = tf.keras.Sequential([
    tf.keras.layers.Embedding(vocab_size, embedding_dim,
                             weights=[embedding_matrix], trainable=False),
    tf.keras.layers.Bidirectional(tf.keras.layers.LSTM(embedding_dim,
                                                         return_sequences=True)),
    tf.keras.layers.Bidirectional(tf.keras.layers.LSTM(embedding_dim)),
    tf.keras.layers.Dense(24, activation='relu'),
    tf.keras.layers.Dense(1, activation='sigmoid')
])
```

Podobnie jak w przypadku poprzednich modeli, możesz teraz przeprowadzić trenowanie. Warto jednak rozważyć zmianę rozmiaru słownika. Jedną z optymalizacji, jakie wykonaliśmy w poprzednim rozdziale, aby uniknąć nadmiernego dopasowania, miała na celu zapobiec przeciążeniu osadzeń słowami o niskiej częstotliwości występowania. Użyliśmy do tego mniejszego słownika, zawierającego częściej wykorzystywane słowa. Ponieważ osadzanie słów zostało już wytrenowane za pomocą zbioru GloVe, można spróbować poszerzyć słownik — ale jak bardzo?

Przede wszystkim sprawdź, ile słów z Twojego zestawu zdań zawiera się w zbiorze GloVe. Składa się on co prawda z 1,2 miliona elementów, ale nie ma przecież gwarancji, że zawiera wszystkie Twoje słowa.

Poniżej przedstawię kod, który pozwoli przeprowadzić szybkie porównanie, dzięki któremu się dowiesz, jak duży powinien być Twój słownik.

Najpierw uporządkujmy dane. Utwórz listę składającą się z elementów X i Y , gdzie X jest indeksem słowa, a $Y = 1$, jeśli słowo znajduje się w osadzeniach (w przeciwnym razie $Y = 0$). Dodatkowo możesz utworzyć zbiorczy zestaw, w którym będziesz zapisywać współczynnik wystąpień słów. Na przykład słowo '<00v>' o indeksie 0 nie występuje w zbiorze GloVe, więc łączna wartość Y będzie równa 0. Kolejne słowo, 'new', jest zawarte w GloVe, więc łączna wartość Y wyniesie w tym momencie 0,5 (co oznacza, że połowa dotychczasowych słów znajduje się w GloVe). W taki sposób będziesz wyznaczać wartość aż do osiągnięcia końca zbioru:


```
xs=[]
ys=[]
cumulative_x=[]
cumulative_y=[]
total_y=0
for word, index in tokenizer.word_index.items():
    xs.append(index)
    cumulative_x.append(index)
    if glove_embeddings.get(word) is not None:
        total_y = total_y + 1
        ys.append(1)
    else:
        ys.append(0)
    cumulative_y.append(total_y / index)
```

Za pomocą tego kodu narysujesz wykres wartości X i Y :

```
import matplotlib.pyplot as plt
fig, ax = plt.subplots(figsize=(12,2))
ax.spines['top'].set_visible(False)

plt.margins(x=0, y=None, tight=True)
#plt.axis([13000, 14000, 0, 1])
plt.fill(ys)
```

W ten sposób uzyskasz wykres częstości występowania słów (rysunek 7.17).




Rysunek 7.17. Wykres częstości występowania słów

Jak widać, gęstość wykresu zmienia się znacząco dla indeksów zawartych w przedziale od 10 000 do 15 000. Słowa, które *nie są* zawarte w osadzeniach zbioru GloVe, zaczynają częściej występować niż te, które się *w nich znajdują*. Ma to miejsce w pobliżu tokenu o numerze 13 000.

Możesz to lepiej zrozumieć, jeśli wykreślisz wykres wartości `cumulative_x` i `cumulative_y`. Oto odpowiedni kod:

```
import matplotlib.pyplot as plt
plt.plot(cumulative_x, cumulative_y)
plt.axis([0, 25000, .915, .985])
```

Wynik przedstawiłem na rysunku 7.18.




Rysunek 7.18. Częstość występowania słów w bazie GloVe

Możesz również odpowiednio zmodyfikować parametry wywołania `plt.axis`, aby znaleźć i przybliżyć punkt przegięcia, w którym słowa nieobecne w zbiorze GloVe zaczynają częściej występować niż te, które są w nim zawarte. Na podstawie uzyskanego wyniku możesz odpowiednio zmodyfikować wielkość słownika.

Skorzystawszy z powyższej metody, zdecydowałem się użyć słownika o rozmiarze 13 200 (zamiast 2000, który był poprzednio stosowany, aby uniknąć nadmiernego dopasowania) oraz takiej architektury modelu, w której liczba wymiarów `embedding_dim` wynosi 25 ze względu na wykorzystywany zbiór GloVe:


