


Wykorzystaj dane z sieci do własnych potrzeb!

Nowe usługi 2.0

Przewodnik po analizie zbiorów danych



O'REILLY®

Toby Segaran

Tytuł oryginału: Programming Collective Intelligence: Building Smart Web 2.0 Applications

Tłumaczenie: Piotr Pilch

ISBN: 978-83-246-9298-9

© 2014 Helion S.A.

Authorized Polish translation of the English edition Programming Collective Intelligence
ISBN 9780596529321 © 2007 Toby Segaran.

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.

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

Wydawnictwo HELION
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)

Pliki z przykładami omawianymi w książce można znaleźć pod adresem:
<ftp://ftp.helion.pl/przyklady/noweus.zip>

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

Printed in Poland.

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

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

Spis treści

Słowo wstępne	11
Przedmowa	13
1. Inteligencja zbiorowa — wprowadzenie	21
Czym jest inteligencja zbiorowa?	22
Czym jest uczenie maszynowe?	23
Ograniczenia uczenia maszynowego	24
Rzeczywiste przykłady	24
Inne zastosowania algorytmów uczących	25
2. Tworzenie rekomendacji	27
Filtrowanie grupowe	27
Gromadzenie preferencji	28
Znajdowanie podobnych użytkowników	29
Rekomendowanie pozycji	34
Dopasowywanie produktów	36
Tworzenie systemu rekomendowania odnośników del.icio.us	38
Filtrowanie oparte na pozycjach	42
Zastosowanie zbioru danych MovieLens	45
Filtrowanie oparte na użytkownikach czy pozycjach?	46
Ćwiczenia	47
3. Wykrywanie grup	49
Porównanie uczenia nadzorowanego z nienadzorowanym	49
Wektory wyrazów	50
Grupowanie hierarchiczne	53
Rysowanie dendrogramu	57
Grupowanie kolumn	59
Grupowanie k-średnich	61

Klastry preferencji	64
Wyświetlanie danych w dwóch wymiarach	68
Inne rzeczy, które mogą być grupowane	71
Ćwiczenia	72
4. Wyszukiwanie i klasyfikowanie	73
Co znajduje się w wyszukiwarce?	73
Prosty przeszukiwacz	75
Budowanie indeksu	77
Odpytywanie	81
Klasyfikacja oparta na treści	83
Użycie odnośników zewnętrznych	87
Uczenie na podstawie kliknięć	91
Ćwiczenia	101
5. Optymalizacja	103
Podróż grupy osób	104
Reprezentowanie rozwiązań	105
Funkcja kosztu	106
Wyszukiwanie losowe	108
Metoda największego wzrostu	109
Symulowane wyżarzanie	111
Algorytmy genetyczne	113
Wyszukiwania rzeczywistych lotów	117
Optymalizowanie pod kątem preferencji	122
Wizualizacja sieci	125
Inne możliwości	130
Ćwiczenia	130
6. Filtrowanie dokumentów	133
Filtrowanie spamu	133
Dokumenty i wyrazy	134
Trenowanie klasyfikatora	135
Obliczanie prawdopodobieństw	137
Naiwny klasyfikator	139
Metoda Fishera	142
Utrwalanie klasyfikatorów po przeprowadzonym treningu	146
Filtrowanie kanałów informacyjnych blogów	148
Poprawianie wykrywania właściwości	150
Użycie interfejsu Akismet	152
Alternatywne metody	153
Ćwiczenia	154

7. Modelowanie przy użyciu drzew decyzyjnych	157
Przewidywanie rejestracji	157
Wprowadzenie do drzew decyzyjnych	159
Uczenie drzewa	160
Wybór najlepszego podziału	162
Budowanie drzewa rekurencyjnego	164
Wyświetlanie drzewa	166
Klasyfikowanie nowych obserwacji	168
Przycinanie drzewa	169
Radzenie sobie z brakującymi danymi	171
Radzenie sobie z wynikami liczbowymi	172
Modelowanie cen domów	173
Modelowanie „atrakcyjności”	176
Kiedy stosować drzewa decyzyjne?	178
Ćwiczenia	179
8. Budowanie modelu cen	181
Budowanie przykładowego zbioru danych	181
Metoda k-najbliższych sąsiadów	183
Sąsiednie elementy z określoną wagą	186
Walidacja krzyżowa	189
Zmienne heterogeniczne	191
Optymalizowanie skali	194
Rozkłady niejednolite	196
Użycie rzeczywistych danych — interfejs API serwisu eBay	200
Kiedy używać metody k-najbliższych sąsiadów?	207
Ćwiczenia	207
9. Zaawansowane klasyfikowanie: metody jądrowe i maszyny wektorów nośnych	209
Zbiór danych swatki	209
Trudności związane z danymi	211
Podstawowa klasyfikacja liniowa	213
Właściwości skategoryzowane	217
Skalowanie danych	218
Metody jądrowe	220
Maszyny wektorów nośnych	223
Zastosowanie biblioteki LIBSVM	225
Dopasowywanie w serwisie Facebook	227
Ćwiczenia	232

10. Znajdowanie niezależnych właściwości	233
Zbiór artykułów	234
Wcześniejsze rozwiązania	237
Nieujemna faktoryzacja macierzy	240
Wyświetlanie wyników	246
Użycie danych rynku giełdowego	249
Ćwiczenia	254
11. Inteligencja rozwojowa	255
Czym jest programowanie genetyczne?	255
Programy w postaci drzew	258
Tworzenie populacji początkowej	261
Testowanie rozwiązania	263
Krzyżowanie	267
Budowanie środowiska	269
Prosta gra	272
Dalsze możliwości	276
Ćwiczenia	278
12. Algorytmy — podsumowanie	281
Klasyfikator bayesowski	281
Klasyfikator drzew decyzyjnych	285
Sieci neuronowe	288
Maszyny wektorów nośnych	292
Metoda k-najbliższych sąsiadów	296
Grupowanie	299
Skalowanie wielowymiarowe	303
Nieujemna faktoryzacja macierzy	305
Optymalizacja	307
A Zewnętrzne biblioteki	311
Universal Feed Parser	311
Python Imaging Library	311
Beautiful Soup	312
pysqlite	313
NumPy	314
matplotlib	315
pydelicious	316

