

O'REILLY®

Potoki danych

Leksykon kieszonkowy

Przenoszenie i przetwarzanie danych
na potrzeby ich analizy



Helion 

James Densmore

Tytuł oryginału: Data Pipelines Pocket Reference: Moving
and Processing Data for Analytics

Tłumaczenie: Robert Górczyński

ISBN: 978-83-8322-338-4

© 2023 Helion S.A.

Authorized Polish translation of the English edition of *Data Pipelines Pocket Reference*
ISBN 9781492087830 © 2021 James Densmore.

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 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.

Drogi Czytelniku!

Jeżeli chcesz ocenić tę książkę, zajrzyj pod adres

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

Możesz tam wpisać swoje uwagi, spostrzeżenia, recenzję.

Pliki z przykładami omawianymi w książce można znaleźć pod adresem:

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

Helion S.A.

ul. Kościuszki 1c, 44-100 Gliwice

tel. 32 230 98 63

e-mail: helion@helion.pl

WWW: <https://helion.pl> (księgarnia internetowa, katalog książek)

Printed in Poland.

- **Kup książkę**
- **Poleć książkę**
- **Oceń książkę**

- **Księgarnia internetowa**
- **Lubię to! » Nasza społeczność**

Spis treści

Wprowadzenie	9
Rozdział 1. Wprowadzenie do potoków danych	13
Czym jest potok danych?	13
Kto tworzy potok danych?	14
Podstawy pracy z SQL i hurtowniami danych	15
Python i/lub Java	15
Przetwarzanie rozproszone	16
Podstawowa administracja systemem	16
Nastawienie bazujące na celach	16
Dlaczego w ogóle są tworzone potoki danych?	17
Jak jest tworzony potok danych?	18
Rozdział 2. Nowoczesna infrastruktura danych	19
Różnorodność źródeł danych	20
Własność źródła danych	20
Interfejs pobierania danych i ich struktura	21
Wolumen danych	23
Czystość danych i ich weryfikacja	24
Opóźnienie i przepustowość systemu źródłowego	25
Jezioro danych i hurtownia danych w chmurze	26
Narzędzia pobierania danych	27
Przekształcanie danych i narzędzia modelowania	28
Platformy narzędzi koordynacji sposobu pracy	30
Skierowany graf acykliczny	30
Dostosowanie infrastruktury danych do własnych potrzeb	32

Rozdział 3. Najczęściej spotykane wzorce potoków danych33

ETL i ELT	33
Pojawienie się ELT po ETL	35
Podwzorzec EtLT	38
ELT w analizie danych	39
ELT dla naukowca	41
ELT dla produktów danych i uczenia maszynowego	41
Etapy potoku danych dla uczenia maszynowego	42
Wykorzystanie informacji zwrotnych w potoku	44
Więcej zasobów dotyczących potoków danych dla uczenia maszynowego	44

Rozdział 4. Pobieranie danych — wyodrębnianie46

Przygotowanie środowiska Pythona	47
Przygotowanie plikowego magazynu danych w chmurze	49
Wyodrębnianie danych z bazy danych MySQL	52
Pełne i przyrostowe wyodrębnianie danych z tabeli MySQL	54
Binarny dziennik zdarzeń replikacji danych MySQL	64
Wyodrębnianie danych z bazy danych PostgreSQL	74
Pełne i przyrostowe wyodrębnianie danych z tabeli PostgreSQL	76
Replikacja danych za pomocą dziennika zdarzeń WAL	78
Wyodrębnianie danych z bazy danych MongoDB	78
Wyodrębnianie danych z API REST	85
Strumieniowane pobieranie danych za pomocą Kafki i Debezium ...	89

Rozdział 5. Pobieranie danych — wczytywanie92

Konfiguracja hurtowni danych Amazon Redshift jako miejsca docelowego	92
Wczytywanie danych do hurtowni danych Redshift	94
Wczytywanie przyrostowe a pełne	99
Wczytywanie danych wyodrębnionych z dziennika zdarzeń CDC ...	102
Konfiguracja hurtowni danych Snowflake jako miejsca docelowego	103
Wczytywanie danych do hurtowni danych Snowflake	105
Używanie plikowego magazynu danych jako jeziora danych	107
Frameworki typu open source	109
Alternatywy komercyjne	110

