

BEN FORTA



WYRAŻENIA
REGULARNE
OD PODSTAW



Tytuł oryginału: Learning Regular Expressions

Tłumaczenie: Marta Danch-Wierzchowska

ISBN: 978-83-283-6058-7

Authorized translation from the English language edition, entitled LEARNING REGULAR EXPRESSIONS, 1st Edition by FORTA, BEN, published by Pearson Education, Inc, publishing as Addison-Wesley Professional, Copyright © 2018 Pearson Education, Inc.

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 Pearson Education, Inc. POLISH language edition published by Helion SA, Copyright © 2020.

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 Helion SA 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 Helion SA nie ponoszą również żadnej odpowiedzialności za ewentualne szkody wynikłe z wykorzystania informacji zawartych w książce.

Helion SA

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)

Drogi Czytelniku!

Jeżeli chcesz ocenić tę książkę, zajrzyj pod adres

<http://helion.pl/user/opinie/wyrepo>

Możesz tam wpisać swoje uwagi, spostrzeżenia, recenzje.

Printed in Poland.

- Kup książkę
- Poleć książkę
- Oceń książkę

- Księgarnia internetowa
- Lubię to! » Nasza społeczność

Spis treści

	O autorze	7
	Wstęp	9
Lekcja 1	Wstęp do wyrażeń regularnych	11
	Zrozumieć potrzebę	11
	Jak wykorzystywane są wyrażenia regularne?	12
	RegEx „znajdź”	13
	RegEx „zamień”	13
	Czym tak naprawdę są wyrażenia regularne?	14
	Użycie wyrażeń regularnych	15
	Przed rozpoczęciem	16
	Podsumowanie	16
Lekcja 2	Dopasowywanie pojedynczych znaków	17
	Dopasowanie dosłowne tekstu	17
	Ile dopasowań?	18
	Problem z wielkością liter	19
	Dopasowanie dowolnego znaku	19
	Dopasowanie znaków specjalnych	23
	Podsumowanie	25
Lekcja 3	Dopasowywanie klasy znaków	27
	Dopasowanie jednego z kilku możliwych znaków	27
	Użycie klasy z przedziałem znaków	30
	Dopasowanie „wszystko oprócz”	34
	Podsumowanie	35

Lekcja 4	Korzystanie z metaznaków	37
	Jeszcze raz o znakach ucieczki	37
	Znajdowanie białych znaków	40
	Znajdowanie klas znaków specjalnych	42
	Znajdowanie cyfr (i niecyfr)	42
	Znajdowanie znaków alfanumerycznych (i niealfanumerycznych)	43
	Znajdowanie białych znaków (i niebiałych znaków)	45
	Wartości w zapisie szesnastkowym i ósemkowym	45
	Znajdowanie znaków z klasy POSIX	46
	Podsumowanie	48
Lekcja 5	Powtórzenia	49
	Ile powtórzeń?	49
	Znalezienie jednego lub kilku znaków	50
	Znalezienie zera lub więcej znaków	52
	Znalezienie jednego lub żadnego znaku	54
	Użycie interwałów	56
	Dokładne dopasowanie interwału	57
	Przedziały wewnątrz interwałów	58
	Przedziały „co najmniej”	59
	Zapobieganie nadmiernemu dopasowaniu	61
	Podsumowanie	63
Lekcja 6	Dopasowywanie położenia	65
	Wykorzystywanie granic	65
	Korzystanie z granic	66
	Definiowanie kotwic	69
	Użycie trybu wieloliniowego	72
	Podsumowanie	74
Lekcja 7	Korzystanie z podwyrażeń	75
	Zrozumieć podwyrażenia	75
	Grupowanie podwyrażeniami	76
	Zagnieżdżanie podwyrażeń	80
	Podsumowanie	83

