

Matematyka dyskretna dla praktyków

Algorytmy i uczenie maszynowe w Pythonie

Ryan T. White
Archana Tikayat Ray

Helion 



Tytuł oryginału: Practical Discrete Mathematics: Discover math principles that fuel algorithms for computer science and machine learning with Python

Tłumaczenie: Filip Kamiński

ISBN: 978-83-283-8396-8

Copyright © Packt Publishing 2021. First published in the English language under the title 'Practical Discrete Mathematics' – (9781838983147).

Polish edition copyright © 2022 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: <https://helion.pl> (księgarnia internetowa, katalog książek)

Pliki z przykładami omawianymi w książce można znaleźć pod adresem:

<https://ftp.helion.pl/przyklady/madypr.zip>

Drogi Czytelniku!

Jeżeli chcesz ocenić tę książkę, zajrzyj pod adres

<https://helion.pl/user/opinie/madypr>

Możesz tam wpisać swoje uwagi, spostrzeżenia, recenzję.

Printed in Poland.

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

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

Spis treści

O autorach	11
O recenzencie	12
Wprowadzenie	13
Część I. Podstawowe pojęcia z obszaru matematyki dyskretnej	17
Rozdział 1. Podstawowe pojęcia, notacja, teoria mnogości, relacje i funkcje	19
Czym jest matematyka dyskretna?	19
Podstawowa teoria mnogości	22
Definicja — zbiory i ich notacja	22
Definicja — elementy zbiorów	22
Definicja — zbiór pusty	22
Przykład — kilka przykładowych zbiorów	22
Definicja — podzbiory i nadzbiory	23
Definicja — notacja konstrukcji zbiorów	23
Przykład — użycie notacji konstrukcji zbiorów	23
Definicja — podstawowe operacje na zbiorach	24
Definicja — zbiory rozłączne	26
Przykład — liczby parzyste i nieparzyste	26
Twierdzenie — prawa De Morgana	26
Przykład — prawo De Morgana	27
Definicja — moc zbioru	27
Przykład — moce zbiorów	28
Funkcje i relacje	28
Definicja — relacje, dziedziny i przeciwdziedziny	28
Definicja — funkcje	28
Przykłady — relacje kontra funkcje	29

Przykład — funkcje w algebrze elementarnej	29
Przykład — funkcje w Pythonie i funkcje matematyczne	30
Podsumowanie	31
Rozdział 2. Logika formalna i dowody matematyczne	33
Logika formalna i dowodzenie za pomocą tablic prawdy	34
Podstawy terminologii stosowanej w logice formalnej	34
Przykład — niepoprawny argument	35
Przykład — wszystkie pingwiny mieszkają w RPA!	36
Podstawowe idee logiki formalnej	37
Tablice prawdy	38
Przykład — implikacja odwrotna	40
Przykład — prawo przechodniości implikacji	40
Przykład — prawa De Morgana	41
Przykład — implikacja przeciwstawna	42
Dowody wprost	43
Przykład — iloczyn parzystych i nieparzystych liczb całkowitych	44
Przykład — pierwiastki liczb parzystych	45
Skrócenie dowodu za pomocą implikacji przeciwstawnej	46
Dowody nie wprost	46
Przykład — czy istnieje najmniejsza dodatnia liczba wymierna?	48
Przykład — dowód, że 2 jest liczbą niewymierną	48
Przykład — ile jest liczb pierwszych?	49
Dowodzenie przez indukcję matematyczną	51
Przykład — suma $1+2+\dots+n$	51
Przykład — kształty wypełniające przestrzeń	53
Przykład — wzrost wykładniczy a wzrost w tempie silni	54
Podsumowanie	56
Rozdział 3. Obliczenia w systemach o podstawie n	57
Zrozumieć liczby o podstawie n	58
Przykład — liczby dziesiętne	58
Definicja — liczby o podstawie n	59
Konwersje między różnymi podstawami	59
Konwersja liczb o podstawie n na liczby dziesiętne	59
Przykład — wartość dziesiętna liczby o podstawie 6	60
Konwersja z zapisu dziesiętnego na system o podstawie n	60
Przykład — konwersja liczby dziesiętnej na liczbę binarną (podstawa 2)	60
Przykład — konwersje z systemu dziesiętnego na binarny i szesnastkowy w Pythonie	61
Liczby binarne i ich zastosowania	62
Algebra Boole'a	63
Przykład — użytkownicy Netflixa	67
Liczby szesnastkowe i ich zastosowania	69
Przykład — położenie obiektów w pamięci komputera	70
Przykład — wyświetlanie komunikatów o błędach	71
Przykład — adresy MAC	71
Przykład — kolory w sieci	72
Podsumowanie	73

Rozdział 4. Kombinatoryka z użyciem SciPy	74
Podstawy zliczania	75
Definicja — iloczyn kartezjański	75
Twierdzenie — moc iloczynów kartezjańskich zbiorów skończonych	75
Definicja — iloczyn kartezjański n zbiorów	76
Twierdzenie — reguła mnożenia	76
Przykład — bajty	76
Przykład — kolory w komputerze	77
Permutacje i kombinacje obiektów	77
Definicja — permutacja	77
Przykład — permutacje prostego zbioru	77
Twierdzenie — permutacje zbioru	78
Przykład — playlista	78
Wzrost w tempie silni	78
Twierdzenie — wariacja bez powtórzeń	79
Definicja — kombinacja	80
Przykład — kombinacje kontra permutacje prostego zbioru	80
Twierdzenie — kombinacje ze zbioru	80
Współczynniki dwumianowe	80
Przykład — tworzenie zespołu	81
Przykład — kombinacje kul	81
Alokacja pamięci	82
Przykład — wstępne przydzielanie pamięci	82
Skuteczność algorytmów siłowych	84
Przykład — szyfr Cezara	84
Przykład — problem komiwojażera	87
Podsumowanie	89
Rozdział 5. Elementy prawdopodobieństwa dyskretnego	90
Definicja — doświadczenie losowe	91
Definicje — zdarzenia elementarne, zdarzenia losowe, przestrzenie prób	91
Przykład — rzut monetą	91
Przykład — rzut wieloma monetami	92
Definicja — miara probabilistyczna	92
Twierdzenie — podstawowe własności prawdopodobieństwa	93
Przykład — sport	94
Twierdzenie — monotoniczność	95
Twierdzenie — zasada włączeń i wyłączeń	95
Definicja — rozkład jednostajny	96
Twierdzenie — obliczanie prawdopodobieństwa	96
Przykład — rzut wieloma monetami	97
Definicja — zdarzenia niezależne	98
Przykład — rzucanie wieloma monetami	98
Prawdopodobieństwo warunkowe i twierdzenie Bayesa	99
Definicja — prawdopodobieństwo warunkowe	100
Przykład — temperatury i opady	100
Twierdzenie — reguły mnożenia	101
Twierdzenie — twierdzenie o prawdopodobieństwie całkowitym	102
Twierdzenie — twierdzenie Bayesa	102

Bayesowski filtr antyspamowy	103
Zmienne losowe, średnie i wariancja	104
Definicja — zmienna losowa	104
Przykład — błędy przesyłania danych	104
Przykład — empiryczna zmienna losowa	105
Definicja — wartość oczekiwana	105
Przykład — empiryczna zmienna losowa	106
Definicja — wariancja i odchylenie standardowe	106
Twierdzenie — obliczanie wariancji w praktyce	106
Przykład — empiryczna zmienna losowa	107
Google PageRank (część I)	107
Podsumowanie	110

Część II. Zastosowania matematyki dyskretnej w analizie danych i informatyce **111**

Rozdział 6. Algorytmy algebry liniowej **113**

Zrozumieć układy równań liniowych	114
Definicja — równanie liniowe dwóch zmiennych	114
Definicja — kartezjański układ współrzędnych	114
Przykład — równanie liniowe	115
Definicja — układ dwóch równań liniowych dwóch zmiennych	116
Przykład — układ oznaczony	116
Przykład — układ sprzeczny	117
Przykład — układ nieoznaczony	119
Definicja — układy równań liniowych i ich rozwiązania	120
Definicja — układy oznaczone, sprzeczne i nieoznaczone	121
Macierze i macierzowe reprezentacje układów równań liniowych	121
Definicja — macierze i wektory	122
Definicja — dodawanie i odejmowanie macierzy	123
Definicja — mnożenie przez skalar	124
Definicja — transpozycja macierzy	125
Definicja — iloczyn skalarny wektorów	126
Definicja — mnożenie macierzy	126
Przykład — ręczne mnożenie macierzy i mnożenie macierzy w NumPy	127
Rozwiązywanie małych układów równań liniowych za pomocą metody eliminacji Gaussa	129
Definicja — współczynnik wiodący	129
Definicja — zredukowana macierz schodkowa	130
Przykład — układ oznaczony z macierzą schodkową	130
Przykład — układ sprzeczny z macierzą schodkową	130
Przykład — układ nieoznaczony z macierzą schodkową	131
Algorytm — eliminacja Gaussa	131
Przykład — układ 3 równań liniowych z 3 niewiadomymi	132
Rozwiązywanie dużych układów równań liniowych za pomocą NumPy	134
Przykład — układ 3 równań z 3 niewiadomymi (NumPy)	134
Przykład — sprzeczne i nieoznaczone układy równań w NumPy	135
Przykład — układ 10 równań z 10 niewiadomymi (NumPy)	136
Podsumowanie	138

Rozdział 7. Złożoność algorytmów	139
Złożoność obliczeniowa algorytmów	139
Notacja dużego O	143
Kiedy stałe mają znaczenie?	147
Złożoność algorytmów zawierających podstawowe instrukcje sterujące	149
Przeptyw sekwencyjny	149
Przeptyw warunkowy	150
Pętla	151
Złożoność popularnych algorytmów wyszukiwania	155
Algorytm wyszukiwania liniowego	155
Algorytm wyszukiwania binarnego	156
Popularne klasy złożoności obliczeniowej	159
Podsumowanie	161
Bibliografia	161
Rozdział 8. Przechowywanie i wyodrębnianie cech z grafów, drzew i sieci	162
Zrozumieć grafy, drzewa i sieci	162
Definicja — graf	163
Definicja — stopień wierzchołka	163
Definicja — ścieżki	164
Definicja — cykle	165
Definicja — drzewa lub grafy acykliczne	165
Definicja — sieci	166
Definicja — grafy skierowane	167
Definicja — sieci skierowane	168
Definicja — wierzchołki sąsiednie	169
Definicja — grafy i składowe spójne	169
Zastosowania grafów, drzew i sieci	171
Przechowywanie grafów i sieci	173
Definicja — lista sąsiedztwa	173
Definicja — macierz sąsiedztwa	173
Definicja — macierz sąsiedztwa dla grafu skierowanego	175
Wydajne przechowywanie danych sąsiedztwa	178
Definicja — macierz wag sieci	178
Definicja — macierz wag sieci skierowanej	179
Wyodrębnianie cech z grafów	181
Stopnie wierzchołków w grafie	181
Liczba ścieżek o określonej długości między wierzchołkami	182
Twierdzenie — potęgi macierzy sąsiedztwa	183
Potęgi macierzy w Pythonie	183
Twierdzenie — najkrótsza (pod względem liczby krawędzi) ścieżka pomiędzy v_i i v_j	184
Podsumowanie	186
Rozdział 9. Przeszukiwanie struktur danych i znajdowanie najkrótszych ścieżek	187
Przeszukiwanie struktur grafowych i drzew	188
Algorytm przeszukiwania w głąb (DFS)	188
Implementacja algorytmu przeszukiwania w głąb w Pythonie	191