Rozdział 6. Przekształcanie danych	113
Przekształcenia pozbawione kontekstu	114
Usunięcie powtarzających się rekordów w tabeli	114
Przetwarzanie adresów URL	119
Kiedy powinno odbywać się przekształcanie	
— podczas pobierania danych czy już po?	123
Podstawy modelowania danych	124
Najważniejsze pojęcia związane z modelowaniem danych	124
Modelowanie w pełni odświeżonych danych	125
Powolna zmiana wymiarów w celu pełnego odświeżenia danych	130
Modelowanie przyrostowo pobieranych danych	132
Modelowanie danych, które są tylko dołączane	137
Modelowanie zmiany przechwytywanych danych	147
Rozdział 7. Narzędzia instrumentacji potoków danych	153
Skierowany graf acykliczny	153
Konfiguracja Apache Airflow i ogólne omówienie	
tego frameworka	154
Instalacja i konfiguracja	155
Baza danych Apache Airflow	156
Serwer WWW i interfejs użytkownika	159
Harmonogram	163
Wykonawca	164
Operatory	165
Tworzenie skierowanego grafu acyklicznego	
za pomocą Apache Airflow	165
Prosty skierowany graf acykliczny	166
Skierowany graf acykliczny potoku danych ELT	170
Dodatkowe zadania potoku danych	175
Komunikaty i powiadomienia	175
Weryfikacja danych	176
Zaawansowane konfiguracje koordynacji	176
Połączone a niepołączone zadania potoku danych	176
Kiedy podzielić skierowany graf acykliczny?	177
Koordynacja wielu grafów za pomocą operatora Sensor	178
Zarządzanie opcje Apache Airflow	181
Inne frameworki koordynacji	182

Rozdział 8. Weryfikacja danych w potoku	184
Weryfikuj wcześniej i często	184
Jakość danych w systemie źródłowym	185
Niebezpieczeństwa związane z pobieraniem danych	186
Umożliwienie analitykowi weryfikacji danych	187
Prosty framework weryfikacji	188
Kod frameworka weryfikacji	188
Struktura testu weryfikacyjnego	192
Wykonywanie testu weryfikacyjnego	194
Używanie frameworka w skierowanym grafie acyklicznym	
Apache Airflow	195
Kiedy zatrzymać wykonywanie potoku, a kiedy tylko wygenerować	
ostrzeżenie i kontynuować potok?	196
Rozbudowa frameworka	198
Przykłady testów weryfikacyjnych	202
Powielone rekordy po operacji pobierania danych	203
Nieoczekiwana zmiana liczby rekordów	
po operacji pobierania danych	204
Fluktuacje wartości wskaźników	207
Komercyjne i niekomercyjne frameworki do weryfikacji danych ...	212
Rozdział 9. Najlepsze praktyki podczas pracy	
z potokiem danych	214
Obsługa zmian w systemach źródłowych	214
Wprowadzenie abstrakcji	214
Obsługa kontraktów danych	215
Ograniczenia schematu podczas odczytu	217
Skalowanie złożoności	219
Standaryzacja pobierania danych	219
Wielokrotne używanie logiki modelu danych	222
Zapewnienie spójności zależności	225
Rozdział 10. Pomiar i monitorowanie wydajności	
działania potoku danych	229
Kluczowe wskaźniki potoku	229
Przygotowanie hurtowni danych	230
Schemat infrastruktury danych	231

Rejestrowanie danych i sprawdzanie wydajności działania operacji pobierania danych	232
Pobieranie z Apache Airflow historii wykonania poszczególnych skierowanych grafów acyklicznych	232
Dodawanie funkcjonalności rejestrowania danych do frameworka weryfikacji danych	236
Przekształcanie danych dotyczących wydajności działania	242
Wskaźnik sukcesu skierowanego grafu acyklicznego	242
Zmiana czasu wykonywania skierowanego grafu acyklicznego na przestrzeni czasu	244
Liczba testów weryfikacyjnych i współczynnik sukcesu	245
Koordinacja wydajności działania potoku	248
Skierowany graf acykliczny dotyczący wydajności działania	249
Przejrzystość wydajności działania	250
Skorowidz	252

Rozdział 3.

