

Spis treści

Przedmowa (11)

Informacje o autorze (13)

Informacje o recenzentach (15)

Wstęp (17)

Rozdział 1. Umożliwianie komputerom uczenia się z danych (25)

- Tworzenie inteligentnych maszyn służących do przekształcania danych w wiedzę (26)
- Trzy różne rodzaje uczenia maszynowego (26)
 - Prognozowanie przyszłości za pomocą uczenia nadzorowanego (27)
 - Rozwiązywanie problemów interaktywnych za pomocą uczenia przez wzmocnianie (29)
 - Odkrywanie ukrytych struktur za pomocą uczenia nienadzorowanego (30)
- Wprowadzenie do podstawowej terminologii i notacji (31)
- Strategia tworzenia systemów uczenia maszynowego (33)
 - Wstępne przetwarzanie - nadawanie danym formy (34)
 - Trenowanie i dobór modelu predykcyjnego (35)
 - Ewaluacja modeli i przewidywanie wystąpienia nieznanych danych (36)
- Wykorzystywanie środowiska Python do uczenia maszynowego (36)
 - Instalacja pakietów w Pythonie (36)
- Podsumowanie (38)

Rozdział 2. Trenowanie algorytmów uczenia maszynowego w celach klasyfikacji (41)

- Sztuczne neurony - rys historyczny początków uczenia maszynowego (42)
- Implementacja algorytmu uczenia perceptronu w Pythonie (47)
 - Trenowanie modelu perceptronu na zestawie danych Iris (50)
- Adaptacyjne neurony liniowe i zbieżność uczenia (54)
 - Minimalizacja funkcji kosztu za pomocą metody gradientu prostego (55)
 - Implementacja adaptacyjnego neuronu liniowego w Pythonie (57)
 - Wielkoskalowe uczenie maszynowe i metoda stochastycznego spadku wzdłuż gradientu (62)
- Podsumowanie (67)

Rozdział 3. Stosowanie klasyfikatorów uczenia maszynowego za pomocą biblioteki scikit-learn (69)

- Wybór algorytmu klasyfikującego (70)
- Pierwsze kroki z biblioteką scikit-learn (70)
 - Uczenie perceptronu za pomocą biblioteki scikit-learn (71)

- Modelowanie prawdopodobieństwa przynależności do klasy za pomocą regresji logistycznej (76)
 - Teoretyczne podłoże regresji logistycznej i prawdopodobieństwa warunkowego (76)
 - Wyznaczanie wag logistycznej funkcji kosztu (79)
 - Uczenie modelu regresji logistycznej za pomocą biblioteki scikit-learn (81)
 - Zapobieganie nadmiernemu dopasowaniu za pomocą regularyzacji (84)
- Wyznaczanie maksymalnego marginesu za pomocą maszyn wektorów nośnych (87)
 - Teoretyczne podłoże maksymalnego marginesu (87)
 - Rozwiązywanie przypadków nieliniowo rozdzielnych za pomocą zmiennych uzupełniających (88)
 - Alternatywne implementacje w interfejsie scikit-learn (90)
- Rozwiązywanie nieliniowych problemów za pomocą jądra SVM (91)
 - Stosowanie sztuczki z funkcją jądra do znajdowania przestrzeni rozdzielających w przestrzeni o większej liczbie wymiarów (93)
- Uczenie drzew decyzyjnych (97)
 - Maksymalizowanie przyrostu informacji - osiągnięcie jak największych korzyści (98)
 - Budowanie drzewa decyzyjnego (101)
 - Łączenie słabych klasyfikatorów w silne klasyfikatory za pomocą modelu losowego lasu (104)
- Algorytm k-najbliższych sąsiadów - model leniwego uczenia (106)
- Podsumowanie (109)

Rozdział 4. Tworzenie dobrych zbiorów uczących - wstępne przetwarzanie danych (111)

- Kwestia brakujących danych (111)
 - Usuwanie próbek lub cech niezawierających wartości (113)
 - Wstawianie brakujących danych (114)
 - Estymatory interfejsu scikit-learn (114)
- Przetwarzanie danych kategoryzujących (116)
 - Mapowanie cech porządkowych (116)
 - Kodowanie etykiet klas (117)
 - Kodowanie "gorącojedynkowe" cech nominalnych (z użyciem wektorów własnych) (118)
- Rozdzielanie zestawu danych na podzbiory uczące i testowe (120)
- Skalowanie cech (121)
- Dobór odpowiednich cech (123)
 - Regularyzacja L1 (124)
 - Algorytmy sekwencyjnego wyboru cech (129)
- Ocenianie istotności cech za pomocą algorytmu losowego lasu (134)
- Podsumowanie (137)