Problem najkrótszej ścieżki i jego warianty	193
Najkrótsze ścieżki w sieciach	194
Inne zastosowania najkrótszych ścieżek	194
Definicja problemu najkrótszej ścieżki	195
Sprawdzenie, czy istnieje rozwiązanie	196
Znajdowanie najkrótszych ścieżek metodą siłową	198
Algorytm Dijkstry znajdowania najkrótszych ścieżek	201
Algorytm Dijkstry	201
Algorytm Dijkstry zastosowany do małego problemu	202
Implementacja algorytmu Dijkstry w Pythonie	207
Przykład — najkrótsze ścieżki	209
Przykład — sieć bez połączenia	211
Podsumowanie	213

Część III. Praktyczne zastosowania matematyki dyskretnej **215**

Rozdział 10. Analiza regresji za pomocą NumPy i scikit-learn **217**

Zbiór danych	218
Linie najlepszego dopasowania i metoda najmniejszych kwadratów	220
Zmienne	220
Zależność liniowa	220
Regresja	220
Linia najlepszego dopasowania	221
Metoda najmniejszych kwadratów i suma kwadratów błędów	224
Dopasowywanie prostej metodą najmniejszych kwadratów w NumPy	226
Dopasowywanie krzywych metodą najmniejszych kwadratów z użyciem NumPy i SciPy	229
Dopasowanie płaszczyzn metodą najmniejszych kwadratów z użyciem NumPy i SciPy	232
Podsumowanie	234

Rozdział 11. Wyszukiwanie w sieci za pomocą algorytmu PageRank **236**

Rozwój wyszukiwarek na przestrzeni lat	237
Google PageRank (część II)	238
Implementacja algorytmu PageRank w Pythonie	245
Zastosowanie algorytmu na danych rzeczywistych	249
Podsumowanie	253

Rozdział 12. Analiza głównych składowych za pomocą scikit-learn **254**

Wartości i wektory własne, bazy ortogonalne	255
Redukcja wymiarowości za pomocą analizy głównych składowych	260
Implementacja metody PCA z scikit-learn	264
Zastosowanie metody PCA na rzeczywistych danych	267
Podsumowanie	270

Przeszukiwanie struktur danych i znajdowanie najkrótszych ścieżek

W tym rozdziale omówimy techniki przeszukiwania grafów, drzew i sieci oraz praktyczne zastosowania przeszukiwania grafów. Przedstawimy i przeanalizujemy dwa popularne algorytmy: **algorytm przeszukiwania w głąb** (ang. *depth-first search*, DFS) oraz algorytm Dijkstry znajdowania najkrótszych ścieżek między wierzchołkami w sieciach. Oba algorytmy zostaną zaprezentowane na małych strukturach, które pozwolą Ci intuicyjnie zrozumieć ich działanie. Następnie zaprezentujemy implementacje w Pythonie, które można wykorzystać do rozwiązywania rzeczywistych problemów.

W tym rozdziale omówimy następujące zagadnienia:

- Przeszukiwanie struktur grafowych i drzew.
- Algorytm przeszukiwania w głąb.
- Problem najkrótszej ścieżki i jego warianty.
- Znajdowanie najkrótszych ścieżek metodą siłową.
- Algorytm Dijkstry znajdowania najkrótszych ścieżek.
- Implementacja algorytmu Dijkstry w Pythonie.

Po przeczytaniu tego rozdziału będziesz umiał wyjaśnić cel przeszukiwania, będziesz wiedział, jak zaimplementować metodę przeszukiwania w głąb, zrozumiesz problemy związane z najkrótszą ścieżką i ich warianty oraz będziesz wiedział, jak zaimplementować algorytm Dijkstry do znajdowania najkrótszych ścieżek.

Przeszukiwanie struktur grafowych i drzew

W poprzednim rozdziale poznałeś grafy i drzewa. Pamiętaj, że w tym rozdziale, ilekroć będziemy odwoływać się do grafów, będziemy mieli na myśli też drzewa, które również są grafami, ale takimi bez cykli. Tematem tego rozdziału jest przeszukiwanie grafów. Przeszukiwanie to po prostu przechodzenie wzdłuż krawędzi grafu w celu znalezienia ścieżek do wierzchołków docelowych. Brzmi to bardzo prosto, ale ponieważ wiele grafów wykorzystywanych w praktyce jest ogromnych, chcemy to zrobić tak wydajnie, jak to tylko możliwe.

Istnieje wiele powodów, dla których możemy chcieć przeszukać graf. Załóżmy na przykład, że chcesz wysłać wiadomość przez sieć do pięciu znajomych mieszkających w pięciu różnych miastach. Z pewnością nie istnieje bezpośrednie połączenie między Twoim urządzeniem a urządzeniami Twoich znajomych. Dlatego zanim wiadomość dotrze do znajomych, musi przejść przez wiele urządzeń sieciowych, które mogą być reprezentowane przez wierzchołki w grafie. Ponieważ urządzenia sieciowe zmieniają strukturę połączeń w czasie, przechowywanie stałego grafu reprezentującego sieć nie jest możliwe. Oznacza to, że ścieżki muszą być wyznaczone w momencie wysłania wiadomości. Jest to przykład, który możemy rozwiązać za pomocą przeszukiwania grafów.

Osobną kwestią jest ustalenie, którą ścieżką należy przesłać wiadomość. Możesz chcieć wybrać ścieżki, które zabierają najmniej czasu na dostarczenie wiadomości, lub ścieżki, które przechodzą przez nieobciążone ruchem urządzenia sieciowe. Znajdowanie najkrótszej ścieżki zostanie omówione w dalszej części tego rozdziału. Na razie wystarczy, abyś wiedział, że przeszukiwanie grafów jest często ważnym elementem rozwiązywania takich problemów.

Algorytmy przeszukiwania grafów nie robią zbyt wiele same z siebie. Wykorzystuje się je zazwyczaj w roli elementów składowych bardziej złożonych programów, które rozwiązują wiele problemów, takich jak znajdowanie najkrótszych ścieżek i minimalnych drzew rozpinających, wykrywanie składowych spójnych, analizowanie przepływu w sieci, dopasowywanie wierzchołków pomiędzy grupami i rozwiązywanie dużych problemów planowania, w których istnieją złożone relacje pomiędzy zadaniami.

W następnym podrozdziale poznasz algorytm przeszukiwania w głąb — jeden z najpopularniejszych algorytmów przeszukiwania grafów.


Algorytm przeszukiwania w głąb (DFS)

Przeszukiwanie grafu to w skrócie przejście przez jego elementy w usystematyzowany sposób. W tym podrozdziale poznasz algorytm pozwalający przeprowadzić taki proces. Choć przejście przez strukturę grafu może być istotne samo w sobie, jak już wspomnieliśmy, często jest to podproblem, który rozwiązuje się w jakimś bardziej złożonym zagadnieniu grafowym. Algorytm przeszukiwania w głąb (ang. *depth-first search*, DFS) jest prawdopodobnie najczęściej stosowanym algorytmem przeszukiwania grafów. Jest to wydajna metoda, często wykorzystywana w bardziej złożonych rozwiązaniach.

Algorytm przeszukiwania w głąb rozpoczyna pracę w wierzchołku startowym, a następnie przechodzi przez pierwszą związaną z nim krawędź do kolejnego wierzchołka i powtarza ten proces aż do momentu, gdy nie będzie krawędzi prowadzących do nieodwiedzonych jeszcze wierzchołków (to znaczy, dopóki nie uda mu się wejść najgłębiej, jak to możliwe). Po dotarciu do końcowego wierzchołka algorytm cofa się do ostatniego wierzchołka, który ma jeszcze nieodwiedzonych sąsiadów, i przechodzi od tego wierzchołka przez kolejne nieodwiedzone wierzchołki, aż do kolejnego ślepego zaułka. Następnie algorytm ponownie się cofa i odwiedza kolejne nieodwiedzone jeszcze wierzchołki aż do momentu, gdy wszystkie wierzchołki połączone z wierzchołkiem startowym zostaną odwiedzone.

Abyś to dobrze zrozumiał, prześledzimy działanie tej metody na małym grafie z rysunku 9.1. Rozpoczniemy od wierzchołka v_1 i przeszukamy graf za pomocą algorytmu przeszukiwana w głąb.

Zauważ, że nie określiliśmy, jak należy dokonać wyboru ścieżek. Ustalmy więc, że w przypadku więcej niż jednej opcji wybierzemy wierzchołek o najniższym numerze. Wierzchołki i krawędzie w obrębie aktualnie przetwarzanej ścieżki zaznaczymy na pomarańczowo, a poprzednio odwiedzone wierzchołki i wcześniej przebyte krawędzie na zielono (rysunek 9.1).




Rysunek 9.1. Graf


Krok 1. Pierwszym krokiem będzie przejście do wierzchołka v_2 . Wierzchołek ten nie sąsiaduje z żadnymi wierzchołkami, których jeszcze nie odwiedziliśmy, więc algorytm zatrzyma się (rysunek 9.2).

Krok 2. Cofamy się do wierzchołka v_1 . Następnie będziemy podążali kolejnymi ścieżkami, aż ponownie dotrzemy do ślepego zaułka. Przechodzimy więc z v_1 do v_5 , potem do v_4 i dalej do v_3 oraz v_6 , który nie ma już żadnych nieodwiedzonych sąsiadów. Ponownie następuje więc zatrzymanie (rysunek 9.3).


Krok 3. Cofamy się do wierzchołka v_5 będącego ostatnim wierzchołkiem na pomarańczowej ścieżce, który ma jeszcze nieodwiedzonych sąsiadów. Przechodzimy kolejno przez v_7 , v_8 , v_9 i v_{10} , gdzie następuje kolejne zatrzymanie (rysunek 9.4).



Rysunek 9.2. Pierwszy krok w algorytmie przeszukiwania w głąb



Rysunek 9.3. Drugi krok algorytmu przeszukiwania w głąb



Rysunek 9.4. Trzeci krok algorytmu przeszukiwania w głąb

W tym momencie wszystkie wierzchołki połączone z v_1 zostały pokolorowane, co oznacza, że wszystkie wierzchołki zostały odwiedzone, a więc przeszukiwanie grafu zostało zakończone.