Najczęściej spotykane wzorce potoków danych

Nawet dla doświadczonego inżyniera danych projektowanie nowego potoku danych za każdym razem będzie nie lada wyzwaniem. Jak już wyjaśniłem w rozdziale 2., poszczególne źródła danych i infrastruktura wiążą się zarówno z wyzwaniami, jak i możliwościami. Ponadto potoki danych są budowane w różnych celach oraz z uwzględnieniem różnych ograniczeń. Czy dane muszą być przetwarzane niemalże w czasie rzeczywistym? Czy mogą być uaktualniane raz dziennie? Czy będą modelowane do użycia w panelach, czy może jako dane wejściowe dla modeli uczenia maszynowego (ang. *machine learning*, ML)?

Na szczęście w potokach danych istnieją pewne najczęściej spotykane wzorce, które okazały się skuteczne i możliwe do zastosowania w wielu różnych przypadkach. W rozdziale tym zamierzam zdefiniować te wzorce. Natomiast w kolejnych rozdziałach przedstawię implementację utworzonych na ich podstawie potoków danych.

ETL i ELT

Do prawdopodobnie najbardziej znanych wzorców zaliczamy ETL i jego nowoczesny wariant ELT. Oba te wzorce są powszechnie stosowane w hurtowniach danych i rozwiązaniach typu Business Intelligence. W ostatnich latach stanowiły inspirację dla wzorców potoków danych przeznaczonych do celów naukowych oraz w modelach uczenia maszynowego stosowanych w produkcji. Te wzorce są na tyle dobrze znane, że wiele osób używa wymienionych pojęć jako synonimów dla potoków danych zamiast jako wzorców, które mogą być stosowane w wielu potokach danych.

Gdy weźmie się pod uwagę korzenie wzorców ETL i ELT w hurtowniach danych, najłatwiej będzie je opisać w pewnym kontekście. Takie

podjęcie zastosowałem w rozdziale. W jego dalszej części wyjaśnię, jak omawiane wzorce są używane w konkretnych sytuacjach.

Wzorce ETL i ELT to podejścia w zakresie przetwarzania danych, którego celem jest przekazanie danych do hurtowni danych oraz zapewnienie użyteczności tych danych na potrzeby narzędzi analizy i raportowania. Różnica między tymi wzorcami kryje się w kolejności dwóch ostatnich kroków (przetwarzaniu i wczytywaniu danych). Implikacje projektowe między tymi wzorcami są poważne i wyjaśnię je w rozdziale. Zaczęń jednak od omówienia poszczególnych kroków w ETL i ELT.

Wyodrębnianie (ang. *extract*) polega na zebraniu danych z różnych źródeł w celu ich przygotowania do wczytania i przekształcenia. W rozdziale 2. dokładniej omówiłem różnorodność źródeł i metod zbierania danych.

Wczytywanie (ang. *load*) dostarcza dane niezmodyfikowane (w przypadku wzorca ELT) lub w pełni przetworzone (w przypadku wzorca ETL) do ich miejsca docelowego. Ostatecznym wynikiem jest wczytanie danych do hurtowni danych, jeziora danych bądź też do innego miejsca.

Przekształcanie (ang. *transform*) to etap, w którym niezmodyfikowane dane z poszczególnych systemów źródłowych zostają połączone i sformatowane w taki sposób, aby stały się użyteczne podczas analizy, do wykorzystania w narzędziach wizualizacji bądź też w innych celach, do których został utworzony potok danych. Na tym etapie naprawdę wiele się dzieje, niezależnie od wybranego wzorca (ETL lub ELT). Szczegółowe omówienie tego etapu znajdziesz w rozdziale 6.