```
model = tf.keras.Sequential([
    tf.keras.layers.Embedding(vocab_size, embedding_dim, weights=[embedding_matrix],
        trainable=False),
    tf.keras.layers.Bidirectional(tf.keras.layers.LSTM(embedding_dim, return_sequences=True)),
    tf.keras.layers.Bidirectional(tf.keras.layers.LSTM(embedding_dim)),
    tf.keras.layers.Dense(24, activation='relu'),
    tf.keras.layers.Dense(1, activation='sigmoid')
])
adam = tf.keras.optimizers.Adam(learning_rate=0.00001, beta_1=0.9, beta_2=0.999, amsgrad=False)
model.compile(loss='binary_crossentropy', optimizer=adam, metrics=['accuracy'])
```

Trenując sieć przez 30 epok, uzyskaliśmy doskonałe rezultaty. Wykres dokładności przedstawiłem na rysunku 7.19. Dokładność walidacji jest bardzo zbliżona do dokładności trenowania, co wskazuje, że nadmierne dopasowanie nie jest już problemem.



Rysunek 7.19. Dokładność w modelu z wieloma warstwami LSTM wykorzystującym osadzenia zbioru GloVe


Potwierdza to również wykres strat, który pokazałem na rysunku 7.20. Nie ma już praktycznie różnicy między wartościami straty dla zbiorów walidacyjnego i treningowego. Chociaż dokładność wynosi tylko około 73%, możemy być jej pewni.



Rysunek 7.20. Strata w modelu z wieloma warstwami LSTM wykorzystującym osadzenia zbioru GloVe


Po wytrenowaniu modelu przez dłuższy czas uzyskujemy bardzo podobne wyniki. Mimo że nadmierne dopasowanie pojawia się w okolicach 80. epoki, model jest nadal bardzo stabilny.

Wykres dokładności na rysunku 7.21 pokazuje, że model został dobrze wytrenowany.



Rysunek 7.21. Dokładność w modelu z wieloma warstwami LSTM wykorzystującym osadzenia zbioru GloVe i trenowanym przez 150 epok

Na wykresie straty z rysunku 7.22 widać, że różnice zaczynają narastać w przybliżeniu od 80. epoki, jednak model jest nadal dobrze dopasowany.



Rysunek 7.22. Strata w modelu z wieloma warstwami LSTM wykorzystującym osadzenia zbioru GloVe i trenowanym przez 150 epok

Wygłąda na to, że ten model można wcześniej zatrzymać, czyli po prostu trenować go przez 75–80 epok, aby uzyskać optymalne wyniki.

Przetestowałem go z tekstami pochodzącymi z witryny The Onion, będącej źródłem sarkastycznych nagłówków dla zbioru danych Sarcasm, a także z innymi zdaniami:

```
test_sentences = ["It Was, For, Uh, Medical Reasons, Says Doctor To Boris Johnson, Explaining  
↳ Why They Had To Give Him Haircut",  
"It's a beautiful sunny day",  
"I lived in Ireland, so in high school they made me learn to speak and write in Gaelic",  
"Census Foot Soldiers Swarm Neighborhoods, Kick Down Doors To TallyHousehold Sizes"]
```

Otrzymane wyniki są następujące (pamiętaj, że wartości bliskie 50% (0,5) oznaczają treści neutralne, bliskie 0 niesarkastyczne, a bliskie 1 sarkastyczne):