Lista wierzchołków odwiedzonych przez algorytm jest następująca:

$$v_1, v_2, v_5, v_4, v_3, v_6, v_7, v_8, v_9, v_{10}$$

Zauważ, że nie odwiedziliśmy wierzchołka v_{11} , który nie jest połączony z wierzchołkiem źródłowym. Algorytm przeszukiwania w głąb nie pominię żadnego wierzchołka, który jest elementem tej samej spójnej składowej co wierzchołek startowy. Aby odwiedzić wszystkie wierzchołki grafu z wieloma składowymi spójnymi, konieczne jest uruchomienie algorytmu w każdej składowej osobno.

Zajmiemy się teraz implementacją algorytmu przeszukiwana w głąb w Pythonie.

Implementacja algorytmu przeszukiwania w głąb w Pythonie

Oczywiście w przypadku dużych problemów spotykanych w praktyce nie jesteśmy w stanie przeprowadzić ręcznego przeszukiwania w głąb! Stwórzmy więc jego implementację w Pythonie.

Zdefiniujemy funkcję o nazwie DFS, która przyjmie macierz sąsiedztwa i zwróci wszystkie wierzchołki połączone ścieżką z wierzchołkiem startowym.

Implementacja będzie się składała z kilku fragmentów, które postaramy się na bieżąco wyjaśniać. Zaczynamy od dokumentacji, która opisuje, co robi funkcja oraz jakie ma parametry wejściowe i wyjściowe:

```
# Algorytm przeszukiwania w głąb (Depth First Search)
#
# WEJŚCIE
# A — kwadratowa, symetryczna i binarna macierz sąsiedztwa
# source — numer wierzchołka startowego (w grafie)
#
# WYJŚCIE
# vertexList — uporządkowana lista odwiedzonych wierzchołków
```

Następnie zdefiniujemy funkcję, która przyjmuje macierz sąsiedztwa i numer wierzchołka źródłowego. W pierwszych wierszach odejmujemy od numeru wierzchołka startowego 1 (w Pythonie tablice są indeksowane od zera), ustalamy liczbę wierzchołków w grafie i inicjujemy kilka struktur danych, w tym tablicę wartości binarnych do przechowywania odwiedzonych wierzchołków, stos, który ma być użyty w algorytmie, oraz listę wierzchołków, które odwiedził algorytm:

```
def DFS(A, source):
    # Zmniejszamy wartość source o 1, aby uniknąć błędów
    source -= 1

    # Znajdowanie liczby wierzchołków
    n = A.shape[0]
```

```
# Stworzenie zbioru nieodwiedzonych wierzchołków. Na początek zbiór ten zawiera wszystkie wierzchołki
unvisited = [1] * n

# Inicjalizacja kolejki. Na początek kolejka zawiera tylko wierzchołek startowy
stack = [source]

# Inicjalizacja listy wierzchołków
vertexList = []
```

Następnie funkcja zdejmuje ostatni wierzchołek ze stosu i dodaje go (jeśli nie został jeszcze odwiedzony) do końca kolejki wraz z listą jego jeszcze nieodwiedzonych sąsiadów. Operacje te są powtarzane aż do momentu, gdy stos będzie pusty. Na zakończenie funkcja zwraca listę odwiedzonych wierzchołków:

```
# Dopóki stos (zmienna stack) nie jest pusty
while stack:
    # Usunięcie odwiedzzonego wierzchołka ze stosu i zapisanie go do zmiennej v
    v = stack.pop()

    # Jeżeli v nie był wcześniej odwiedzony, oznaczamy go jako odwiedzony i dodajemy do listy
    # odwiedzonych wierzchołków
    if unvisited[v]:
        # Zapis i wyświetlenie numeru właśnie odwiedzzonego wierzchołka
        vertexList.append(v)

        # Oznaczenie wierzchołka v jako odwiedzzonego
        unvisited[v] = 0

    # Przejście przez wierzchołki
    for u in range(n - 1, 0, -1):
        # Dodanie każdego nieodwiedzzonego wierzchołka do stosu
        if A[v,u] == 1 and unvisited[u] == 1:
            stack.append(u)

# Zwrócenie listy odwiedzonych wierzchołków
return vertexList
```

Kod jest już kompletny. Aby upewnić się, że działa on zgodnie z przeznaczeniem, przetestujemy go na przykładzie, który rozwiązaliśmy wcześniej ręcznie. Najpierw musimy zapisać naszą macierz sąsiedztwa:

```
# Macierz sąsiedztwa grafu z rysunku 9.1
A = numpy.array([[0, 1, 0, 0, 1, 0, 0, 0, 0, 0, 0],
                 [1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0],
                 [0, 0, 0, 1, 0, 1, 0, 0, 0, 0, 0],
                 [0, 0, 1, 0, 1, 1, 0, 0, 0, 0, 0],
                 [1, 0, 0, 1, 0, 0, 1, 1, 1, 0, 0],
                 [0, 0, 1, 1, 0, 0, 0, 0, 0, 0, 0],
                 [0, 0, 0, 0, 1, 0, 0, 1, 0, 1, 0],
                 [0, 0, 0, 0, 1, 0, 1, 0, 1, 1, 0],
                 [0, 0, 0, 0, 1, 0, 0, 1, 0, 1, 0],
                 [0, 0, 0, 0, 0, 0, 1, 1, 1, 0, 0],
                 [0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0]])
```

Następnie należy wywołać funkcję DFS z parametrem `source=1`, czyli z numerem wierzchołka, od którego rozpoczęliśmy ręczne obliczenia. Ponieważ numerowaliśmy nasze wierzchołki od 1, a Python indeksuje tablice od 0, do elementów listy otrzymanej z wywołania musimy dodać 1:

```
# Uruchomienie algorytmu na macierzy sąsiedztwa A z parametrem source równym 1
vertexList = DFS(A,1)

# Dodanie 1 do numerów wierzchołków
[x + 1 for x in vertexList]
```

Po uruchomieniu kodu otrzymasz poniższy wynik:

```
[1, 2, 5, 4, 3, 6, 7, 8, 9, 10]
```

Zauważ, że podczas ręcznej implementacji algorytmu znaleźliśmy dokładnie tę samą listę z dokładną tą samą kolejnością elementów. Najwyraźniej nasz kod robi dokładnie to samo, co zrobiliśmy ręcznie. Jedyna różnica jest taka, że wynik otrzymujemy niemal natychmiast. Nasza implementacja algorytmu przeszukiwania w głąb okazała się więc wielkim sukcesem!

W tym podrozdziale dowiedziałeś się, czym jest algorytm przeszukiwania w głąb oraz jakie są wybrane zastosowania. Zaprezentowaliśmy też jego działanie na przykładzie i zaimplementowaliśmy go w Pythonie. Na koniec pokazaliśmy, że otrzymane wyniki są zgodne z tymi z ręcznych obliczeń.

Pozostała część rozdziału koncentruje się na bardzo praktycznym problemie, jakim jest znalezienie najkrótszej ścieżki między dwoma wierzchołkami w sieci lub grafie ważonym.

Problem najkrótszej ścieżki i jego warianty

W tym podrozdziale skupimy się na innym problemie związanym z grafami, jakim jest znajdowanie najkrótszych ścieżek między wierzchołkami w sieci. Problem ten jest istotny w zagadnieniach związanych z routinguem, takich jak znalezienie najkrótszej trasy do celu lub najszybszego sposobu dostarczenia wiadomości przez sieć komputerową. Zagadnienie najkrótszej ścieżki zostało również wykorzystane w problemie dotyczącym minimalizacji spalania paliwa przy jednoczesnym precyzyjnym ustawieniu floty małych satelitów badawczych wykorzystywanych do przesyłania obrazów odległych gwiazd.

Problem znajdowania najkrótszej ścieżki w grafach bez ważonych krawędzi został omówiony w poprzednim rozdziale. Powróćmy do niego na chwilę, zanim przejdziemy do bardziej ogólnego problemu, który dotyczy sieci (grafów ważonych). W rozdziale 8. „Przechowywanie i wyodrębnianie cech z grafów, drzew i sieci” przedstawiliśmy sposób znalezienia najkrótszej (składającej się z najmniejszej liczby krawędzi) ścieżki między węzłami v_i i v_j w grafie i w grafie skierowanym. Była to po prostu najmniejsza liczba n , taka, że n -ta potęga macierzy sąsiedztwa zawiera dodatnią wartość w i -tym wierszu i j -tej kolumnie. Jest to dość oczywiste, ponieważ wartość z tej pozycji jest równa liczbie ścieżek z v_i do v_j o długości n .


Ponieważ złożoność obliczeniowa mnożenia macierzy jest niewielka (poniżej $O(n^3)$), zależność ta jest niezwykle przydatna, pozwala bowiem w efektywny sposób znaleźć najkrótszą odległość między wierzchołkami w grafach i grafach skierowanych.

Najkrótsze ścieżki w sieciach

Problemem o znacznie szerszym zastosowaniu jest zagadnienie znajdowania najkrótszej ścieżki między węzłami w sieci, w której wagi krawędzi reprezentują odległość między węzłami. Jest to bardzo ważny problem, którego rozwiązanie pozwala usługom takim jak MapQuest, Mapy Google i Waze znajdować najkrótszą trasę między dwoma miastami. Zapewne wielu czytelników codziennie korzysta z tych rozwiązań! Równoważnym problemem jest znalezienie najkrótszej trasy na dostarczenie energii elektrycznej z elektrowni przez stacje przesyłowe aż do naszych gniazdek. Biorąc pod uwagę, że na dłuższych trasach dochodzi do większych strat energii, inteligentna sieć energetyczna powinna utrzymywać odległości na niskim poziomie, tak aby efektywnie wykorzystywać energię generowaną przez elektrownie.

Inne zastosowania najkrótszych ścieżek

Poza powyższymi zastosowaniami wagi można również interpretować jako coś innego niż odległości. Na przykład podczas korzystania z Map Google bardziej niż przebytą odległością możesz być zainteresowany czasem potrzebnym na dotarcie do jakiegoś punktu. Trasa piesza może być najkrótsza, ale jeśli odległość jest mierzona w dziesiątkach lub setkach kilometrów, informacja o najkrótszej trasie może być zupełnie bezużyteczna! Zamiast tego krawędziom sieci możemy przypisać wagi odpowiadające czasowi podróży między węzłami. Powiązaniem zagadnieniem, wykorzystywanym w rozwiązaniach takich jak Waze, jest wykorzystanie danych o ruchu drogowym w czasie rzeczywistym do zapewnienia lepszego oszacowania czasu potrzebnego na przejazd między dwiema lokalizacjami. Ponownie odległość nie jest tu najważniejszym czynnikiem, bardziej interesuje nas najszybsza trasa (rysunek 9.5).