ROZDZIELENIE ETAPÓW WYODRĘBNIANIA I WCZYTYWANIA

Połączenie etapów wyodrębniania i wczytywania jest często określane mianem **pobierania danych**. Szczególnie we wzorcu ELT i w jego podwzorcu EtLT (zwróć uwagę na małą literę *t*), zdefiniowanym w dalszej części rozdziału, wyodrębnianie i wczytywanie są często ściśle ze sobą powiązane i zdefiniowane razem we frameworkach oprogramowania. Jednak podczas projektowania potoków danych najlepiej będzie uznawać je za dwa zupełnie oddzielne etapy, ze względu na złożoność operacji wyodrębniania i wczytywania w różnych systemach i infrastrukturze.

W rozdziałach 4. i 5. znajdziesz znacznie dokładniejsze omówienie technik pobierania danych, a także przykłady ich implementacji za pomocą najczęściej używanych frameworków.

Pojawienie się ELT po ETL

Przez dekady ETL był złotym standardem wzorców potoków danych. Wprawdzie nadal jest stosowany, ale ostatnio pojawił się jego nowy wariant, ELT. Dlaczego? Zanim powstały nowoczesne hurtownie danych, głównie w chmurze (zob. rozdział 2.), zespoły pracujące z danymi nie miały dostępu do magazynów danych o pojemnościach i możliwościach niezbędnych do obsługi ogromnej ilości danych niezmodyfikowanych i ich przekształcania na użyteczne modele danych. Ponadto ówczesne hurtownie danych miały zwykle postać opartych na rekordach baz danych, które świetnie sprawdzały się w rozwiązaniach wymagających obsługi transakcji, ale nie w przypadku charakteryzujących się ogromnym wolumenem danych zapytań będących codziennością w trakcie analizy danych. Dlatego też dane były najpierw wyodrębniane z systemów źródłowych, a następnie przekształcane w innych systemach, zanim wreszcie były wczytywane do hurtowni danych w celu ostatecznego modelowania danych i ich używania przez analityków oraz w narzędziach wizualizacji.

Większość obecnych hurtowni danych jest tworzona w postaci wysoce skalowalnych, kolumnowych baz danych, które mogą zarówno przechowywać, jak i przekształcać ogromne zbiory danych w niezwykle efektywny sposób. To się zmieniło dzięki efektywnym systemom wejścia-wyjścia kolumnowych baz danych, kompresji danych oraz możliwości rozpraszania danych i zapytań między wieloma węzłami współpracującymi ze sobą podczas przetwarzania danych. Teraz lepiej jest skoncentrować się na wyodrębnianiu danych i ich wczytywaniu do hurtowni danych, w której następnie można przeprowadzić niezbędne przekształcenia i tym samym zakończyć działanie potoku danych.

Nie wolno pominąć wpływu różnicy między hurtowniami danych bazującymi na rekordach i kolumnach. Na rysunku 3.1 pokazałem sposób przechowywania rekordów na dysku w opartej na rekordach bazie

danych, takiej jak MySQL lub PostgreSQL. Każdy rekord bazy danych jest przechowywany na dysku w jednym bloku lub w ich większej liczbie, w zależności od wielkości rekordu. Jeżeli rekord jest mniejszy niż blok bądź wielkość rekordu nie dzieli się równo przez wielkość bloku, wówczas pewna ilość miejsca na dysku pozostaje niewykorzystana.

OrderId	CustomerId	ShippingCountry	OrderTotal
1	1258	US	55,25
2	5698	AUS	125,36
3	2265	US	776,95
4	8954	CA	32,16
Blok 1	1, 1258, US, 55,25		
Blok 2	2, 5698, AUS, 125,36		
Blok 3	3, 2265, US, 776,95		
Blok 4	4, 8954, CA, 32,16		

Rysunek 3.1. Tabela przechowywana w bazie danych, której działanie opiera się na rekordach. Każdy blok zawiera rekord pochodzący z tabeli

Rozważ przykład użycia bazy danych w rozwiązaniu typu OLTP (ang. *online transaction processing*), np. w aplikacji internetowej typu e-commerce, która do przechowywania informacji wykorzystuje bazę danych MySQL. Generowane przez tę aplikację internetową zapytania odczytu i zapisu są wykonywane do bazy danych MySQL i bardzo często obejmują wiele wartości dla danego rekordu, np. szczegóły dotyczące zamówienia wyświetlane na stronie zawierającej podsumowanie zamówienia. W danej chwili możliwe jest uaktualnianie lub pobieranie informacji tylko o jednym zamówieniu. Bazujący na rekordzie magazyn danych jest optymalny, ponieważ na dysku dane aplikacji muszą być przechowywane blisko siebie, a ilość jednocześnie pobieranych danych jest niewielka.