Rozdział 5. Kompresja danych poprzez redukcję wymiarowości (139)

- Nienadzorowana redukcja wymiarowości za pomocą analizy głównych składowych (140)

- Wyjaśniona wariancja całkowita (141)
- Transformacja cech (145)
- Analiza głównych składowych w interfejsie scikit-learn (147)
- Nadzorowana kompresja danych za pomocą liniowej analizy dyskryminacyjnej (150)
 - Obliczanie macierzy rozproszenia (151)
 - Dobór dyskryminant liniowych dla nowej podprzestrzeni cech (154)
 - Rzutowanie próbek na nową przestrzeń cech (156)
 - Implementacja analizy LDA w bibliotece scikit-learn (156)
- Jądrowa analiza głównych składowych jako metoda odwzorowywania nierozdzielnych liniowo klas (158)
 - Funkcje jądra oraz sztuczka z funkcją jądra (160)
 - Implementacja jądrowej analizy głównych składowych w Pythonie (164)
 - Rzutowanie nowych punktów danych (170)
 - Algorytm jądrowej analizy głównych składowych w bibliotece scikit-learn (174)
- Podsumowanie (175)

Rozdział 6. Najlepsze metody oceny modelu i strojenie parametryczne (177)

- Usprawnianie cyklu pracy za pomocą kolejkowania (177)
 - Wczytanie zestawu danych Breast Cancer Wisconsin (178)
 - Łączenie funkcji transformujących i estymatorów w kolejce czynności (179)
- Stosowanie k-krotnego sprawdzianu krzyżowego w ocenie skuteczności modelu (180)
 - Metoda wydzielania (181)
 - K-krotny sprawdzian krzyżowy (182)
- Sprawdzanie algorytmów za pomocą krzywych uczenia i krzywych walidacji (186)
 - Diagnozowanie problemów z obciążeniem i wariancją za pomocą krzywych uczenia (186)
 - Rozwiązywanie problemów nadmiernego i niewystarczającego dopasowania za pomocą krzywych walidacji (189)
- Dostrajanie modeli uczenia maszynowego za pomocą metody przeszukiwania siatki (191)
 - Strojenie hiperparametrów przy użyciu metody przeszukiwania siatki (192)
 - Dobór algorytmu poprzez zagnieżdżony sprawdzian krzyżowy (193)
- Przegląd metryk oceny skuteczności (195)
 - Odczytywanie macierzy pomyłek (195)
 - Optymalizacja precyzji i pełności modelu klasyfikującego (197)
 - Wykres krzywej ROC (198)
 - Metryki zliczające dla klasyfikacji wieloklasowej (201)
- Podsumowanie (202)

Rozdział 7. Łączenie różnych modeli w celu uczenia zespołowego (203)

- Uczenie zespołów (203)

- Implementacja prostego klasyfikatora wykorzystującego głosowanie większościowe (207)
 - Łączenie różnych algorytmów w celu klasyfikacji za pomocą głosowania większościowego (213)
- Ewaluacja i strojenie klasyfikatora zespołowego (216)
- Agregacja - tworzenie zespołu klasyfikatorów za pomocą próbek początkowych (221)
- Usprawnianie słabych klasyfikatorów za pomocą wzmocnienia adaptacyjnego (226)
- Podsumowanie (232)

Rozdział 8. Wykorzystywanie uczenia maszynowego w analizie sentymentów (235)

- Zestaw danych IMDb movie review (235)
- Wprowadzenie do modelu worka słów (237)
 - Przekształcanie słów w wektory cech (238)
 - Ocena istotności wyrazów za pomocą ważenia częstości termów - odwrotnej częstości w tekście (239)
 - Oczyszczanie danych tekstowych (241)
 - Przetwarzanie tekstu na znaczniki (243)
- Uczenie modelu regresji logistycznej w celu klasyfikowania tekstu (245)
- Praca z większą ilością danych - algorytmy sieciowe i uczenie pozardzeniowe (247)
- Podsumowanie (250)

Rozdział 9. Wdrażanie modelu uczenia maszynowego do aplikacji sieciowej (251)

- Serializacja wyuczonych estymatorów biblioteki scikit-learn (252)
- Konfigurowanie bazy danych SQLite (254)
- Tworzenie aplikacji sieciowej za pomocą środowiska Flask (256)
- Nasza pierwsza aplikacja sieciowa (257)
 - Sprawdzanie i wyświetlanie formularza (258)
 - Przekształcanie klasyfikatora recenzji w aplikację sieciową (262)
- Umieszczanie aplikacji sieciowej na publicznym serwerze (269)
 - Aktualizowanie klasyfikatora recenzji filmowych (271)
- Podsumowanie (272)