B	Formuły matematyczne	317
	Odległość euklidesowa	317
	Współczynnik korelacji Pearsona	317
	Średnia ważona	318
	Współczynnik Tanimoto	319
	Prawdopodobieństwo warunkowe	319
	Niejednorodność Giniego	320
	Entropia	321
	Wariancja	321
	Funkcja Gaussa	322
	Iloczyny skalarne	322
	Skorowidz	324

Inteligencja zbiorowa — wprowadzenie

Netflix to internetowa wypożyczalnia płyt DVD, która umożliwia wybór filmów z wysyłką do domu. Firma podaje rekomendacje na podstawie filmów, które zostały wcześniej wypożyczone przez klientów. Pod koniec 2006 r. firma Netflix poinformowała o nagrodzie w wysokości 1 mln dolarów dla pierwszej osoby, która poprawi dokładność systemu rekomendacji wypożyczalni o 10%. Ponadto każdego roku firma będzie wręczać dodatkowo 50 tys. dolarów aktualnemu liderowi do czasu trwania konkursu. W konkursie wzięły udział tysiące zespołów z całego świata. W kwietniu 2007 r. najlepszemu zespołowi udało się uzyskać poprawę rekomendacji o 7%. Korzystając z danych dotyczących filmów, które spodobały się poszczególnym klientom, firma Netflix ma możliwość rekomendowania filmów innym klientom. Ci klienci mogli nawet nigdy o nich nie słyszeć. Po ich obejrzeniu mogą oni zdecydować się na kolejne filmy. Każdy sposób ulepszenia swojego systemu rekomendacji wart jest dla firmy Netflix mnóstwo pieniędzy.

Wyszukiwarka internetowa firmy Google zaczęła działać w 1998 r. W tamtym czasie istniało już kilka dużych wyszukiwarek. Wiele osób przyjęło, że nowy gracz nie będzie w stanie konkurować z gigantami branżowymi. Jednakże założyciele firmy Google zastosowali zupełnie nową metodę tworzenia rankingów wyników wyszukiwania, korzystając z odnośników na milionach stron internetowych podczas określania, które strony są najbardziej odpowiednie. Wyniki wyszukiwania wyszukiwarki Google okazały się znacznie lepsze od oferowanych przez innych graczy, którzy w 2004 r. obsługiwali 85% wyszukiwań w Internecie. Założyciele firmy Google zaliczają się obecnie do najbogatszych ludzi świata.

Co te dwie firmy mają ze sobą wspólnego? Obie doszły do nowych wniosków i stworzyły nowe możliwości biznesowe, korzystając z zaawansowanych algorytmów w celu połączenia danych zebranych od wielu różnych osób. Możliwość gromadzenia informacji i moc obliczeniowa pozwalająca na ich interpretowanie stworzyły ogromne możliwości współpracy oraz lepszego zrozumienia użytkowników i klientów. Tego rodzaju działania mają miejsce w różnych przypadkach. Serwisom randkowym zależy na szybszym znalezieniu najlepiej dopasowanych kandydatów. Pojawiają się firmy przewidujące zmiany cen biletów lotniczych. Niemal każdemu zależy na lepszym zrozumieniu swoich klientów, aby przygotować reklamy trafiające do właściwszych osób.

To tylko kilka przykładów ekscytującej dziedziny inteligencji zbiorowej. Rozpowszechnianie się nowych usług powoduje, że każdego dnia pojawiają się nowe możliwości. Wierzę, że opanowanie uczenia maszynowego i metod statystycznych stanie się jeszcze ważniejsze w przeróżnych dziedzinach, szczególnie w przypadku interpretowania i organizowania ogromnej ilości informacji tworzonych przez ludzi na całym świecie.

Czym jest inteligencja zbiorowa?

Pojęcie *inteligencji zbiorowej* jest używane od dziesięcioleci. Jego znaczenie i popularność zaczęły się zwiększać wraz z pojawieniem się nowych technologii komunikacji. Choć nazwa terminu może przywołać na myśl pojęcia związane ze świadomością zbiorową lub zjawiskiem nadprzyrodzonym, to używając go, specjaliści od technologii mają zwykle na myśli łączenie zachowań, preferencji lub pomysłów grupy osób w celu uzyskania nowatorskich spostrzeżeń.

Oczywiście inteligencja zbiorowa była możliwa przed pojawieniem się Internetu. Nie jest wymagana sieć WWW, aby zgromadzić dane od różnych grup ludzi, połączyć je i poddać analizie. Jedną z najbardziej podstawowych form inteligencji zbiorowej jest ankieta lub spis ludności. Zbieranie odpowiedzi od dużej grupy ludzi umożliwia uzyskanie wniosków statystycznych dotyczących grupy, których nie określiliby w pojedynkę żaden jej członek. Tworzenie nowych wniosków przy udziale niezależnych uczestników w rzeczywistości jest tym, do czego służy inteligencja zbiorowa.