Rysunek 9.5. Na tej mapie widzimy dwie trasy. Pierwsza ma długość 503 mil, a druga 511 mil

Zwróć uwagę, że na rysunku 9.5 Mapy Google rekomendują dłuższą trasę. Dzieje się tak, ponieważ ich celem jest znalezienie najszybszej trasy, która bywa nieco dłuższa. Istnieje wiele powodów, dla których dłuższą trasę możemy pokonać szybciej: na krótszej trasie może być większy ruch, niższe ograniczenia prędkości lub więcej światła.

Traktowanie wag jako czasów wiąże się z zupełnie nowym obszarem praktycznych zastosowań, w których interesują nas ścieżki o najkrótszym czasie. Załóżmy, że chcesz wysłać wiadomość tekstową ze swojego telefonu na komputer znajomego. W takim przypadku o wiele bardziej niż odległość, jaką musi pokonać sygnał, interesuje Cię opóźnienie w sieci lub czas dostarczenia wiadomości. Znajdowanie najkrótszych ścieżek pozwala inteligentnie sterować ruchem w sieci komputerowej lub w internecie.

Inną opcją jest użycie wag, które reprezentują koszt dodania krawędzi do ścieżki. Załóżmy, że z przejściem przez krawędź wiążą się koszty, takie jak cena paliwa lub wynagrodzenie kierowcy ciężarówki. Może interesować nas znalezienie ścieżki, której koszt jest najmniejszy, nawet jeśli odległość i czas nie są minimalne. Załóżmy, że chcielibyśmy wybudować drogę łączącą dwa miasta, która przebiega przez jakieś węzły pośrednie. Koszty budowy dla każdego odcinka pomiędzy każdą parą węzłów będą różne i zależne nie tylko od odległości między węzłami, ale także od ukształtowania terenu, konieczności przewiezienia materiałów, zatrudnienia pracowników oraz wielu innych kwestii.

Niezależnie od tego, czy szukamy najkrótszych ścieżek w kontekście odległości, czasu, kosztów, czy innych parametrów, wszystkie one sprowadzają się do tego samego problemu — znalezienia minimalnej sumy wag łączących dwa punkty w sieci. Możliwość połączenia tak wielu różnych problemów w jeden abstrakcyjny problem dotyczący sieci pokazuje moc matematyki w uogólnianiu i rozwiązywaniu wielu problemów naraz.

Definicja problemu najkrótszej ścieżki

Jak widzisz, w praktycznych zastosowaniach wagi mogą reprezentować wiele różnych wartości. Warto więc wprowadzić pewną abstrakcję od konkretnych założeń dotyczących tego, co reprezentują wagi, i sformalizować opis problemu znalezienia najkrótszych ścieżek w sieciach.

Niech $N = (V, E, W)$ będzie siecią, w której $V = \{v_1, v_2, \dots, v_n\}$ to zbiór wierzchołków, E to zbiór krawędzi łączących pary wierzchołków, a W to zbiór wag krawędzi. Poszukamy najkrótszej drogi od wierzchołka v_i do wierzchołka v_j . Innymi słowy, chcemy znaleźć zbiór krawędzi łączących v_i z v_j , których suma wag będzie minimalna.

Zauważ, że między daną parą węzłów może istnieć wiele różnych ścieżek lub może nie istnieć żadna. Jeśli ścieżki istnieją, to może też istnieć więcej niż jedna ścieżka z minimalną sumą wag. W związku z tym powinniśmy pamiętać, że jest to problem, w którym rozwiązanie: może nie istnieć, może istnieć unikalne rozwiązanie lub może istnieć wiele rozwiązań.

W większości praktycznych zastosowań istotna jest jedynie możliwość nieistnienia rozwiązania, czyli sytuacja, w której v_i nie jest połączone z v_j żadną ścieżką. Do sprawdzenia, czy v_i jest połączone z v_j , możemy wykorzystać metody z poprzedniego rozdziału.

Sprawdzenie, czy istnieje rozwiązanie

Przypomnijmy, że ścieżkę z v_i do v_j z minimalną liczbą krawędzi możemy znaleźć, potęgując macierz sąsiedztwa, aż do otrzymania dodatniej wartości w i -tym wierszu i j -tej kolumnie macierzy. Oczywiście jeśli v_i nie jest połączone z v_j , to możemy nigdy nie otrzymać takiej wartości. Ponieważ wiemy, ile krawędzi ($|E|$) znajduje się w sieci, możemy sprawdzić, czy istnieje ścieżka pomiędzy interesującymi nas wierzchołkami. Ścieżka nie istnieje, jeżeli macierz A^n zawiera w i -tym wierszu i j -tej kolumnie zera dla wszystkich $n \leq |E|$. Tym samym wiemy też, że nawet gdybyśmy wykorzystali wszystkie krawędzie w sieci, to nie znaleźlibyśmy ścieżki (a więc i najkrótszej ścieżki) między wierzchołkami. W przypadku, gdy wierzchołki są połączone, istnieje jakaś ścieżka, a tym samym również ścieżka o minimalnej długości.

Przed zastosowaniem algorytmu znajdowania najkrótszej ścieżki warto najpierw sprawdzić poprzez potęgowanie macierzy sąsiedztwa, czy jakakolwiek ścieżka istnieje. Stwórzmy więc funkcję, która wykona takie sprawdzenie. Funkcja ta sprawdzi, czy wierzchołki sąsiadują ze sobą. Jeżeli nie, funkcja obliczy kolejne potęgi macierzy sąsiedztwa aż do otrzymania potwierdzenia lub przekroczenia $A^{|E|}$ bez wykrycia ścieżki (wtedy będziemy pewni, że nie istnieje żadna ścieżka z v_i do v_j). W takim przypadku będziemy wiedzieć, że najkrótsza ścieżka nie istnieje, i unikniemy kłopotów związanych z jej poszukiwaniem!

Jeżeli ścieżka istnieje, to nasza funkcja wyświetli jej długość i zwróci True. W przeciwnym razie funkcja zwróci False i wyświetli informację, że nie znaleziono ścieżki:

```
import numpy

# Funkcja zwraca True, jeżeli w macierzy sąsiedztwa istnieje połączenie pomiędzy wierzchołkami i i j
def isConnected(A, i, j):
    # Inicjalizacja macierzy ścieżek i przypisanie do niej macierzy sąsiedztwa
    paths = A

    # Ustalenie liczby wierzchołków w grafie
    numberOfVertices = A.shape[0]

    # Ustalenie liczby krawędzi w grafie
    numberOfEdges = numpy.sum(A)/2

    # Jeżeli vi sąsiaduje z vj, funkcja zwraca True
    if paths[i-1][j-1] > 0:
        print('Wierzchołek', i, 'i wierzchołek', j, 'sąsiadują ze sobą')
        return True


    else:
        # Pętla trwa do momentu znalezienia ścieżki
        for pathLength in range(2, numberOfVertices):
            # Potęgowanie macierzy sąsiedztwa
            paths = numpy.dot(paths, A)

            # Jeżeli element w i-tym wierszu i j-tej kolumnie jest większy od zera, to znaleźliśmy ścieżkę
            if paths[i-1][j-1] > 0:
                print('Pomiędzy wierzchołkami', i, 'i', j, 'istnieje ścieżka
                    ↳ o długości', pathLength)
                return True
```

```
# Brak ścieżek, wierzchołki nie są połączone
if pathLength == numberOfEdges:
    print('Nie istnieje żadna ścieżka z wierzchołka', i, 'do wierzchołka', j)
    return False
```

Ponieważ kod umieściliśmy w funkcji, jego uruchomienie nie da żadnego wyjścia. Aby coś obliczyć, musimy wywołać funkcję z macierzą sąsiedztwa i numerami wierzchołków i oraz j . Zapisanie kodu w postaci funkcji pozwala na jego ponowne wykorzystanie z różnymi danymi wejściowymi i daje nam możliwość sprawdzenia, czy różne wierzchołki są ze sobą połączone.

W ramach testów wykorzystamy powyższy kod do znalezienia długości ścieżek w małym grafie. Dzięki temu będziemy mogli łatwo sprawdzić poprawność otrzymanych wyników za pomocą diagramu sieci. W rozdziale 8. „Przechowywanie i wyodrębnianie cech z grafów, drzew i sieci” analizowaliśmy dwa grafy pokazane na rysunku 9.6.



Rysunek 9.6. Graf G_1 (po lewej) i graf G_2 (po prawej)

Nazwijmy graf z lewej części rysunku G_1 , a graf z prawej G_2 . Równie dobrze grafy te mogłyby być sieciami z ważonymi krawędziami, ale wagi nie mają znaczenia dla określenia, czy dwa wierzchołki są ze sobą połączone:

```
# Macierz sąsiedztwa grafu G1
A1 = numpy.array([[0, 1, 1, 0, 1, 0], [1, 0, 1, 1, 0, 1],
                 [1, 1, 0, 1, 1, 0], [0, 1, 1, 0, 1, 0],
                 [1, 0, 1, 1, 0, 0], [0, 1, 0, 0, 0, 0]])

# Sprawdzenie połączeń pomiędzy niektórymi wierzchołkami
print(isConnected(A1, 1, 4))
print(isConnected(A1, 2, 3))
print(isConnected(A1, 5, 6))
```

W powyższym kodzie zdefiniowaliśmy macierz sąsiedztwa dla grafu G_1 i sprawdziliśmy, czy kilka par wierzchołków jest ze sobą połączonych. Kod wyświetlił następujące wyniki:

```
Pomiędzy wierzchołkami 1 i 4 istnieje ścieżka o długości 2
True
Wierzchołek 2 i wierzchołek 3 sąsiadują ze sobą
True
Pomiędzy wierzchołkami 5 i 6 istnieje ścieżka o długości 3
True
```

Oczywiście wyniki te są zgodne z tym, co widzimy na rysunku 9.6. W grafie istnieje ścieżka z v_1 do v_4 składająca się z dwóch krawędzi, krawędź łącząca v_2 z v_3 oraz trzeylementowa ścieżka z v_5 do v_6 .

W przypadku niektórych wierzchołków z grafu G_2 kod powinien zwrócić False. Sprawdźmy:

```
# Macierz sąsiedztwa grafu G2
A2 = numpy.array([[0, 1, 0, 0, 0, 0], [1, 0, 0, 0, 0, 1],
                  [0, 0, 0, 1, 1, 0], [0, 0, 1, 0, 1, 0],
                  [0, 0, 1, 1, 0, 0], [0, 1, 0, 0, 0, 0]])

print(isConnected(A2, 1, 6))
print(isConnected(A2, 2, 5))
print(isConnected(A2, 1, 4))
```

Powyższy kod wyświetli następujące informacje:

**Pomiędzy wierzchołkami 1 i 6 istnieje ścieżka o długości 2
True**

**Nie istnieje żadna ścieżka z wierzchołka 2 do wierzchołka 5
False**

**Nie istnieje żadna ścieżka z wierzchołka 1 do wierzchołka 4
False**

Ponownie wyniki są zgodne z rysunkiem prezentującym graf G_2 . Wierzchołki v_1 i v_6 są ze sobą połączone, a wierzchołki v_2 i v_5 oraz v_1 i v_4 nie.