Lekcja 8	Korzystanie z referencji wstecznych	85
	Zrozumieć referencje wsteczne	85
	Dopasowywanie za pomocą referencji wstecznych	88
	Przeprowadzanie operacji zastępowania	91
	Konwersja wielkości znaków	94
	Podsumowanie	95
Lekcja 9	Przewidywanie w przód i wstecz	97
	Wprowadzenie do grup przewidywania	97
	Przewidywanie w przód	98
	Przewidywanie wstecz	100
	Łączenie przewidywania w przód i wstecz	103
	Negacja grup przewidujących	104
	Podsumowanie	106
Lekcja 10	Zagnieżdżanie warunków	107
	Po co zagnieżdżać warunki?	107
	Używanie warunków	108
	Warunki dla referencji wstecznych	109
	Warunki dla przewidywania	111
	Podsumowanie	113
Lekcja 11	Wyrażenia regularne jako rozwiązanie popularnych problemów	115
	Adresy IP	115
	URL	116
	Pełny URL	118
	Adresy e-mail	119
	Komentarze HTML-a	120
	Komentarze w JavaScriptcie	121
	Numery kart kredytowych	122
	Numery telefonów w Ameryce Północnej	126
	Kody pocztowe w Stanach Zjednoczonych	128
	Kody pocztowe w Kanadzie	129
	Kody pocztowe w Wielkiej Brytanii	130
	Numery ubezpieczenia społecznego w Stanach Zjednoczonych	131
	Podsumowanie	132

Dodatek A	Wyrażenia regularne	
	w popularnych narzędziach i językach133
	grep133
	Java134
	JavaScript135
	Microsoft .NET136
	Microsoft SQL Server T-SQL137
	Microsoft Visual Studio .NET138
	MySQL139
	Oracle PL/SQL140
	Perl140
	PHP141
	Python142

Wstęp do wyrażeń regularnych

W tej lekcji omówiono, czym są wyrażenia regularne i w jaki sposób mogą być użyteczne.

Zrozumieć potrzebę

Wyrażenia regularne (w skrócie nazywane **RegEx** lub **regexami**, od ang. *Regular Expressions*) są narzędziem i jak wszystkie narzędzia są zaprojektowane, by rozwiązywać konkretne problemy. Najlepszą metodą pozwalającą zrozumieć wyrażenia regularne i zasadę ich działania jest zrozumienie rozwiązywanego przezeń problemu.

Oto kilka problemów:

- Należy znaleźć plik zawierający tekst oko (niezależnie od wielkości znaków), ale bez słów zawierających oko w środku słowa (np. oko*l*iczości, woko*o*, wysoko).
- Podczas tworzenia strony internetowej trzeba wyświetlić tekst z bazy danych. Tekst może zawierać linki, które mają być hiperłączami na stworzonej stronie (tak, aby zamiast generować po prostu tekst, stworzyć funkcjonalny HTML `<a href> `).
- Podczas tworzenia aplikacji z formularzem dla użytkownika zawierającym adres e-mail należy zweryfikować, czy adres jest prawidłowo sformatowany (czy składnia jest poprawna).

- Podczas edycji kodu źródłowego należy zamienić wszystkie wystąpienia `size` na `iSize`, ale jedynie słowa `size`, nie `size` jako część innego słowa.
- Należy wyświetlić listę wszystkich plików w komputerze, by znaleźć jedynie te, które zawierają tekst Aplikacja.
- Do aplikacji są importowane dane, które są oddzielone tabulatorem, a aplikacja wspiera format plików CSV (jeden wiersz w linii, wartości oddzielone przecinkami, każdy wpis ujęty w cudzysłów).
- Należy znaleźć specyficzny tekst w pliku, ale jedynie w konkretnym miejscu (np. na początku linii albo na końcu zdania).

Wszystkie powyższe punkty pokazują przykładowe wyzwania programistyczne i wszystkie mogą być rozwiązane w dowolnym języku, który wspiera przetwarzanie warunkowe i operacje na ciągach znaków. Jak bardzo skomplikowane byłoby jednak rozwiązanie? Należałoby przejrzeć kolejno wszystkie słowa albo znaki, przetwarzając jednocześnie wiele zapytań warunkowych, śledzić wiele flag tak, by wiedzieć, co już zostało znalezione, a co nie, sprawdzać białe znaki i znaki specjalne itd. A wszystko to trzeba by zrobić za każdym razem ręcznie.