W omawianym przykładzie nieefektywny sposób użycia dysku ze względu na pozostawianie przez rekordy pustego miejsca w blokach wydaje się rozsądnym kompromisem, ponieważ znaczenie ma szybkość częstego odczytywania i zapisywania pojedynczych rekordów. Jednak podczas analizy danych sytuacja jest zgoła odmienna. Zamiast konieczności

częstego zapisywania i odczytywania niewielkich ilości danych mamy do czynienia z rzadkim zapisywaniem i odczytywaniem dużych ilości danych. Ponadto istnieje znacznie mniejsze prawdopodobieństwo, że wykonywane w trakcie analizy danych zapytanie będzie wymagało wielu bądź wszystkich kolumn tabeli, a raczej pojedynczej kolumny tabeli zawierającej ich wiele.

Na przykład rozważ tabelę zamówień w naszej fikcyjnej aplikacji typu e-commerce. Zawiera ona wiele informacji, m.in. wartość zamówienia i adres, pod który ma być ono wysłane. W przeciwieństwie do aplikacji internetowej działającej z pojedynczymi zamówieniami analityk używający hurtowni danych będzie chciał analizować zamówienia w większych partiach. Ponadto tabela zawierająca dane zamówień w hurtowni danych ma kolumny dodatkowe, których wartości pochodzą z wielu tabel w bazie danych MySQL. Na przykład to mogą być informacje o kliencie składającym dane zamówienie. Być może analityk będzie chciał zsumować wszystkie zamówienia złożone przez klientów aktualnie posiadających aktywne konta. Wprawdzie takie zapytanie może obejmować miliony rekordów, ale dane będą odczytywane np. tylko z dwóch kolumn, takich jak `OrderTotal` (wartość całkowita zamówienia) i `CustomerActive` (klient z aktywnym kontem). Ostatecznie analiza nie dotyczy tworzenia lub zmiany danych (jak ma to miejsce w OLTP), ale raczej pochodzenia wskaźników i zrozumienia danych.

Jak pokazałem na rysunku 3.2, kolumnowa baza danych, taka jak Snowflake lub Amazon Redshift, przechowuje dane w blokach na dysku na podstawie kolumn, a nie rekordów. W omawianym przykładzie zapytanie wykonywane przez analityka musi jedynie uzyskać dostęp do bloków przechowujących wartości `OrderTotal` i `CustomerActive`, a nie bloków przechowujących całe rekordy, jak ma to miejsce w przypadku bazy danych MySQL. To oznacza mniejsze obciążenie dyskowymi operacjami wejścia-wyjścia i mniejszą ilość danych koniecznych do wczytania, aby przeprowadzić filtrowanie i sumowanie wymagane przez zapytanie analityczne. Kolejną korzyścią jest zmniejszenie poziomu użycia pamięci masowej dzięki możliwości pełnego wykorzystania bloków i zastosowaniu optymalnej kompresji, ponieważ dany blok przechowuje ten sam typ danych, a nie wiele typów jak to zwykle ma miejsce w przypadku danych przechowywanych w rekordach.

OrderId	CustomerId	Shipping Country	Order Total	Customer Active
1	1258	US	55,25	TRUE
2	5698	AUS	125,36	TRUE
3	2265	US	776,95	TRUE
4	8954	CA	32,16	FALSE
Blok 1	1, 2, 3, 4			
Blok 2	1258, 5698, 2265, 8954			
Blok 3	US, AUS, US, CA			
Blok 4	55,25, 125,36, 776,95, 32,16			
Blok 5	TRUE, TRUE, TRUE, FALSE			