Rozdział 10. Przewidywanie ciągłych zmiennych docelowych za pomocą analizy regresywnej (275)

- Wprowadzenie do prostego modelu regresji liniowej (276)
- Zestaw danych Housing (277)
 - Wizualizowanie ważnych elementów zestawu danych (278)
- Implementacja modelu regresji liniowej wykorzystującego zwykłą metodę najmniejszych kwadratów (282)
 - Określanie parametrów regresyjnych za pomocą metody gradientu prostego (283)
 - Szacowanie współczynnika modelu regresji za pomocą biblioteki scikit-learn (286)

- Uczenie odpornego modelu regresyjnego za pomocą algorytmu RANSAC (288)
- Ocenianie skuteczności modeli regresji liniowej (291)
- Stosowanie regularyzowanych metod regresji (294)
- Przekształcanie modelu regresji liniowej w krzywą - regresja wielomianowa (295)
 - Modelowanie nieliniowych zależności w zestawie danych Housing (297)
 - Analiza nieliniowych relacji za pomocą algorytmu losowego lasu (300)
- Podsumowanie (305)

Rozdział 11. Praca z nieoznakowanymi danymi - analiza skupień (307)

- Grupowanie obiektów na podstawie podobieństwa przy użyciu algorytmu centroidów (308)
 - Algorytm k-means++ (311)
 - Klasteryzacja twarda i miękka (312)
 - Stosowanie metody łokcia do wyszukiwania optymalnej liczby skupień (315)
 - Ujęcie ilościowe jakości klasteryzacji za pomocą wykresu profilu (316)
- Organizowanie skupień do postaci drzewa klastrow (320)
 - Przeprowadzanie hierarchicznej analizy skupień na macierzy odległości (323)
 - Dołączanie dendrogramów do mapy cieplnej (326)
 - Aglomeracyjna analiza skupień w bibliotece scikit-learn (328)
- Wyznaczanie rejonów o dużej gęstości za pomocą algorytmu DBSCAN (328)
- Podsumowanie (333)

Rozdział 12. Trenowanie sztucznych sieci neuronowych w rozpoznawaniu obrazu (335)

- Modelowanie złożonych funkcji przy użyciu sztucznych sieci neuronowych (336)
 - Jednowarstwowa sieć neuronowa - powtórzenie (337)
 - Wstęp do wielowarstwowej architektury sieci neuronowych (338)
 - Aktywacja sieci neuronowej za pomocą propagacji w przód (340)
- Klasyfikowanie pisma odręcznego (343)
 - Zestaw danych MNIST (344)
 - Implementacja wielowarstwowego perceptronu (348)
- Trenowanie sztucznej sieci neuronowej (356)
 - Obliczanie logistycznej funkcji kosztu (356)
 - Uczenie sieci neuronowych za pomocą algorytmu wstecznej propagacji (359)
- Ujęcie intuicyjne algorytmu wstecznej propagacji (361)
- Usuwanie błędów w sieciach neuronowych za pomocą sprawdzania gradientów (363)
- Zbieżność w sieciach neuronowych (368)
- Inne architektury sieci neuronowych (370)
 - Splotowe sieci neuronowe (370)
 - Rekurencyjne sieci neuronowe (371)

- Jeszcze słowo o implementacji sieci neuronowej (373)
- Podsumowanie (373)

Rozdział 13. Równoległe przetwarzanie sieci neuronowych za pomocą biblioteki Theano (375)

- Tworzenie, kompilowanie i uruchamianie wyrażeń w interfejsie Theano (376)
 - Czym jest Theano? (377)
 - Pierwsze kroki z Theano (378)
 - Konfigurowanie środowiska Theano (379)
 - Praca ze strukturami tablicowymi (381)
 - Przejdźmy do konkretów - implementacja regresji liniowej w Theano (384)
- Dobór funkcji aktywacji dla jednokierunkowych sieci neuronowych (387)
 - Funkcja logistyczna - powtórzenie (388)
 - Szacowanie prawdopodobieństw w klasyfikacji wieloklasowej za pomocą znormalizowanej funkcji wykładniczej (390)
 - Rozszerzanie zakresu wartości wyjściowych za pomocą funkcji tangensa hiperbolicznego (391)
- Skuteczne uczenie sieci neuronowych za pomocą biblioteki Keras (393)
- Podsumowanie (398)

Skorowidz (401)