Albo... można wykorzystać wyrażenia regularne. Każdy z przedstawionych powyżej problemów może być rozwiązany za pomocą stworzonego już wyrażenia — zwięzłego ciągu znaków zawierającego tekst i instrukcje specjalne — które mogłoby wyglądać na przykład tak:

```
\b[0o][Kk][0o]\b
```

Uwaga

Powyższa linia już wkrótce stanie się zrozumiała.

Jak wykorzystywane są wyrażenia regularne?

Gdyby przyjrzeć się wypisanym w poprzedniej sekcji problemom, można zauważyć, że każdy z nich można zaklasyfikować jako jeden z dwóch typów: albo informacja jest szukana (**znajdź**, ang. *search*), albo informacja jest szukana i edytowana (**zamień**, ang. *replace*). W rzeczywistości do tego właśnie wyrażenia regularne są używane: **znajdź** i **zamień**. Każde wyrażenie regularne albo dopasowuje tekst (**znajdź**), albo dopasowuje i zamienia tekst (**zamień**).

RegEx „znajdź”

Wyrażenia regularne są wykorzystywane w wyszukiwaniach (znajdź), gdy tekst, którego szukają, jest wysoce dynamiczny, jak w przypadku opisanego wcześniej poszukiwania tekstu oko. Na początek należy zlokalizować oko, 0K0, 0ko albo 0k0 — to ta łatwa część (wiele narzędzi do wyszukiwania potrafi znaleźć ciągi znaków niezależnie od wielkości). Trudniejsza część to natomiast upewnienie się, że okoli czności, wokoło i wysoko nie pasują. Niektóre, bardziej wyszukane edytory tekstu mają opcję *Dopasuj tylko całe słowa* (ang. *Match Only the Whole Word*), ale wiele edytorów jej nie ma i może nie być możliwe wprowadzenie takiej zmiany w edytowanym dokumencie. Wykorzystując wyrażenia regularne do przeszukiwania, zamiast szukać jedynie tekstu oko rozwiązuje się problem.

Wskazówka

Jak wygląda rozwiązanie powyższego problemu? Już się pojawiło w książce — to przykładowe wyrażenie przedstawione wcześniej:
`\b[0o][Kk][0o]\b.`

Warto zauważyć, że sprawdzanie zgodności (np. *czy adres e-mail podany przez użytkownika spełnia to wyrażenie regularne*) to również operacją „znajdź”. Sprawdzany jest cały ciąg znaków wprowadzony przez użytkownika (podobnie jak poszukiwania podciągów, co jest typowym zastosowaniem operacji „znajdź”).

RegEx „zamień”

Operacje typu „znajdź” wyrażeń regularnych są nieprawdopodobnie skuteczne, bardzo praktyczne i nie aż tak trudne do nauczenia. Wiele przykładów i rozdziałów w tej książce dotyczy właśnie ich. Jednak prawdziwa siła regexów tkwi w operacjach typu „zamień”. Poniżej został omówiony znany już przykład z zamianą linków URL na hiperłącza. Na początek należy znaleźć wszystkie linki w tekście (prawdopodobnie szukając ciągów zaczynających się od `http://` lub `https://`, a kończących się przecinkiem, kropką lub znakiem białym). Następnie trzeba zamienić znaleziony link na dwa powtórzenia znalezionej linku wraz z dołączonymi komendami HTML-a. W ten sposób link:

```
http://www.forta.com/
```

jest zamieniany na:

```
<a href="http://www.forta.com">http://www.forta.com/</a>
```

Może się też zdarzyć, że znaleziony link jest tylko adresem, a nie pełnym ciągiem URL:

```
www.forta.com
```

co również należy zamienić na:

```
<a href="http://www.forta.com">http://www.forta.com/</a>
```

Opcje „znajdź” i „zamień” w większości aplikacji nie obsługują tego typu operacji, ale przy wykorzystaniu wyrażeń regularnych zadanie to staje się nieprawdopodobnie proste.

Czym tak naprawdę są wyrażenia regularne?

Teraz, gdy już wiadomo, do czego używa się wyrażeń regularnych, można wprowadzić definicje. Mówiąc wprost, **wyrażenia regularne** to ciągi znaków, które są wykorzystywane do dopasowania i operowania na tekście. Wyrażenia regularne są tworzone za pomocą języka wyrażeń regularnych, który został opracowany specjalnie po to, by możliwe było wszystko to, o czym zostało tu napisane, i wiele, wiele więcej. Jak każdy inny język, wyrażenia regularne mają specyficzną składnię i instrukcje, których należy się nauczyć, a po to jest ta książka.