Jej dobrze znanym przykładem są rynki finansowe, w przypadku których cena nie jest ustalana przez jedną osobę ani nie jest wynikiem skoordynowanego działania, lecz stanowi efekt operacji handlowych wielu niezależnych od siebie osób, które działają zgodnie z tym, co w ich przekonaniu służy ich najlepszemu interesowi. Choć z początku może się to wydawać sprzeczne z intuicją, *rynki kontraktów terminowych*, gdzie wielu uczestników handluje kontraktami, próbując określić ich przyszłe ceny, są uważane za lepsze w przewidywaniu cen niż eksperci, którzy niezależnie przygotowują prognozy. Wynika to stąd, że w przypadku tworzenia przewidywań takie rynki łączą w sobie wiedzę, doświadczenie i spostrzeżenia tysięcy osób, a nie analizują jedynie punkt widzenia jednej osoby.

Chociaż metody inteligencji zbiorowej istniały przed powstaniem Internetu, możliwość gromadzenia informacji od tysięcy, a nawet milionów osób w sieci internetowej stworzyła wiele nowych opcji analizy. Ludzie używają Internetu do robienia zakupów, prowadzenia badań, szukania rozrywki i budowania własnych witryn internetowych. Wszystkie te działania mogą być monitorowane i wykorzystywane do uzyskiwania informacji bez żadnej konieczności wpływania na intencje użytkownika przez zadawanie mu pytań. Istnieje ogromna liczba możliwych metod przetwarzania i interpretowania tych informacji. Oto dwa kluczowe przykłady prezentujące przeciwstawne metody.

- *Wikipedia* to internetowa encyklopedia stworzona w całości w wyniku współpracy użytkowników. Dowolna strona może zostać utworzona lub zmodyfikowana przez każdego. Niewielka liczba administratorów monitoruje powtarzające się nadużycia. Serwis Wikipedia ma więcej wpisów niż jakakolwiek inna encyklopedia. Pomimo manipulacji dokonywanych przez użytkowników o złych intencjach, generalnie może być uważana za dokładną w przypadku większości zagadnień. Jest to przykład inteligencji zbiorowej, ponieważ każdy artykuł jest utrzymywany przez dużą grupę osób. Efektem jest encyklopedia znacznie większa od jakiegokolwiek, która mogłaby zostać stworzona przez dowolną pojedynczą, skoordynowaną grupę. Oprogramowanie encyklopedii Wikipedia nie realizuje żadnych wyszukanych operacji w odniesieniu do uczestniczących użytkowników. Po prostu śledzi zmiany i wyświetla najnowszą wersję.
- Wspomniana wcześniej wyszukiwarka *Google* to najpopularniejsza na świecie wyszukiwarka internetowa. Jako pierwsza zaczęła oceniać strony internetowe na podstawie liczby innych stron, które się do nich odwołują. W przypadku tej metody oceniania uzyskiwane

są informacje o tym, co tysiące osób stwierdziły na temat konkretnej strony internetowej. Informacje te służą do tworzenia rankingu wyników wyszukiwania. Jest to rzykiad inteligencji zbiorowej bardzo odmienny od Wikipedii. Serwis Wikipedia wprost zaprasza swoich użytkowników do uczestnictwa, natomiast wyszukiwarka Google wydobywa ważne informacje o tym, jakie działania twórcy treści sieciowych podejmują w obrębie własnych witryn, a następnie wykorzystuje je do generowania wyników dla swoich użytkowników.

Choć Wikipedia stanowi znakomity zasób i wyjątkowy przykład inteligencji zbiorowej, swoje istnienie zawdzięcza bardziej bazie użytkowników dodających informacje niż sprytnym algorytmom zawartym w oprogramowaniu. W książce skoncentrowano się na drugim końcu tego spektrum, czyli na omówieniu algorytmów takich jak PageRank wyszukiwarki Google, który pobiera dane użytkownika i przeprowadza obliczenia w celu utworzenia nowych informacji mogących wpłynąć na poprawę komfortu obsługi użytkownika. Część danych jest gromadzona jawnie, być może przez prośbę o ocenę różnych rzeczy skierowaną do internautów, a część jest zbierana mimochodem przez obserwację tego, co jest przez nich kupowane. W obu przypadkach istotne jest nie samo zbieranie i wyświetlanie informacji, lecz przetwarzanie ich w inteligentny sposób i generowanie nowych wiadomości.

W książce zostaną zaprezentowane metody gromadzenia danych za pośrednictwem otwartych interfejsów API. Przedstawione będą różne algorytmy uczenia maszynowego oraz metody statystyczne. Taka kombinacja umożliwi przygotowanie metod inteligencji zbiorowej dla danych uzyskanych we własnych aplikacjach, a także gromadzenie danych z innych miejsc i eksperymentowanie z ich wykorzystaniem.

Czym jest uczenie maszynowe?

Uczenie maszynowe to dziedzina podlegająca sztucznej inteligencji związanej z algorytmami, które umożliwiają *uczenie* komputerów. W większości przypadków oznacza to, że algorytm otrzymuje zbiór danych i określa wnioski dotyczące ich właściwości. Informacje te umożliwiają tworzenie przewidywań odnośnie do innych danych, które mogą pojawić się w przyszłości. Jest to możliwe, ponieważ niemal wszystkie nielosowe dane zawierają wzorce, które pozwalają maszynie dokonywać uogólnień. W tym celu trenowany jest *model* przy użyciu tego, co maszyna uzna za najważniejsze aspekty danych.

Aby zrozumieć, jak powstają modele, rozważmy prosty przykład ze skomplikowanej dziedziny, jaką jest filtrowanie poczty elektronicznej. Załóżmy, że otrzymywana jest spora ilość spamu, który zawiera słowa „apteka internetowa”. Człowiek ma odpowiednie możliwości rozpoznawania wzorców, dlatego potrafi szybko stwierdzić, że każda wiadomość zawierająca te dwa słowa to spam, który powinien trafić bezpośrednio do kosza. Jest to uogólnienie. W rzeczywistości został utworzony myślowy model tego, czym jest spam. Po zgłoszeniu kilku takich wiadomości jako spamu algorytm uczenia maszynowego zaprojektowany do filtrowania spamu powinien być w stanie dokonać takiego samego uogólnienia.