Teraz gdy znasz już metodę pozwalającą sprawdzić, czy rozwiązanie istnieje, zajmiemy się znajdowaniem najkrótszej ścieżki w małym problemie.

Zwróć uwagę, że w przypadku dużych sieci sprawdzenie, czy połączenie istnieje, jest dość kosztowne. W takim przypadku warto przejść od razu do szukania najkrótszych ścieżek, chociaż należy zdawać sobie sprawę, że wyszukiwanie nie powiedzie się, jeśli wierzchołki v_i i v_j nie są ze sobą połączone.

Znajdowanie najkrótszych ścieżek metodą siłową

Jak wspomnieliśmy w poprzednim podrozdziale, interesują nas ścieżki od wierzchołka v_i do wierzchołka v_j z minimalną sumą wag krawędzi. Przyjrzyjmy się możliwości znalezienia najkrótszych ścieżek za pomocą algorytmu siłowego.

Rozważ sieć z rysunku 9.7, którą omówiliśmy w rozdziale 8. „Przechowywanie i wyodrębnianie cech z grafów, drzew i sieci”. Niech V będzie zbiorem wierzchołków, E będzie zbiorem krawędzi, a W zbiorem wag.



Rysunek 9.7. Sieć

Przykładowym problemem, który spróbujemy rozwiązać, jest znalezienie najkrótszej ścieżki z v_1 do v_2 . Istnieje wiele ścieżek pomiędzy tymi dwoma wierzchołkami. W tabeli 9.1 wymieniono je wraz z ich długościami.

Tabela 9.1. Wszystkie ścieżki od v_1 do v_2 i ich długości. Nie pokazano ścieżek, które ponownie przechodzą przez ten sam wierzchołek

Ścieżka z v_1 do v_2	Długość ścieżki
v_1-v_2	4
$v_1-v_3-v_2$	$1 + 2 = 3$
$v_1-v_3-v_4-v_2$	$1 + 1 + 1 = 3$
$v_1-v_3-v_5-v_4-v_2$	$1 + 1 + 2 + 1 = 5$
$v_1-v_5-v_3-v_2$	$2 + 1 + 2 = 5$
$v_1-v_5-v_4-v_2$	$2 + 2 + 1 = 5$
$v_1-v_5-v_4-v_3-v_2$	$2 + 2 + 1 + 2 = 7$

Analiza pełnej listy ścieżek z v_1 do v_2 pozwala łatwo zauważyć, że najkrótsze ścieżki to te znajdujące się w wyróżnionych wierszach. Ścieżki te mają długość trzech jednostek i są to $v_1-v_3-v_2$ oraz $v_1-v_3-v_4-v_2$.

Zauważ, że ścieżki te składają się z większej liczby krawędzi niż ścieżka o minimalnej liczbie krawędzi przechodząca bezpośrednio od v_1 do v_2 , która ma długość 4 jednostek. Oczywiście długość ścieżki nie jest koniecznym związana z liczbą krawędzi. Nie powinniśmy oczekiwać, że najkrótsze ścieżki będą zawsze składały się z najmniejszej liczby krawędzi.

W tym przykładzie po prostu wymieniliśmy wszystkie możliwe ścieżki, ale w przypadku dużego grafu może to być niezwykle kosztowne. Załóżmy na przykład, że graf z n wierzchołkami jest kompletny, co oznacza, że pomiędzy każdą parą wierzchołków znajduje się krawędź. Tak

więc wierzchołek v_1 sąsiaduje z $n-1$ krawędziami. Wierzchołek v_2 ma $n-2$ sąsiednich krawędzi plus krawędź od v_1 do v_2 , która została już wcześniej uwzględniona. Wierzchołek v_3 ma $n-3$ sąsiednich krawędzi plus dwie krawędzie łączące go z v_1 i v_2 . Kontynuując ten wzorzec, w końcu znajdujemy tylko 1 nieuwzględnioną krawędź związaną z wierzchołkiem v_{n-1} . W ten sposób możemy obliczyć liczbę krawędzi w grafie. A zatem łączna liczba krawędzi jest równa:

$$1 + 2 + 3 + \dots + n - 1$$

Zgodnie z dowodem indukcyjnym z rozdziału 2. „Logika formalna i dowody matematyczne” suma pierwszych $n-1$ nieujemnych liczb całkowitych jest równa:

$$\frac{(n-1)n}{2}$$

Jeśli graf ma na przykład 100 wierzchołków, to łącznie jest w nim $\binom{100}{2} = 4950$ krawędzi. W takim grafie mogą istnieć miliony różnych ścieżek od jednego wierzchołka do drugiego!

Ile ścieżek będzie więc pomiędzy parą wierzchołków? Załóżmy, że chcemy ustalić liczbę ścieżek z v_1 do v_2 , które przechodzą przez k dodatkowych wierzchołków. Zgodnie z informacjami z rozdziału 4. „Kombinatoryka z użyciem SciPy” mamy $|V|-2$ krawędzie do wyboru. Liczba ścieżek przechodzących przez k wierzchołków będzie więc równa:

$$\binom{|V|-2}{k} = \frac{(|V|-2)!}{k!(|V|-2-k)!}$$

Jest to prawda dla każdego k od 0 do $|V|-2$. Stąd liczba ścieżek przechodzących przez 5 dodatkowych wierzchołków w naszym 100-wierzchołkowym kompletnym grafie jest równa:

$$\binom{100-2}{5} = \binom{98}{5} = \frac{98!}{5!(98-5)!} = 67910864$$

Oczywiście nie ma powodu, dla którego w ścieżce miałyby być tylko pięć dodatkowych wierzchołków. Równie dobrze może ich być 2, 3, 4, ..., 98, co oznacza, że łączna liczba ścieżek to:

$$\binom{98}{0} + \binom{98}{1} + \binom{98}{2} + \dots + \binom{98}{98}$$

Chociaż sposób wyliczenia tej wartości wykracza poza zakres niniejszej książki, wiadomo, że ta suma jest równa:

$$2^{98} \approx 3,17 \cdot 10^{29}$$

Tym samym podejście oparte na metodzie siłowej jest wyraźnie ograniczone! Przetestowanie tak wielu ścieżek zajęłoby całkowicie nierealną ilość czasu. Ponadto ten 100-wierzchołkowy graf jest dość mały, zwłaszcza jeśli weźmie się pod uwagę fakt, że na przykład mapy, takie jak Mapy Google, umieszczają wierzchołek na każdym skrzyżowaniu. Oznacza to, że w samym Nowym Jorku jest ponad 12 000 wierzchołków!

Chociaż ta metoda jest łatwa do zrozumienia, jej praktyczne wykorzystanie jest nie możliwe. Potrzebne nam będzie bardziej strategiczne podejście pozwalające znaleźć najkrótszą ścieżkę w sensownym czasie. Potrzebujemy skutecznego sposobu na znalezienie najkrótszych ścieżek między określonymi wierzchołkami w sieciach lub sieciach skierowanych przy założeniu, że rozwiązanie istnieje. To właśnie robi algorytm Dijkstry. Czas więc się z nim zapoznać!

Algorytm Dijkstry znajdowania najkrótszych ścieżek

W tym podrozdziale omówimy algorytm Dijkstry, który służy do znajdowania najkrótszych ścieżek. Przedstawimy jego działanie w prosty sposób i zastosujemy algorytm ręcznie na małej sieci.

Algorytm Dijkstry jest najpopularniejszym algorytmem znajdowania ścieżek w sieciach. Algorytm został nazwany na cześć holenderskiego informatyka Edsgera W. Dijkstry, który opracował go w 1956 roku. W tamtych czasach informatyka była nową dziedziną i na rynku istniało niewiele czasopism naukowych jej poświęconych. Dlatego autor nie opublikował swoich odkryć aż do 1959 roku.

Aby zrozumieć ideę algorytmu i wyrobić sobie intuicję, zaczniemy od prezentacji jego działania na małej sieci z rysunku 9.7. Zrozumienie sposobu pracy algorytmu jest ważne, ponieważ istnieje wiele jego odmian. Mamy nadzieję, że nauczysz się go dostosowywać do własnych problemów!

Tak jak w poprzednim podrozdziale, interesować nas będą najkrótsze ścieżki z v_1 do v_2 . Ponieważ wykorzystana przez nas sieć była niewielka, takie ścieżki udało się nam znaleźć metodą siłową, są to:

$$v_1 - v_3 - v_2 \text{ i } v_1 - v_3 - v_4 - v_2$$

Każda z nich ma długość 3 jednostek. W praktyce, aby znaleźć najkrótszą ścieżkę z v_1 do v_2 , znaleźlibyśmy najkrótsze ścieżki z v_1 do wszystkich wierzchołków po drodze do v_2 (tak działa typowa implementacja algorytmu Dijkstry).

Algorytm Dijkstry

Zacznijemy od wierzchołka v_1 i przejdziemy przez graf, realizując algorytm Dijkstry. W trakcie przejścia będziemy utrzymywali dwie listy: listę wierzchołków, które odwiedziliśmy, oraz listę wierzchołków, w których jeszcze nie byliśmy. Na początku zbiór odwiedzonych wierzchołków będzie pusty, a wszystkie wierzchołki znajdą się w zbiorze nieodwiedzonych:

- *odwiedzone wierzchołki* = { },
- *nieodwiedzane wierzchołki* = $\{v_1, v_2, v_3, v_4, v_5, v_6\}$.

W naszym problemie punktem wyjścia (źródłem, ang. *source*) będzie wierzchołek v_1 . Algorytm Dijkstry składa się z następujących kroków:

- **Inicjalizacja.** Ustaw odległość od źródła do każdego wierzchołka na nieskończoność. Ustaw odległość źródła do niego samego na 0.
- Odwiedź najbliższy nieodwiedzony sąsiedni wierzchołek, który znajduje się najbliżej od źródła (w przypadku większej liczby wierzchołków o tej samej odległości można wybrać dowolny z nich):
 - a. Jeśli jakiegokolwiek ścieżki przechodzące przez aktualnie przetwarzany wierzchołek są krótsze niż dotychczas znane trasy, zaktualizuj tabele odległości.
 - b. Dla każdej zmienionej odległości zapamiętaj bieżący wierzchołek jako „poprzedni”.
 - c. Dodaj bieżący wierzchołek do listy odwiedzonych wierzchołków.
- Powtarzaj poprzedni punkt, aż odwiedzione zostaną wszystkie wierzchołki.