Język wyrażeń regularnych nie jest w pełni językiem programowania. Zazwyczaj nie jest to nawet program czy pakiet, który można zainstalować i stosować. Najczęściej wyrażenia regularne są minijęzykami wbudowanymi w inne języki lub produkty. Dobra wiadomość jest taka, że obecnie niemal każdy porządny język lub narzędzie wspiera wyrażenia regularne. Zła wiadomość: język wyrażeń regularnych sam w sobie w niczym nie przypomina żadnego innego języka ani narzędzia, w który jest wbudowany. Język wyrażeń regularnych jest językiem samym w sobie — językiem zdecydowanie nie najbardziej intuicyjnym i czywistym, na jaki można trafić.

Uwaga

Wyrażenia regularne zostały stworzone na potrzeby matematyki w latach 50. ubiegłego wieku. Wiele lat później główne zasady i koncepcje zostały przeniesione i zaadaptowane do świata unixowego Perla w poleceniach takich jak `grep`. Przez długi czas wyrażenia regularne (wykorzystywane w przypadkach podobnych jak te opisane wcześniej) były dostępne wyłącznie dla wąskiego grona społeczności unixowej. Zmieniło się to jednak, a wyrażenia regularne są obecnie wspierane w różnej formie na niemal każdej platformie obliczeniowej.

Oto funkcjonalne wyrażenia regularne (wkrótce nabiorą one sensu):

- Ben
- .
- `www\.\.forta\.\.com`
- `[a-zA-Z0-9_\.]*`
- `<[Hh]1>.*</[Hh]1>`
- `\r\n\r\n`
- `\d{3,3}-\d{3,3}-\d{4,4}`

W tym miejscu należy zauważyć, że składnia to najprostsza część nauki wyrażeń regularnych. Największym wyzwaniem jest opanowanie, w jaki sposób zastosować tę składnię, by przełożyć napotkany problem na rozwiązanie regexowe. Nie wystarczy do tego przeczytać książkę, podobnie bowiem jak w przypadku każdego innego języka, biegłość przychodzi wraz z praktyką.

Użycie wyrażeń regularnych

Jak już wspomniano, nie ma programu do wyrażeń regularnych, nie ma aplikacji ani oprogramowania, które można kupić lub pobrać. Język wyrażeń regularnych jest zaimplementowany w wiele programów, języków, komend i środowisk deweloperskich.

W jaki sposób używa się wyrażeń regularnych i jak ich funkcjonalność różni się w poszczególnych aplikacjach? Niektóre aplikacje mają opcje w menu i okna dialogowe, za pomocą których można używać wyrażeń regularnych, podczas gdy języki programowania najczęściej dostarczają funkcji, klas lub obiektów, które zawierają funkcjonalności regexów.

Co więcej, nie wszystkie implementacje wyrażeń regularnych są jednakowe. Często pojawiają się subtelne (a czasem mniej subtelne) różnice w składni i cechach.

Dodatek A, „ Wyrażenia regularne w popularnych narzędziach i językach”, zawiera przydatne szczegóły i uwagi dotyczące wsparcia wyrażeń regularnych w wielu aplikacjach i językach. Przed przejściem do kolejnej lekcji warto zajrzeć do tego dodatku, by nauczyć się specyfiki odnoszącej się do aplikacji lub języka, w którym chce się wykorzystywać wyrażenia regularne.

Dla łatwiejszego startu można przejrzeć linki do narzędzi internetowych stworzonych do testowania wyrażeń regularnych zamieszczone na stronie poświęconej oryginalnej wersji tej książki:

<http://forta.com/books/0134757068/>

Zamieszczone tam przykładowe narzędzia są najczęściej najprostszą metodą eksperymentowania z wyrażeniami regularnymi¹.