Istnieje wiele różnych algorytmów uczenia maszynowego, cechujących się różną siłą działania i dopasowanych do różnego typu problemów. Niektóre z nich, takie jak drzewa decyzyjne, są transparentne. Oznacza to, że obserwator może w pełni pojąć proces rozumowania realizowany przez maszynę. Inne algorytmy, takie jak sieci neuronowe, to „czarna skrzynka”. Oznacza to, że generują one odpowiedź, często jednak bardzo trudne jest odtworzenie związanego z tym rozumowania.

Wiele algorytmów uczenia maszynowego intensywnie korzysta z matematyki i statystyki. Zgodnie z definicją, którą wcześniej podałem, można nawet stwierdzić, że prosta analiza korelacji i regresja to podstawowe formy uczenia maszynowego. W książce nie założono, że czytelnik ma wiedzę z dziedziny statystyki, dlatego podjąłem się próby objaśnienia zastosowanej statystyki w jak najprostszy sposób.

Ograniczenia uczenia maszynowego

Uczenie maszynowe nie jest pozbawione wad. Algorytmy mają różne możliwości uogólniania dużych zbiorów wzorców. Wzorec, który nie przypomina żadnego wcześniej napotkanego przez algorytm, z dużym prawdopodobieństwem zostanie niewłaściwie zinterpretowany. Ludzie mogą wykorzystywać rozległe doświadczenie i wiedzę o charakterze kulturowym, a także mają niezwykłą zdolność rozpoznawania podobnych sytuacji podczas podejmowania decyzji dotyczących nowych wiadomości. Z kolei metody uczenia maszynowego mogą jedynie uogólniać na podstawie już napotkanych danych, i to w bardzo ograniczony sposób.

Metoda filtrowania spamu, która zostanie przedstawiona w książce, opiera się na występowaniu słów lub fraz bez względu na ich znaczenie lub na strukturę zdań. Choć teoretycznie możliwe jest zbudowanie algorytmu, który uwzględniałby gramatykę, w praktyce dzieje się to rzadko z powodu wymaganych nakładów nieproporcjonalnie dużych w stosunku do uzyskiwanego ulepszenia algorytmu. Zrozumienie znaczenia słów lub ich powiązania z życiem danej osoby wymagałoby znacznie większej ilości informacji niż ta, do której mogą uzyskać dostęp filtry spamu w swojej obecnej postaci.

Poza tym, choć wszystkie metody uczenia maszynowego różnią się pod tym względem, są podatne na możliwość przesadnego uogólniania. Jak z większością rzeczy w życiu, duże uogólnienia oparte na kilku przykładach rzadko są w pełni dokładne. Z pewnością możliwe jest otrzymanie od znajomego ważnej wiadomości e-mail, która zawiera słowa „apteka internetowa”. W tym przypadku poinstruowano by algorytm, że wiadomość nie jest spamem. W rezultacie algorytm mógłby wywnioskować, że komunikaty od tego konkretnego znajomego są możliwe do zaakceptowania. Natura wielu algorytmów uczenia maszynowego jest taka, że mogą one kontynuować proces uczenia wraz z pojawianiem się nowych informacji.

Rzeczywiste przykłady

W Internecie istnieje wiele witryn, które obecnie gromadzą dane od wielu różnych osób, a ponadto stosują uczenie maszynowe i metody statystyczne w celu skorzystania z nich. Wyszukiwarka Google to prawdopodobnie największe rozwiązanie (nie tylko używa łączy internetowych do tworzenia rankingu stron, ale nieustannie zbiera informacje dotyczące momentu kliknięcia reklam przez różnych użytkowników), które umożliwia firmie Google bardziej skuteczne kierowanie reklam. W rozdziale 4. zostaną omówione wyszukiwarki internetowe i algorytm Page-Rank, który stanowi istotną część systemu rankingowego wyszukiwarki Google.

Inne przykłady obejmują witryny internetowe z systemami rekomendacji. Witryny takich firm, jak Amazon i Netflix, używają informacji o rzeczach kupionych lub wypożyczonych przez ludzi do określania, jacy internauci lub jakie produkty są do siebie podobne, a następnie tworzenia rekomendacji na podstawie historii zakupów. Inne witryny, takie jak Pandora i Last.fm, stosują oceny użytkowników dotyczące różnych zespołów i piosenek, aby tworzyć tematyczne

stacje radiowe z muzyką, która w opinii ich właścicieli powinna być interesująca. W rozdziale 2. omówiono metody budowania systemów rekomendacji.

Rynki prognostyczne to także forma inteligencji zbiorowej. Jednym z najbardziej znanych jest serwis Hollywood Stock Exchange (<http://hsx.com/>), w którym użytkownicy handlują akcjami związanymi z filmami i gwiazdami filmowymi. Możliwe jest kupno lub sprzedaż akcji po aktualnej cenie, jeśli wiadomo, że jej ostateczna cena będzie jedną milionową rzeczywistej kwoty w momencie premiery filmu. Ze względu na to, że cena jest zależna od handlujących akcjami, jej wysokość nie jest ustalana przez żadną konkretną osobę, lecz jako wynik działania grupy. Aktualna cena może być przewidywaniem całej grupy dotyczącym wyniku finansowego filmu po premierze. Przewidywania określone przez serwis Hollywood Stock Exchange są często lepsze od opracowywanych przez poszczególnych ekspertów.