Algorytm Dijkstry zwróci najkrótsze ścieżki od źródła v_1 do każdego innego wierzchołka grafu. Jest to znacznie więcej, niż oczekiwaliśmy, ale w wielu zagadnieniach i tak interesuje nas coś więcej niż tylko ścieżka pomiędzy określonymi wierzchołkami.

Algorytm Dijkstry jest przykładem **algorytmu zachłannego**, ponieważ w każdym kroku wybiera najkrótszą ścieżkę od źródła. Oczywiście generowanie ścieżki w oparciu o najkrótsze trasy z punktu startowego do kolejnych punktów na trasie nie musi prowadzić do najlepszej ścieżki, ale czasami się to zdarza. Jeśli dopisze nam szczęście, to dzięki niektórym z tych wczesnych wyborów znajdziemy najkrótszą trasę. Jeśli nie, algorytm i tak znajdzie rozwiązanie, ale zanim to zrobi, być może będzie musiał cofnąć się wiele razy. Proces ten nie jest szybki, ale i tak trwa to *znacznie* krócej niż znalezienie trasy metodą siłową. Dzięki temu mamy szansę znaleźć trasę w rzeczywistych problemach wielkoskalowych.


Algorytm Dijkstry zastosowany do małego problemu

Sprawdźmy, czy da się wykonać te kroki dla małej sieci z poprzedniego przykładu! W każdym kroku wyjaśnimy, co się dzieje, narysujemy zaktualizowaną sieć, zaznaczymy bieżący wierzchołek i nowe krawędzie, które mają zostać włączone do najkrótszej ścieżki, zaktualizujemy tabelę najkrótszych odległości i poprzednich wierzchołków oraz zaktualizujemy listy odwiedzonych i nieodwiedzonych wierzchołków.

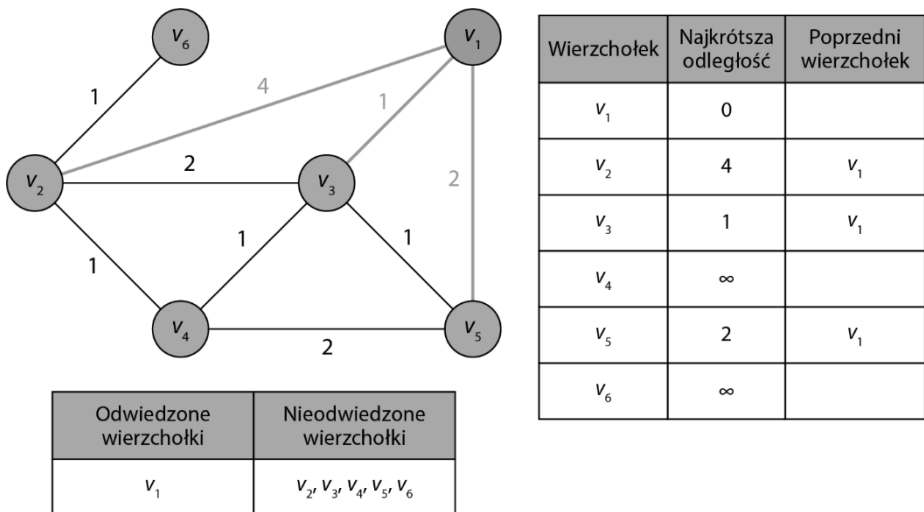
Krok 0 (inicjalizacja). Ustaw najkrótszą odległość do każdego wierzchołka na nieskończoność (∞). Ustaw odległość od źródła do niego samego na 0 (rysunek 9.8).

Krok 1. Dodaj v_1 do zbioru odwiedzonych wierzchołków. Znajdź odległości od źródła do jego wszystkich sąsiadów ze zbioru nieodwiedzonych wierzchołków. Jeśli znaleziona odległość jest krótsza niż aktualnie znana, zapisz ją w tabeli (rysunek 9.9).

Krok 2. Odwiedź jeszcze nieodwiedzony wierzchołek o najkrótszej dotychczas znalezionej odległości od źródła, dodaj go do zbioru odwiedzonych wierzchołków, znajdź odległości od źródła przez ten wierzchołek do każdego nieodwiedzionego jeszcze wierzchołka i zapisz nowe wartości, o ile są one mniejsze niż dotychczasowe (w tym przykładzie będą one wynosić 1 plus długość nowej krawędzi; rysunek 9.10).




Rysunek 9.8. Zerowy krok algorytmu Dijkstry



Rysunek 9.9. Pierwszy krok algorytmu Dijkstry

Krok 3. Odwiedź nieodwiedzony wierzchołek o najkrótszej jak dotąd odległości od źródła (v_4). Dodaj go do zbioru odwiedzonych wierzchołków, znajdź odległości od źródła przez ten wierzchołek do każdego nieodwiedzonego wierzchołka i zapisz wszystkie odległości, które uległy skróceniu.


Tym razem zarówno v_4 , jak i v_5 znajdują się w odległość 2 jednostek od źródła. Arbitralnie wybierzemy więc v_4 (rysunek 9.11).



Odwiedzone wierzchołki	Nieodwiedzone wierzchołki
v_1, v_2, v_3, v_4	v_5, v_6

Wierzchołek	Najkrótsza odległość	Poprzedni wierzchołek
v_1	0	
v_2	$1 + 2 = 3$	v_3
v_3	1	v_1
v_4	$1 + 1 = 2$	v_3
v_5	2	v_1
v_6	∞	

Rysunek 9.10. Drugi krok algorytmu Dijkstry



Odwiedzone wierzchołki	Nieodwiedzone wierzchołki
v_1, v_2, v_3, v_4, v_5	v_6


Wierzchołek	Najkrótsza odległość	Poprzedni wierzchołek
v_1	0	
v_2	3	v_3
v_3	1	v_1
v_4	2	v_3
v_5	2	v_1
v_6	∞	

Rysunek 9.11. Trzeci krok algorytmu Dijkstry

Odległość do v_2 wynosi $2 + 1 = 3$, co nie jest lepszą wartością. Odległość do v_5 wynosi $2 + 2 = 4$, co też nie jest poprawne. W tym kroku nie dokonamy żadnych aktualizacji i po prostu przejdziemy do następnego najkrótszej odległości na liście.

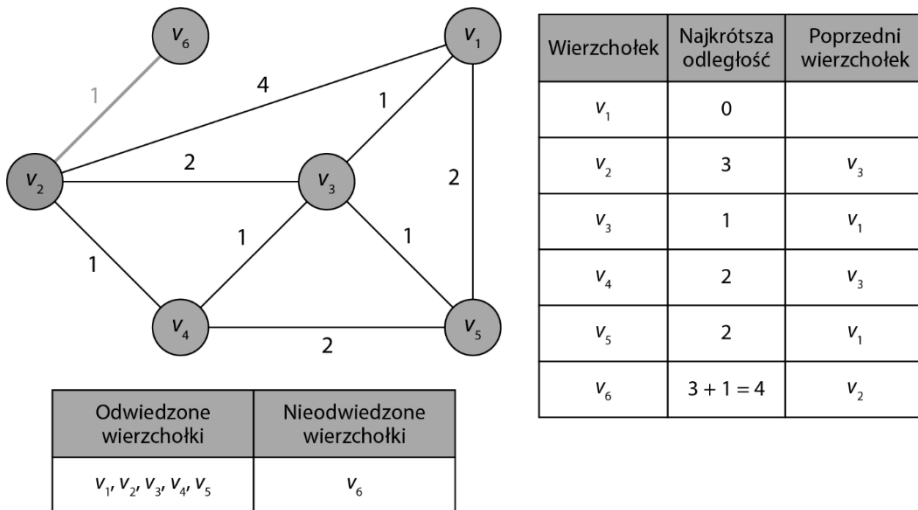
Krok 4. Odwiedź kolejny nieodwiedzony jeszcze wierzchołek o najkrótszej znalezionej do tej pory odległości (v_5), dodaj go do zbioru odwiedzonych wierzchołków, znajdź odległości od źródła przez ten wierzchołek do każdego nieodwiedzonego wierzchołka i zapisz wszystkie odległości, które uległy skróceniu.

Wierzchołek v_5 nie ma już żadnych nieodwiedzonych sąsiadów (rysunek 9.12). Przejdźmy więc do kolejnego kroku.




Rysunek 9.12. Czwarty krok algorytmu Dijkstry

Krok 5. Odwiedź nieodwiedzony wierzchołek o najkrótszej znalezionej jak dotąd odległości od źródła (v_2), dodaj go do zbioru odwiedzonych wierzchołków, znajdź odległości od źródła przez ten wierzchołek do każdego nieodwiedzonego wierzchołka i zapisz wszystkie odległości, które uległy skróceniu (rysunek 9.13).



Rysunek 9.13. Piąty krok algorytmu Dijkstry

Krok 6. Odwiedź nieodwiedzony wierzchołek o najkrótszej znalezionej jak dotąd odległości od źródła (v_6), dodaj go do zbioru odwiedzonych wierzchołków, znajdź odległości od źródła przez ten wierzchołek do każdego nieodwiedzonego wierzchołka i zapisz wszystkie odległości, które uległy skróceniu (rysunek 9.14).



Rysunek 9.14. Szósty krok algorytmu Dijkstry

Zbiór nieodwiedzonych wierzchołków jest teraz pusty, a najkrótsza odległość do v_2 wynosi 3 jednostki. Zgodnie z tabelą z rysunku 9.14 ostatnią krawędzią najkrótszej ścieżki jest krawędź od v_3 do v_2 . Wierzchołkiem poprzedzającym v_3 w najkrótszej ścieżce jest v_1 . Stąd najkrótsza ścieżka od v_1 do v_2 to:

$$v_1 - v_3 - v_2$$

Znaleziona ścieżka i jej długość odpowiadają wartościom, które znaleźliśmy wcześniej metodą siłową. Tym razem jednak zastosowaliśmy bardziej systematyczne podejście. Zapiszmy też dodatkowe wyniki, które daje nam algorytm Dijkstry, czyli najkrótsze ścieżki od v_1 do każdego innego węzła. Podsumowanie wyników znajduje się w tabeli 9.2.

Tabela 9.2. Najkrótsze ścieżki od v_1 do każdego innego wierzchołka znalezionej za pomocą algorytmu Dijkstry


Wierzchołek końcowy	Ścieżka	Odległość
v_2	$v_2 \leftarrow v_3 \leftarrow v_1$	3
v_3	$v_3 \leftarrow v_1$	1
v_4	$v_4 \leftarrow v_3 \leftarrow v_1$	2
v_5	$v_5 \leftarrow v_1$	2
v_6	$v_6 \leftarrow v_2 \leftarrow v_3 \leftarrow v_1$	4

W tym podrozdziale poznałeś algorytm Dijkstry wykorzystywany do znajdowania najkrótszych ścieżek między wierzchołkami w sieci. Pokazaliśmy też, jak można zastosować go ręcznie w przypadku małej sieci. Teraz gdy rozumiesz już, jak działa ten algorytm, spróbujemy zaimplementować go w Pythonie, tak abyś mógł rozwiązywać jeszcze większe problemy!