Przed rozpoczęciem

Przed rozpoczęciem pracy należy zwrócić uwagę na kilka ważnych kwestii:

- Podczas stosowania wyrażeń regularnych można zauważyć, że niemal zawsze istnieje kilka możliwych rozwiązań danego problemu. Niektóre są prostsze, inne szybsze, jedne mogą być bardziej kompaktowe, drugie bardziej uniwersalne. Rzadko kiedy rozwiązanie jest po prostu dobre albo złe (oczywiście pod warunkiem, że działa jak należy).
- Jak już zostało powiedziane, istnieją różnice pomiędzy implementacjami regexów. Przykłady i lekcje przedstawione w tej książce zostały dostosowane możliwie najogólniej do najczęściej wykorzystywanych implementacji, a ewentualne różnice zostały również zaznaczone.
- Podobnie jak w każdym języku, tak i w tym przypadku kluczem do sukcesu jest praktyka, praktyka i jeszcze raz praktyka.

Uwaga

Zdecydowanie zalecane jest, aby w trakcie lektury książki testować każdy zawarty w niej przykład.

Podsumowanie

Wyrażenia regularne są jednym z najpotężniejszych narzędzi umożliwiających operowanie na tekście. Język wyrażeń regularnych jest wykorzystywany do tworzenia wyrażeń regularnych (stworzony ciąg znaków jest nazywany **wyrażeniem regularnym**). Wyrażenia regularne są używane w operacjach „znajdź” i „zamień”.

¹ Opisane materiały są w języku angielskim — *przyp. red.*

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

REGEX: ZROZUM I UŻYWAJ DO WOLI!

Wyrażenia regularne (RegEx) służą do dopasowywania ciągów znaków i manipulowania tekstem. Umożliwiają proste rozwiązywanie wielu złożonych problemów programistycznych. Szczególnie często są wykorzystywane przez twórców aplikacji. Nie istnieje jakiś specjalny język do obsługi wyrażen regularnych, jednak znakomita większość języków programowania wspiera ich stosowanie. Wyrażenia regularne uchodzą za niezrozumiałe i trudne w implementacji, a ich składnia bywa określana jako zawiła i nieintuicyjna. Tymczasem największą barierą okazuje się jasne zrozumienie zagadnienia oraz prawidłowe określenie sposobu wykorzystania wyrażen regularnych w praktyce.

Ta książka jest znakomitym podręcznikiem, dzięki któremu zaczniesz szybko i poprawnie stosować wyrażenia regularne w praktyce. W przystępny sposób wyjaśniono tu, czym są RegEx i jakie problemy mogą rozwiązać, a także jak należy (i jak nie należy) się nimi posługiwać. Przedstawiono wyrażenia regularne, które faktycznie należy znać, od prostych porównań tekstu po bardziej złożone tematy, takie jak stosowanie referencji wstecznych, oceny warunkowej i procesów przewidywania. Poszczególne zagadnienia wyłożono w metodyczny i prosty sposób, bogato ilustrując materiał praktycznymi, gotowymi do wykorzystania przykładami zaprezentowanymi w różnych językach programowania.

Dzięki tej książce nauczysz się:

- rozumieć wyrażenia regularne
- stosować tekst i metaznaki do budowania potężnych wzorców
- przeprowadzać złożone operacje typu znajdź-i-zamień
- dodawać wyrafinowane formuły i ciągi tekstowe do aplikacji WWW
- pracować z numerami telefonów, kodami pocztowymi,
- numerami ubezpieczeń i kart kredytowych, adresami IP i e-mail oraz URL

BEN FORTA — pełni funkcję dyrektora ds. inicjatyw edukacyjnych w Adobe Systems. Jest również autorem ponad 40 popularnych książek dotyczących różnych zagadnień technicznych, w tym kilku bestsellerów. Od ponad 30 lat zajmuje się przemysłem komputerowym, rozwojem, marketingiem i szkoleniami.

 Pearson
Addison-Wesley


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

Sprawdź nasze szkolenia!

SZKOLENIA



AKADEMIA IT & BUSINESS

WWW.SZKOLENIA.HELION.PL

KOD KORZYŚCI
Śledź po więcej! ▶



ISBN 978-83-283-6058-7



9 788328 360587

INFORMATYKA W NAJLEPSZYM WYDANIU

Cena: 39,90 zł