Niektóre serwisy randkowe, takie jak eHarmony, używają informacji zebranych od uczestników do określenia, kto byłby odpowiednim kandydatem. Choć takie firmy utrzymują zwykle stosowane metody dopasowywania osób w tajemnicy, całkiem prawdopodobne jest, że dowolna skuteczna metoda będzie uwzględniać ciągle ponawianie oceny na podstawie tego, czy wybrani kandydaci faktycznie zostali do siebie pomyślnie dopasowani.

Inne zastosowania algorytmów uczących

Metody opisane w książce nie są nowe. Choć przykłady skupiają się na problemach z inteligencją zbiorową w przypadku zastosowań internetowych, znajomość algorytmów uczenia maszynowego może okazać się pomocna dla twórców oprogramowania w wielu innych dziedzinach. Algorytmy te są szczególnie przydatne w obszarach, w których wykorzystuje się duże zbiory danych przeszukiwane pod kątem interesujących wzorców. Oto przykłady.

Biotechnologia

Postępy w technologii sekwencjonowania i badania przesiewowego spowodowały utworzenie ogromnych zbiorów różnych rodzajów danych, takich jak sekwencje kodu DNA, struktury białek, przesiewy związków chemicznych i ekspresja RNA. Techniki uczenia maszynowego są intensywnie wykorzystywane w przypadku wszystkich tego rodzaju danych. Ma to na celu znalezienie wzorców, które zwiększają stopień zrozumienia procesów biologicznych.

Wykrywanie oszustw finansowych

Firmy obsługujące karty kredytowe nieustannie poszukują nowych sposobów wykrywania nielegalnych transakcji. W związku z tym zastosowały one takie techniki, jak sieci neuronowe i logika indukcyjna, aby weryfikować transakcje i wychwytywać przypadki niewłaściwego użycia.

System wizyjny

Interpretowanie obrazów z kamery wideo do celów wojskowych lub obserwacyjnych to aktywny obszar badań. Wiele technik uczenia maszynowego używanych jest w celu podejmowania próby automatycznego wykrywania intruzów, identyfikowania pojazdów lub rozpoznawania twarzy. Szczególnie interesujące jest zastosowanie technik nienadzorowanych, takich jak *niezależna analiza komponentów*, która umożliwia znajdowanie interesujących właściwości w dużych zbiorach danych.

Marketing produktów

Przez bardzo długi czas zrozumienie demografii i trendów było bardziej formą sztuki niż nauką. Zwiększona w ostatnim czasie możliwość gromadzenia danych od konsumentów zapewniła opcje wykorzystania technik uczenia maszynowego, takich jak grupowanie, aby lepiej zrozumieć naturalne podziały istniejące na rynkach i przygotować precyzyjniejsze przewidywania dotyczące przyszłych trendów.

Optymalizacja łańcucha dostaw

Duże organizacje mogą zaoszczędzić miliony dolarów dzięki efektywnemu funkcjonowaniu ich łańcuchów dostaw i dokładnemu przewidywaniu zapotrzebowania na produkty w różnych obszarach. Liczba możliwych metod tworzenia łańcucha dostaw jest ogromna, tak samo jak liczba czynników, które potencjalnie mogą mieć wpływ na popyt. Optymalizacja i techniki uczenia są często używane do analizowania związanych z tym zbiorów danych.

Analiza rynków giełdowych

Od czasu powstania rynku giełdowego ludzie podejmowali próby wykorzystania matematyki do zarobienia większej ilości pieniędzy. Wraz z coraz większym stopniem zaawansowania uczestników rynku akcji stało się konieczne analizowanie większych zbiorów danych i używanie zaawansowanych technik do wykrywania wzorców.

Bezpieczeństwo narodowe

Ogromna ilość informacji jest gromadzona przez agencje rządowe całego świata. Analiza tych danych wymaga od komputerów wykrywania wzorców i wiązania ich z potencjalnymi zagrożeniami.

To zaledwie kilka przykładów intensywnego wykorzystywania uczenia maszynowego. Z powodu tego, że tendencją jest generowanie większej ilości informacji, prawdopodobnie w większej liczbie dziedzin konieczne będzie wykorzystanie uczenia maszynowego i metod statystycznych, gdy ilość informacji przekroczy ludzkie możliwości zarządzania nimi przy użyciu starych sposobów.

Biorąc pod uwagę, jak dużo nowych informacji udostępnianych jest każdego dnia, oczywiście pojawia się znacznie więcej możliwości. Po poznaniu kilku algorytmów uczenia maszynowego zaczną być zauważalne przeróżne miejsca, w których mogą one zostać wykorzystane.

A

Akismet, 16, 152
aktualizowanie multiplikatywne, 244
algorytm, 23, 281
 backpropagation,
 Patrz: algorytm wstecznej propagacji błędów
CART, *Patrz:* CART
filtrowania grupowego,
 Patrz: filtrowanie grupowe
genetyczny, 113, 116, 256, 308
kNN, *Patrz:* kNN
NMF, *Patrz:* macierz
 faktoryzacja nieujemna
PageRank, *Patrz:* PageRank
sprzężenia wyprzedzającego, 96
syntetyzujący inteligencję zbiorową, 16
transparentny, 23
uczenia maszynowego,
 Patrz: uczenie maszynowe wstecznej propagacji błędów, 93, 97
wybór, 209, 255
wyodrębniania właściwości,
 Patrz: dane właściwość wyodrębnianie
wyróżniania rdzeni wyrazów, 79
wyszukiwania pełnotekstowego, 73
zmieniający wagi połączeń między węzłami,
 Patrz: algorytm wstecznej propagacji błędów
Amazon, 24, 27
analiza
 komponentów niezależna, 25
 korelacji, 24
 rynków giełdowych, 26