Implementacja algorytmu Dijkstry w Pythonie

Wiesz już, jak działa algorytm Dijkstry, teraz zajmiemy się jego implementacją w Pythonie.

Dane wejściowe do algorytmu to sieć i wierzchołek źródłowy. Najprostszym sposobem reprezentacji sieci jest użycie macierzy wag, która została wprowadzona w rozdziale 8. „Przechowywanie i wyodrębnianie cech z grafów, drzew i sieci”. Sieć z rysunku 9.7 wraz z odpowiadającą jej macierzą wag pokazano na rysunku 9.15.



Rysunek 9.15. Mała sieć i jej macierz wag

W kontekście problemu najkrótszej trasy macierz wag można nazwać macierzą odległości. My jednak powstrzymamy się od stosowania tego określenia, ponieważ jak miałeś okazję przekonać się w poprzednich podrozdziałach, problemy z najkrótszą ścieżką mogą, ale nie muszą odnosić się do odległości.

Wynikiem działania algorytmu będzie tabela, taka jak ta w prawym górnym rogu rysunku 9.14. Tabela ta będzie zawierała najkrótsze odległości z wierzchołka źródłowego do każdego z pozostałych wierzchołków.

Tabelę 9.2 można wygenerować również bezpośrednio w kodzie algorytmu, ale my zrobimy to poza nim.

Stworzymy funkcję, która przyjmie macierz wag i wierzchołek źródłowy, wykona algorytm Dijkstry i zwróci tabelę. Ponieważ kod będzie dość długi, pokażemy go we fragmentach wraz z ich wyjaśnieniem.

Najpierw zaimportujemy NumPy i stworzymy krótką dokumentację, która podsumuje działanie kodu. Jest to dobra praktyka podczas tworzenia nowej funkcji lub dużej porcji kodu:

```
import numpy

# Implementacja algorytmu Dijkstry znajdująca najkrótsze ścieżki do
# wszystkich innych wierzchołków w grafie
#
# WEJŚCIE
# W — kwadratowa macierz wag
# i — numer wierzchołka startowego
#
# WYJŚCIE
# shortestDistances — tablica najkrótszych odległości od wierzchołka startowego do pozostałych
#
# previousVertices — tablica poprzednich wierzchołków w ścieżce od wierzchołka początkowego
#
```

Teraz zdefiniujemy funkcję o nazwie `Dijkstra`, która przyjmie macierz wag W i wierzchołek startowy v_i . Na początku musimy ustalić liczbę wierzchołków i zainicjować kilka tablic, które będą zawierały dane dotyczące wierzchołków, w tym informację, czy został on odwiedzony.

Ustawimy również odległości do wszystkich wierzchołków na ∞ , odległość wierzchołka źródłowego do niego samego na 0 i oznaczymy wierzchołek źródłowy jako odwiedzony:

```
def Dijkstra(W, i):
    # Ustalenie liczby wierzchołków w grafie
    n = W.shape[0]

    # Inicjalizacja tablicy shortestDistances
    shortestDistances = numpy.array([numpy.inf] * n)

    # Inicjalizacja tablicy previousVertices
    previousVertices = numpy.array([numpy.inf] * n)

    # Inicjalizacja zbioru nieodwiedzonych wierzchołków. Na początku znajdują się w nim wszystkie wierzchołki
    unvisited = numpy.array([1] * n)

    # Oznaczenie wierzchołka startowego jako odwiedzonego
    unvisited[i - 1] = 0

    # Ustawienie odległości pomiędzy wierzchołkiem startowym i nim samym na zero
    shortestDistances[i - 1] = 0
```

Następnie stworzymy pętlę, która będzie przechodzić przez wierzchołki. W pętli znajdziemy najbliższy nieodwiedzony wierzchołek (x) i go odwiedzimy:

```
# Pętla po wierzchołkach. Pętla zakończy się, gdy zbiór nieodwiedzonych wierzchołków będzie pusty
for _ in range(n):
    # Znajdowanie odległości do wszystkich sąsiednich wierzchołków
```

```

# Odległości do pozostałych ustawiane są na zero
distances = shortestDistances * unvisited

# Znajdowanie najbliższego nieodwiedzzonego wierzchołka (distances > 0)
x = numpy.argmin(numpy.ma.masked_where(
    distances == 0, distances))

# Oznaczenie wierzchołka x jako odwiedzony
unvisited[x] = 0

```

W następnym etapie przejdziemy przez wierzchołki kolejną pętlą. Jeśli jakikolwiek sąsiedni i nieodwiedzony jeszcze wierzchołek znajduje się bliżej wierzchołka źródłowego (przy przejściu przez bieżący), zapiszemy jego nową, krótszą odległość od źródła oraz oznaczymy bieżący wierzchołek jako przedostatni w tej najkrótszej ścieżce znalezionej do tej pory przez algorytm:

```

# Przejście przez wierzchołki
for v in range(n):

    oldDistance = shortestDistances[v]
    newDistance = shortestDistances[x] + W[v,x]
    adjacent = W[v,x] > 0
    unvis = unvisited[v]

    # Jeżeli v i x są ze sobą połączone, a wierzchołek v nie został znaleziony, to szukamy
    # najkrótszej trasy do v...
    if adjacent and unvis and oldDistance > newDistance:
        # Zapamiętanie najkrótszej znalezionej do tej pory ścieżki
        shortestDistances[v] = shortestDistances[x] + W[v,x]
        # Zapamiętanie poprzedniego wierzchołka
        previousVertices[v] = x

```

Na koniec wyświetlimy tabelę, taką jak ta w prawym górnym rogu rysunku 9.14. Zwróć uwagę, że do numerów wierzchołków dodajemy 1, aby poradzić sobie z faktem, że Python numeruje wierzchołki od 0 (my numerujemy je od 1). Na wypadek, gdybyśmy chcieli połączyć algorytm z inną funkcją, zwracamy również te same informacje w postaci, w jakiej przechowuje je Python:

```

# Wyświetlenie tabeli podobnej do tej z książki
print(numpy.array([numpy.arange(n) + 1, shortestDistances,
                  previousVertices + 1]).T)

# Zwrócenie wartości
return shortestDistances, previousVertices

```

Po stworzeniu implementacji algorytmu Dijkstry powinniśmy ją przetestować. Nasza implementacja powinna zadziałać nawet w przypadku dużych problemów, ale zawsze powinniśmy przetestować nowy kod (zwłaszcza długi) na problemie ze znanym rozwiązaniem, aby upewnić się co do poprawności jego działania.

Przykład — najkrótsze ścieżki

Weźmy macierz wag małej sieci z rysunku 9.15 i sprawdźmy, czy algorytm zwróci poprawne wyniki pokazane na rysunku 9.14.

Najpierw zapiszemy macierz wag w postaci tablicy NumPy:

```
# Stworzenie macierzy wag dla sieci z rysunku 9.15
W1 = numpy.array([[0, 4, 1, 0, 2, 0],
                  [4, 0, 2, 1, 0, 1],
                  [1, 2, 0, 1, 1, 0],
                  [0, 1, 1, 0, 2, 0],
                  [2, 0, 1, 2, 0, 0],
                  [0, 1, 0, 0, 0, 0]])
```

Następnie wywołamy funkcję Dijkstra z macierzą W1 i wierzchołkiem v_1 :

```
# Uruchomienie algorytmu Dijkstry z punktem startowym w wierzchołku v1
Dijkstra(W1, 1)
```

Kod wyświetli następujący wynik:

```
[[ 1.  0. inf]
 [ 2.  3.  3.]
 [ 3.  1.  1.]
 [ 4.  2.  3.]
 [ 5.  2.  1.]
 [ 6.  4.  2.]]
```

```
(array([0., 3., 1., 2., 2., 4.]), array([inf, 2., 0., 2., 0., 1.]))
```

Tablica wyświetlona jako pierwsza zawiera te same wartości, co znaleziona przez nas ręcznie tablica z rysunku 9.14.

Druga wyświetlona wartość (czyli to, co zwróciła funkcja) zawiera dwie prawe kolumny z tablicy z rysunku 9.14. Wartości te są jednak mniejsze o 1, ponieważ indeksowanie w Pythonie rozpoczyna się od zera.

Wyświetlone dane może i są ciekawe, ale co z właściwymi ścieżkami? Wygodnie byłoby wygenerować same ścieżki, tak jak zrobiliśmy to ręcznie w tabeli 9.2. W przypadku długiej ścieżki cały proces byłby jednak bardzo żmudny, dlatego stworzymy funkcję, która zrobi to za nas!

Najpierw zdefiniujemy nową funkcję i zainicjalizujemy niektóre zmienne i listy:

```
# Funkcja odtwarza najkrótsze ścieżki z source do destination na podstawie previousVertices i je wyświetla
def printShortestPath(shortestDistances, previousVertices, source, destination):
    # Uwzględnienie różnic w indeksowaniu
    source -= 1
    destination -= 1

    # Konwersja previousVertices na int
    previousVertices = previousVertices.astype(int)

    # Inicjalizacja listy elementów ścieżki. Przypisanie do niej wierzchołka docelowego
    path = [destination]
```


Następnie w pętli będziemy dodawać poprzednie wierzchołki z tabeli, aż dotrzemy do źródła:

```
# Dodawanie poprzednich wierzchołków z previousVertices aż do momentu osiągnięcia wierzchołka startowego
for _ in range(previousVertices.shape[0] - 1):
    # Jeżeli wierzchołek startowy znajduje się w ścieżce, pętla jest przerywana
    if path[-1] == source:
        break
    # Jeżeli wierzchołek startowy nie znajduje się w ścieżce, dodawany jest do niej kolejny wierzchołek
    else:
        path.append(previousVertices[path[-1]])
```

Na koniec stworzymy i wypiszemy łańcuch znaków podobny do drugiej kolumny tabeli 9.2:

```
# Inicjalizacja wyjściowego łańcucha znaków
output = []

# Przejście przez ścieżkę od tyłu (od wierzchołka startowego do wierzchołka docelowego)
for i in numpy.flip(path):
    # Stworzenie listy łańcuchów znaków
    if i > 0:
        output.append('->')

    output.append('v' + str(i + 1))

# Wyświetlenie łańcuchów znaków bez spacji
print('Ścieżka =', *output, '\t\t Odległość =',
      shortestDistances[destination])
```

Uruchomimy kod, aby znaleźć najkrótsze ścieżki od v_1 do innych wierzchołków:

```
for i in range(2,7):
    printShortestPath(shortestDistances, previousVertices, 1, i)
```

Po uruchomieniu kod wypisze następujące informacje:


Ścieżka = v1 -> v3 -> v2	Odległość = 3.0
Ścieżka = v1 -> v3	Odległość = 1.0
Ścieżka = v1 -> v3 -> v4	Odległość = 2.0
Ścieżka = v1 -> v5	Odległość = 2.0
Ścieżka = v1 -> v3 -> v2 -> v6	Odległość = 4.0

Jak widzisz, otrzymane wartości są zgodne z tabelą 9.2.