```
[[0.8170955 ]  
 [0.08711044]  
 [0.61809343]  
 [0.8015281 ]]
```

Pierwsze i czwarte zdanie, oba zaczerpnięte z witryny The Onion, zostały ocenione jako sarkastyczne (z prawdopodobieństwem wyższym niż 80%). Wypowiedź o pogodzie była zdecydowanie niesarkastyczna (9%), a informację o uczęszczaniu do liceum w Irlandii model uznał za potencjalnie sarkastyczną, ale nie był tego pewny (62%).

Podsumowanie

W tym rozdziale zaprezentowałem rekurencyjne sieci neuronowe, które wykorzystują logikę zorientowaną na sekwencje, dzięki czemu oceniają zdania nie tylko na podstawie zawartych w nich słów, ale także kolejności, w jakiej się one pojawiają. Dowiedziałeś się, jak działa podstawowa sieć RNN, a także w jaki sposób wykorzystuje się w niej warstwy LSTM, aby uzyskać możliwość długotrwałego przechowywania kontekstu. Użyliśmy ich, żeby ulepszyć model wykrywania emocji, który wcześniej stworzyliśmy. Następnie przeanalizowaliśmy problemy związane z nadmiernym dopasowaniem sieci RNN i metody jego unikania, między innymi uczenie transferowe na podstawie wstępnie wytrenowanych osadzeń. Zdobytą wiedzę wykorzystasz w rozdziale 8., by przewidywać słowa. Dzięki temu zaprojektujesz model, który tworzy teksty w postaci wierszy.

PROGRAM PARTNERSKI

— GRUPY HELION —



1. ZAREJESTRUJ SIĘ
2. PREZENTUJ KSIĄŻKI
3. ZBIERAJ PROWIZJĘ

Zmień swoją stronę WWW w działający bankomat!

Dowiedz się więcej i dołącz już dzisiaj!

<http://program-partnerski.helion.pl>

GRUPA
Helion 

Uczenie maszynowe: nie przestawaj zdobywać wiedzy!

Sztuczna inteligencja i uczenie maszynowe znajdują coraz więcej zastosowań w niemal wszystkich istotnych branżach. W technologiach sieci neuronowych tkwi olbrzymi potencjał. Za rozwojem uczenia maszynowego muszą nadążać architekci i programiści: aplikacja, w której wykorzystano technologie sztucznej inteligencji, musi pasować do określonego zastosowania. Poszczególne systemy różnią się od siebie, tak samo jak różne są rozwiązywane przez nie problemy. Sztuczna inteligencja ujawni swoje ogromne możliwości tylko, jeśli inżynierowie dostosują swoje aplikacje do rozwiązywania konkretnych problemów.

Ta książka jest praktycznym podręcznikiem opartym na sprawdzonej metodyce: nauce poprzez pisanie kodu w Pythonie. Aby w pełni z niego skorzystać, nie musisz znać wyższej matematyki. Dzięki praktycznym lekcjom szybko zaczniesz programowo tworzyć konkretne rozwiązania. Dowiesz się, jak można zaimplementować najważniejsze algorytmy uczenia maszynowego, korzystając ze znakomitej biblioteki TensorFlow. Nauczysz się także, w jaki sposób wdrażać modele uczenia maszynowego i tworzyć przydatne aplikacje, które będą działały w różnych środowiskach i na różnych platformach: przykładowo napiszesz aplikację w języku Kotlin w środowisku Android Studio czy też w języku Swift w środowisku Xcode.

W książce między innymi:

- podstawy uczenia maszynowego
- zastosowanie biblioteki TensorFlow do budowy praktycznych modeli
- tworzenie modeli sieci neuronowych
- implementacja widzenia komputerowego i rozpoznawania obrazów
- przetwarzanie języka naturalnego
- implementacja modeli dla urządzeń z systemami Android i iOS

Laurence Moroney pracuje w Google. Kieruje zespołem, który zajmuje się rozwiązaniami wykorzystującymi sztuczną inteligencję. Jest też trenerem: szkoli projektantów oprogramowania w zakresie technik budowy systemów uczenia maszynowego. Często udziela się na kanale TensorFlow w YouTube. Jest znanym na całym świecie prelegentem, a także autorem książek beletrystycznych — napisał kilka dobrze przyjętych powieści science fiction.

Helion 

 **helion.pl**

 **HELION SA**
ul. Kościuszki 1c
44-100 Gliwice
tel.: 32 230 98 63
helion@helion.pl

Sprawdź nasze szkolenia!

SZKOLENIA



AKADEMIA IT & BUSINESS

HELIONSZKOLENIA.PL

KOD KORZYŚCI
Sięgnij po więcej! ▶



ISBN 978-83-283-7850-6



9 788328 378506

INFORMATYKA W NAJLEPSZYM WYDANIU

Cena: 79,00 zł