API, 16, 23, 39, 173, 176, 201, 227
Application Programming Interface,
 Patrz: API

B

backpropagation, *Patrz:* algorytm wstecznej propagacji błędów
Bayesa twierdzenie,
 Patrz: twierdzenie Bayesa
baza danych
 indeksu pełnotekstowego, 77
 klient-serwer, 74
 pysqlite, *Patrz:* pysqlite
 SQLite, 74, 77, 147
Beautiful Soup, 64, 75, 312
biblioteka
 Beautiful Soup, *Patrz:* Beautiful Soup
 języka Python, 16
LIBSVM, *Patrz:* LIBSVM
matplotlib, 198
NumPy, *Patrz:* NumPy
PIL, 57, 128, 311
pydelicious, 316
urllib2, 75
biologia obliczeniowa, 49
bliskość, 54
blog, 49, 50, 52
 filtrowanie, 148

C

CART, 160
cena, 181, 205, 206, 207
 licytacji, 181
centroid, 62
Classification and Regression Trees, *Patrz:* CART

D

dane, *Patrz też:* baza danych, zbiór brakujące, 171
demograficzne, 49
gromadzenie, 23
grupowanie, 49, 50, 54
liczbowe, 217
macierz, *Patrz:* macierz artykułów
nieliniowość, 211
przekształcenie w liczby, 217
skalowanie, 193, 194, 218, 297
 optymalizacja, 194
transformacja do nowej przestrzeni, 221, 293
właściwości wyodrębnianie, 233, 235
 wzajemna zależność zmiennych, 211
delicio.us, 16, 38, 39, 316
demografia, 26
dendrogram, 57, 60
Document Object Model,
 Patrz: DOM
dokument
 gromadzenie, 73
 klasyfikacja, 133
 tabela, 73, 78
 XML, 51
DOM, 118
domena rozwiązania, 308
drzewo, 258
 decyzyjne, 23, 49, 157, 159, 168, 169, 172, 178, 181, 212, 285, 287
 brakujące dane, 171
 nadmiernie dopasowane, 169, 170
 przycinanie, 169, 170
 rekurencyjne, 164

uczenie, 160, 285
wady, 287
wyświetlanie, 166, 167
zalety, 287
głębokość, 263
rekurencyjne, 258
reprezentacja, 259
składni, 258
węzeł, 259
przechowywania, 277
wyświetlanie, 261

E

eBay, 16, 200, 202
Quick Start Guide, 201
eHarmony, 25
elitaryzm, 113
e-mail
dystrybucja masowa, 158
identyfikowanie, 133
entropia, 163, 164, 170, 321
przyrost informacji, 164

F

Facebook, 227
klucz programisty, 227
sesja, 228
znajomy, 229, 230
faktoryzacja macierzy,
Patrz: macierz faktoryzacja
filtrowanie
bayesowskie, 50, 139, 140, 141,
154, 157, 158, 181, 238, 281,
283
wady, 284
zalety, 284
grupowe, 28, 42, 46, 47
poczty elektronicznej, 23
spam, Patrz: spam
filtrowanie
Fishera metoda, Patrz: metoda
Fishera
funkcja
bazowa radialna, 221, 222
entropii, Patrz: entropia
Gaussa, 188, 322
kosztu, 106, 124, 130, 244, 307,
308
niejednorodności Giniego,
Patrz: niejednorodność
Giniego
odejmowania, 187
odwrotna, 186

określania wag, 100
pow, 30
przydatności, 256
sigmoidalna, 96
tangensa hiperbolicznego, 95
ważona kNN, 189, 322

G

Gaussa funkcja, Patrz: funkcja
Gaussa
generacja, 113, 256, 308
początkowa, 261
Goldberg David, 28
Google, 21, 22, 24, 88
granica decyzyjna, 212
gromadzenie dokumentów, 73
GroupLens, 45
grupowanie, 233, 238
danych, Patrz: dane
grupowanie
hierarchiczne, 53, 55, 57, 61,
299, 300, 302
kolumn, 59
k-średnich, 62, 299, 301
wierszy, 59

H

hill climbing, Patrz: metoda
największego wzrostu
hiperpłaszczyzna z
maksymalnym marginesem, 223
hodowanie, Patrz: krzyżowanie
Holland John, 116
Hollywood Stock Exchange, 25
Hot or Not, 16, 176
HTML, 79

I

iloczyn skalarny, 215, 216, 221,
222, 293, 322
implementacja referencyjna, 14
indeks pełnotekstowy, 77, 79, 80
inteligencja
rozwojowa, 255
sztuczna, 23
w grze, 272
zbiorowa, 22, 25, 249, 255
interfejs
Akismet, Patrz: Akismet
API, Patrz: API

J

Jaccarda współczynnik,
Patrz: współczynnik Jaccarda
język
Lisp, 258
Python, Patrz: Python
XML, Patrz: XML

K

kanal informacyjny
Atom, 51, 234
RSS, 51, 234
filtrowanie, 148
Kayak, 16, 117, 119
k-centroid, 62
klaster, 55, 57
błąd całkowity, 58
środek, 62
wysokość, 58
klasyfikacja
odnośników zewnętrznych,
82, 87, 88, 91
oparta na treści, 82, 83
klasyfikator, 135, 146, 153, 209, 238
bayesowski, 140, 154, 157, 181,
238, 281, 283
naiwny, 139, 142, 143, 146
uczenie, 282
wady, 284
zalety, 284
drzew decyzyjnych,
Patrz: drzewo decyzyjne
Fishera, Patrz: metoda Fishera
liniowy, 213, 214, 216, 220, 293
oparty
na regułach, 133, 134, 141
na właściwości, 134, 141, 145
k-Nearest Neighbors, Patrz: kNN
kNN, 183, 185, 196, 207, 296, 298
wady, 299
wagi, 186, 189, 196, 298
zalety, 299
kodu wcięcie, 15
korelacja Pearsona, 29, 31, 32, 33,
35, 54, 66, 317
krzywa
dzwonowa, 188, 322
normalna, Patrz: krzywa
dzwonowa
krzyżowanie, 256, 258, 267, 308
k-średnia, 62, 183