W tym przykładzie wszystko wygląda świetnie. Spójrzmy jednak na trudniejszy — sieć, w której pomiędzy niektórymi parami wierzchołków nie istnieje żadna ścieżka.

Przykład — sieć bez połączenia

Rozważ sieć i macierz wag z rysunku 9.16.



Rysunek 9.16. Sieć bez połączenia

Ten graf składa się z dwóch składowych spójnych, które nie są połączone ze sobą żadnymi krawędziami, a zatem nie istnieje najkrótsza ścieżka między wierzchołkami pochodzącymi z różnych składowych. W związku z tym nasza implementacja algorytmu Dijkstry nie zadziała z taką macierzą wag. Aby znaleźć najkrótsze ścieżki, musimy najpierw dostosować nasze metody.

Zacznijemy od zapisania macierzy wag w postaci tablicy NumPy:

```
# Macierz wag dla sieci z rysunku 9.16
W2 = numpy.array([[0, 4, 0, 0, 0, 0],
                  [4, 0, 0, 0, 0, 1],
                  [0, 0, 0, 1, 4, 0],
                  [0, 0, 1, 0, 2, 0],
                  [0, 0, 4, 2, 0, 0],
                  [0, 1, 0, 0, 0, 0]])
```

Następnie stworzymy małą funkcję, która wykona kilka czynności: (1) za pomocą funkcji `isConnected` znajdzie wszystkie wierzchołki połączone z węzłem źródłowym; (2) uruchomi algorytm Dijkstry, aby znaleźć najkrótsze ścieżki:

```
# Znajdowanie najkrótszych ścieżek pomiędzy połączonymi ze sobą wierzchołkami
def distancesWithinComponent(source):
    # Inicjalizacja listy reprezentującej spójną składową
    component = [source]

    # Tworzenie spójnej składowej
    for i in range(1, W2.shape[0] + 1):
        if i != source and isConnected(W2, source, i):
            component.append(i)

    # Znajdowanie macierzy wag spójnej składowej
    subnetwork = W2[numpy.array(component) - 1, :][:, numpy.array(component) - 1]

    # Uruchomienie algorytmu Dijkstry
    return Dijkstra(subnetwork, 1)
```

Uruchommy algorytm z wierzchołkiem źródłowym v_1 :

```
distancesWithinComponent(1)
```

Kod wyświetli następujący wynik:

```
Wierzchołek 1 i wierzchołek 2 sąsiadują ze sobą
Pomiędzy wierzchołkami 1 i 6 istnieje ścieżka o długości 2
[[ 1.  0. inf]
 [ 2.  4.  1.]
 [ 3.  5.  2.]]
(array([0., 4., 5.]), array([inf, 0., 1.]])
```

Zauważ, że wynikowa tabela jest nieco zmodyfikowana. Pierwsza kolumna powinna zawierać wartości 1, 2 i 6. Jednak stworzyliśmy podsieć i zmieniliśmy numerację wierzchołków na 1, 2 i 3. Wyraźnie widzimy, że najkrótsza ścieżka od v_1 do v_2 przebiega po łączącej je krawędzi o długości 4. Najkrótsza ścieżka od v_1 do v_6 przechodzi zaś przez v_2 i ma długość 5.

Następnie wywołamy funkcję z wierzchołkiem startowym z drugiej składowej (v_3).

```
distancesWithinComponent(3)
```

Kod wyświetli następujący wynik:

```
Wierzchołek 3 i wierzchołek 4 sąsiadują ze sobą
Wierzchołek 3 i wierzchołek 5 sąsiadują ze sobą
[[ 1.  0. inf]
 [ 2.  1.  1.]
 [ 3.  3.  2.]]
(array([0., 1., 3.]), array([inf, 0., 1.]])
```

W tym wywołaniu wierzchołkami są v_3 , v_4 i v_5 . Najkrótsza ścieżka od v_3 do v_4 przechodzi po prostu przez łączącą je krawędź i ma długość 1. Najkrótsza ścieżka od v_3 do v_5 przechodzi przez v_5 i ma długość 3. W przypadku małego grafu wyniki są dość oczywiste, ale dobrze wiedzieć, że możemy wykorzystać napisany przez nas kod do znajdowania ścieżek w grafach niespójnych.

Podsumowanie

W tym rozdziale wykorzystaliśmy struktury grafowe, w tym drzewa i sieci, które poznałeś w rozdziale 8. „Przechowywanie i wyodrębnianie cech z grafów, drzew i sieci”. W rozdziale omówiliśmy kilka praktycznych problemów związanych z grafami i przedstawiliśmy popularne algorytmy ich rozwiązywania.

Zaczęliśmy od zagadnienia przeszukiwania grafów, w którym przechodzimy przez graf, aby odkryć jego strukturę i ewentualnie wykonać pewne obliczenia w każdym wierzchołku. Następnie zaprezentowaliśmy algorytm przeszukiwania w głąb — prawdopodobnie najpopularniejszy algorytm przeszukiwania grafów. Przed pokazaniem implementacji w Pythonie przeanalizowaliśmy jego ręczną implementację na małym grafie. Obie implementacje dały te same wyniki.

Następnie przeszliśmy do bardzo praktycznego problemu, jakim jest znajdowanie najkrótszych ścieżek między wierzchołkami w sieciach. Zagadnienie to odgrywa istotną rolę w znajdowaniu optymalnych tras podróży, trasowaniu wiadomości w sieciach komputerowych, wydajnym dostarczaniu energii elektrycznej w sieciach elektrycznych i w wielu innych obszarach. Ponieważ w niektórych sieciach nie istnieją ścieżki pomiędzy pewnymi wierzchołkami, stworzyliśmy krótką procedurę sprawdzania, czy wierzchołki są ze sobą połączone ścieżką. Następnie wykorzystaliśmy kilka metod z rozdziału 4. „Kombinatoryka z użyciem SciPy”, aby pokazać, że znalezienie ścieżki metodą siłową jest praktycznie niewykonalne.

Ponieważ metoda siłowa nie dała oczekiwanych rezultatów, w kolejnym podrozdziale przedstawiliśmy algorytm Dijkstry do znajdowania najkrótszych tras z wierzchołka źródłowego do innego wierzchołka w sieci. Jest to zachłanny algorytm, który w każdej iteracji podejmuje najbardziej optymalną decyzję. Najpierw zaprezentowaliśmy działanie algorytmu krok po kroku na małym problemie, tak abyś lepiej zrozumiał jego działanie.

W ostatnim podrozdziale zaimplementowaliśmy od podstaw algorytm Dijkstry w Pythonie. Nasza implementacja działa tak samo jak w przykładzie, który rozwiązaliśmy ręcznie. Kod wygenerował dokładnie tę samą optymalną ścieżkę, ale dodatkowo pokazaliśmy, jak poprzez użycie innej macierzy wag i innego węzła źródłowego możemy natychmiast zastosować go do znalezienia ścieżki w innej sieci.

Teraz przejdziemy do trzeciej części książki, która koncentruje się na praktycznych zastosowaniach poznanych zagadnień, w tym na zastosowaniu regresji liniowej w uczeniu maszynowym, wyszukiwaniu w sieci za pomocą algorytmu Google PageRank oraz na analizie głównych składowych, czyli na metodzie redukcji wymiarów, która pozwala nam przechowywać duże zbiory danych za pomocą mniejszej liczby zmiennych.

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 

Matematyka dyskretna — poznaj, zrozum, zastosuj!

Mimo że osiągnięcia matematyczne stały się podwalinami algorytmiki, wielu inżynierów nie w pełni rozumie reguły matematyki dyskretniej. Nawet jeśli nie stanowi to szczególnego problemu w codziennej pracy, w końcu okazuje się, że matematyka dyskretna jest niezbędna do osiągnięcia prawdziwej biegłości w operowaniu algorytmami i w pracy na danych. Co więcej, znajomość tej dziedziny bardzo ułatwia rozwiązywanie problemów z zakresu uczenia maszynowego. W ten sposób praktyczna biegłość w matematyce zauważalnie poprawia wyniki pracy inżynierów.

Ta książka jest kompleksowym wprowadzeniem do matematyki dyskretniej, przydatnym dla każdego, kto chce pogłębić i ugruntować swoje umiejętności informatyczne. W zrozumiały sposób przedstawiono tu metody matematyki dyskretniej i ich zastosowanie w algorytmach i analizie danych, włączając w to techniki uczenia maszynowego. Zaprezentowano również zasady oceny złożoności obliczeniowej algorytmów i używania wyników tej oceny do zarządzania pracą procesora. Omówiono także sposoby przechowywania struktur grafowych, ich przeszukiwania i znajdowania ścieżek między wierzchołkami. Pokazano też, jak wykorzystać przedstawione informacje podczas posługiwania się bibliotekami Pythona, takimi jak scikit-learn i NumPy.

W książce między innymi:

- terminologia i metody matematyki dyskretniej
- zastosowanie metod matematyki dyskretniej w algorytmach i analizie danych
- algebra Boole'a i kombinatoryka w podstawowych strukturach algorytmów
- rozwiązywanie problemów z dziedziny teorii grafów
- zadania związane z uczeniem maszynowym a matematyka dyskretna

Dr Ryan T. White — jest naukowcem specjalizującym się w uczeniu maszynowym i teorii prawdopodobieństwa. Wykłada matematykę w Florida Institute of Technology. Zajmuje się analizą stochastyczną i jej algorytmami, kieruje też projektami z zakresu uczenia maszynowego.

Archana Tikayat Ray — przygotowuje się do obrony doktoratu w Georgia Institute of Technology w Atlancie. Jej prace badawcze koncentrują się na uczeniu maszynowym i przetwarzaniu języka naturalnego (NLP).

Helion 	<i>Sprawdź nasze szkolenia!</i>	KOD KORZYŚCI <i>Sięgnij po więcej!</i> 	
 helion.pl	 SZKOLENIA AKADEMIA IT & BUSINESS	ISBN 978-83-283-8396-8	
 0 801 339900			
 0 601 339900		9 788328 383968	
INFORMATYKA W NAJLEPSZYM WYDANIU		Cena: 69,00 zł	

Packt