L

Last.fm, 24
LIBSVM, 225, 226, 295
linia
 najlepszego dopasowania, 32
 podziału, 212, 216, 219, 221,
 223, 224, 292
lista, 15
logika indukcyjna, 25

M

macierz, 240
 aktualizacji, 244
 artykułów, 241, 244
 wyświetlanie, 247
 danych, *Patrz:* macierz
 artykułów
 faktoryzacja nieujemna, 50,
 240, 241, 242, 243, 249, 251,
 305, 306
 mnożenie, 240, 243, 305
 obserwacji, 251
 transpozycja, 241, 243
 wag, 241, 242, 243, 305
 właściwości, 241, 243, 305
 wyświetlanie, 246, 252
maksimum lokalne, 271
mapa samoorganizująca się, 50
maszyna wektorów nośnych, 50,
 181, 209, 223, 224, 225, 226, 231, 292
 wady, 295
 zalety, 295
matplotlib, 315
metoda
 Fishera, 142, 145
 k-najbliższych sąsiadów,
 Patrz: kNN
 modyfikowania rozwiązań, 113
 największego wzrostu, 109
 oparta na wektorach
 i iloczynach skalarnych, 214
metryka częstości wyrazów, 84, 85,
 86
miara
 odległości, 302
 podobieństwa, 29, 31, 32, 33,
 35, 44, 54, 319
 stopnia niejednorodności, 320
 ważona, 34, 186, 189
MLP, 92
model
 myślowy, 23
 przewidyjący ceny, 181, 186,
 190, 191, 192, 193, 195, 196,
 198, 205, 206, 207

Multilayer Perceptron, *Patrz:* MLP
mutacja, 113, 256, 258, 265, 308

N

nawigowanie, *Patrz:*
 przeszukiwanie
Netflix, 21, 24
niejednorodność Giniego, 162, 163,
 320
NMF, *Patrz:* macierz faktoryzacja
 nieujemna
Non-Negative Matrix
 Factorization, *Patrz:* macierz
 faktoryzacja nieujemna
NumPy, 242, 314

O

ocena, 83, 88
 częstości występowania
 wyrazów, 83
 liczbowa, 84
 lokalizacja w dokumencie, 83
 normalizacja, 84
 odległość między wyrazami, 83
odległość
 euklidesowa, 29, 33, 35, 54,
 184, 317
 Manhattan, 33
 między wyrazami, 83
odnośnik zewnętrzny, 82
optymalizacja, 103, 122, 125, 130,
 307, 309
 algorytm genetyczny, *Patrz:*
 algorytm genetyczny
 funkcja kosztu, *Patrz:* funkcja
 kosztu
 łańcucha dostaw, 26
 metoda największego
 wzrostu, *Patrz:* metoda
 największego wzrostu
 podróży grupy osób, 104, 117,
 122
 presja ewolucyjna,
 Patrz: presja ewolucyjna
 reprezentowanie rozwiązania,
 105, 123, 125, 126, 130
 stochastyczna, 103
 wyszukiwanie losowe,
 Patrz: wyszukiwanie losowe
 wyżarzanie symulowane,
 Patrz: wyżarzanie
 symulowane

P

Page Larry, 88
PageRank, 23, 24, 88, 89
pakiet minidom, 118
Pandora, 24
plik HTML, 79
poczty elektronicznej filtrowanie,
 23
populacja, *Patrz:* generacja
Porter Stemmer, 79
prawdopodobieństwo, 319
 gęstość, 196, 198, 322
 skumulowane, 198
 warunkowe, 320
presja ewolucyjna, 256
problem koktajlowy, 233
program
 krzyżowanie,
 Patrz: krzyżowanie
 miara sukcesu, 264, 269
 mutacja, *Patrz:* mutacja
 reprezentacja drzewa,
 Patrz: drzewo
programowanie
 funkcyjne, 14
 genetyczne, 116, 255, 256, 257
 funkcje, 276
 gra, 272, 274, 275
 pamięć, 277
 program, *Patrz:* program
 ranking programów, 271
 środowisko, 269, 277
 test, 263, 264
 obiektywne, 14
 proceduralne, 14
przeszukiwanie, 73, 75, 80, 81, 83,
 84, 85, 86, 87
przewidywanie liczbowe, 181
przyrost informacji, 164
punkt średniej, 213
pysqlite, 313
Python, 14, 15
Python Imaging Library, *Patrz:*
 biblioteka PIL

R

regresja, 24
reguła aktualizowania
 multiplikatywnego, 244
rekomendacja, 27, 36
 odnośników, 38, 41
 sąsiadów, 41
 tworzenie, 43

rynek

finansowy, 22, 249, 250
wolumen obrotów, 249, 250
kontraktów terminowych, 22
prognostyczny, 25

S

serwis randkowy, 25, 176, 209
sieć neuronowa, 23, 25, 49, 74, 92,
157, 158, 288, 291
definicja, 93
funkcja sigmoidalna, 96
funkcja tangensa
hiperbolicznego, 95
neuron, *Patrz:* sieć neuronowa
węzeł
perceptronu
wielowarstwowego,
Patrz: MLP
sztuczna, 92, 100, 153
śledząca kliknięcia, 92
uczenie, 93, 99, 290
wady, 292
warstwa ukryta, *Patrz:*
warstwa ukryta
węzeł, 92, 94
zalety, 292
skalowanie wielowymiarowe, 68,
303, 304
słownik, 15, 39, 40
identyfikatorów adresów
URL, 84
ocen, 84
zagnieżdżony, 28
spam, 23, 133
filtrowanie, 24, 133
łączenie
prawdopodobieństw, 139,
144
obliczanie
prawdopodobieństwa,
137, 138, 139, 140, 141, 142
oparte na regułach, 133
uczenie się, 134, 135, 138,
139, 140, 142, 146, 147
klasyfikator, *Patrz:* klasyfikator
WordPress, 152
SpamBayes, 142
strona
internetowa, 75
ocena, *Patrz:* ocena
Support Vector Machine, *Patrz:*
maszyna wektorów nośnych
SVM, *Patrz:* maszyna wektorów
nośnych
system rekomendacji, 24

Ś

średnia
punkt, *Patrz:* punkt średniej
ważona, 189, 318
świadomość zbiorowa, 22

T

tabela
dokumentów, 73, 78
indeks, 94
tangens hiperboliczny,
Patrz: funkcja tangensa
hiperbolicznego
Tanimoto współczynnik,
Patrz: współczynnik Tanimoto
Tapestry, 28
technika nienadzorowana,
Patrz: uczenie nienadzorowane
tekst odnośników, 91
transformacja wielomianowa, 293
trik jądrowy, 221, 224, 293, 294
twierdzenie Bayesa, 140

U

uczenie
maszynowe, 14, 16, 23, 25, 159
grupowanie, 26
ograniczenia, 24
nadzorowane, 49, 153, 233,
238
nienadzorowane, 50, 233, 299,
302
za pomocą drzew
decyzyjnych, *Patrz:* drzewo
decyzyjne
Universal Feed Parser, 51, 234, 311

W

walidacja krzyżowa, 189, 206
wariancja, 321
warstwa
ukryta, 92, 94
zapytań, 92
wektor, 214, 221, 322
wiadomość e-mail, *Patrz:* e-mail
wiersz
poleceń, 14
zachęty, 14
Wikipedia, 22
witryna społecznościowa, 64, 316
wizualizacja sieci, 125

wolumen obrotów, 249, 250
WordPress, 152
współczynnik
Jaccarda, 33
korelacji Pearsona,
Patrz: korelacja Pearsona
Tanimoto, 66, 319
tłumienia, 88
wtyczka SpamBayes,
Patrz: SpamBayes
wykres punktowy, 211
wyrażenie listowe, 15, 34
wyszukiwanie
losowe, 108, 109
pełnotekstowe, 73
wyszukiwarka, 88
Kayak, *Patrz:* Kayak
pełnotekstowa, 73
rejestrwanie kliknięć, 91
wyżarzanie symulowane, 111,
128, 244, 308

X

Xerox PARC, 28
XML, 14, 51

Y

Yahoo! Finance, 249, 250

Z

zakładka, 38
zapytanie klasyfikowanie, 74
zbiór
testowy, 189
uczący, 189
zmiennych
heterogenicznych, 191
nieistotnych, 192, 193
zbiór danych
budowanie, 40, 42
MovieLens, 45
Zebo, 64, 65
Zillow, 173
zmienna
heterogeniczna, 191
nieistotna, 192, 193, 297
wzajemna zależność, 211
znacznik, 42
zupa, 64

PROGRAM PARTNERSKI

GRUPY WYDAWNICZEJ 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 WYDAWNICZA



Helion SA

Nowe usługi 2.0

Przewodnik po analizie zbiorów danych



Internet to nic innego jak gigantyczny zbiór danych. Każdy, kto znajdzie sposób na ich umiejętne wykorzystanie, ma szansę zbudować aplikację, która odniesie światowy sukces. Serwisy randkowe, portale społecznościowe, porównywarki cen – to tylko drobna część serwisów, które możesz wykorzystać przy tworzeniu nowej usługi. Jak analizować dane i wyciągnąć wnioski? Na wiele podobnych pytań odpowiada ta jedyna w swoim rodzaju książka.

W trakcie lektury poznasz najlepsze sposoby filtrowania danych, tworzenia rekomendacji, wykrywania grup oraz wyszukiwania i klasyfikowania. Na kolejnych stronach znajdziesz bogaty zbiór informacji poświęconych algorytmom analizującym dane. Ponadto będziesz mieć możliwość zapoznania się z różnymi sposobami optymalizacji, modelowania przy użyciu drzew decyzyjnych oraz tworzenia modeli cenowych. Książka ta w rękach wprawnego programisty może stanowić niesamowite narzędzie. Otwiera wrota do świata pełnego danych i zależności pomiędzy nimi!

Dzięki tej książce:

- poznasz najlepsze i najskuteczniejsze algorytmy do analizy danych,
- zbudujesz model cen,
- nauczysz się korzystać z drzew decyzyjnych,
- zastosujesz dane z sieci do budowy nowych usług.

Wyciągnij właściwe wnioski z posiadanych danych!

helion.pl
księgarnia
internetowa

Nr katalogowy: 24398



Księgarnia internetowa:
<http://helion.pl>



Zamówienia telefoniczne:
0 801 339900
0 601 339900



Helion

Sprawdź najnowsze promocje:

🔗 <http://helion.pl/promocje>

Książki najchętniej czytane:

🔗 <http://helion.pl/bestsellery>

Zamów informacje o nowościach:

🔗 <http://helion.pl/nawosci>

Helion SA

ul. Kościuszki 1c, 44-100 Gliwice

tel.: 32 230 98 63

e-mail: helion@helion.pl

<http://helion.pl>



ISBN 978-83-246-9298-9



Cena 54,00 zł