Rysunek 3.2. Przykład tabeli przechowywanej w kolumnowej bazie danych. Każdy blok dysku przechowuje dane pochodzące z tej samej kolumny. Dwie kolumny używane w naszym przykładzie zostały zaznaczone kolorem szarym. W celu wykonania zapytania konieczne jest uzyskanie dostępu jedynie do tych bloków. Każdy blok zawiera dane tego samego typu, co pozwala na optymalne zastosowanie kompresji

Pojawienie się kolumnowych baz danych spowodowało, że przechowywanie, przekształcanie i wykonywanie zapytań do ogromnych zbiorów danych w hurtowni danych stało się efektywne. Inżynierowie danych mogą tę zaletę wykorzystać podczas opracowywania etapów potoków danych specjalizujących się w wyodrębnianiu danych i ich wczytywaniu w hurtowniach danych. Następnie te dane mogą być przekształcane, modelowane i używane przez analityków lub naukowców, którzy lepiej czują się w ramach baz danych. W efekcie ELT stał się idealnym wzorcem dla potoków hurtowni danych, a także w innych zastosowaniach, np. w uczeniu maszynowym lub w tworzeniu produktów.

Podwzorzec EtLT

Gdy ELT został dominującym wzorcem, stało się jasne, że przeprowadzenie pewnych przekształceń już po wyodrębnieniu danych, ale jeszcze przed ich wczytaniem, przynosi określone korzyści. Jednak zamiast przekształcenia wykorzystującego logikę biznesową lub modelowanie danych ten rodzaj przekształcania jest bardziej ograniczony. Oznaczam go *małą literą t* — *EtLT*.

Oto wybrane przykłady typów przekształceń wpisujących się w podwzorzec EtLT:

- usuwanie powielonych rekordów w tabeli,
- przetwarzanie parametrów URL na postać poszczególnych komponentów,
- maskowanie bądź w inny sposób zabezpieczanie danych wrażliwych.

Tego rodzaju przekształcenia są w pełni oddzielone od logiki biznesowej bądź, w przypadku zadań takich jak maskowanie danych wrażliwych, są umieszczone jak najwcześniej w potoku ze względów czasowych, prawnych bądź z uwagi na zapewnienie bezpieczeństwa. Poza tym rozsądne jest używanie właściwego narzędzia do wykonania danej pracy. Jak wyjaśnię w rozdziałach 4. i 5., większość nowoczesnych hurtowni danych wczytuje dane w najbardziej efektywny sposób, gdy są one doskonale przygotowane. W przypadku potoków przekazujących ogromne ilości danych lub w sytuacjach, w których opóźnienie ma znaczenie kluczowe, przeprowadzenie pewnych prostych przekształceń między etapami wyodrębniania i wczytywania jest warte włożonego wysiłku.

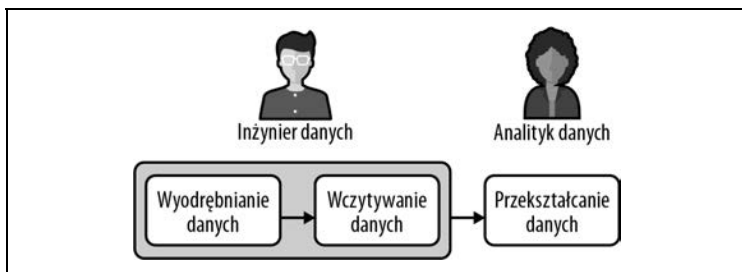
Możesz przyjąć założenie, że pozostałe wzorce dotyczące ELT zostały opracowane również z uwzględnieniem podwzorca EtLT.

ELT w analizie danych

ELT stał się najczęściej stosowanym i w mojej opinii jest najbardziej optymalnym wzorcem dla potoków danych przygotowanych na potrzeby analizy danych. Jak wcześniej wspomniałem, kolumnowe bazy danych świetnie sprawdzają się podczas obsługi ogromnych ilości danych. Zostały opracowane również do obsługi szerokich tabel, czyli tabel zawierających wiele kolumn — dzięki temu, że tylko dane użyte w wykonywanym zapytaniu są skanowane na dysku i wczytywane do pamięci.

Pomijając kwestie techniczne — analiza danych zwykle odbywa się płynnie w SQL. Dzięki ELT inżynierowie danych mogą skoncentrować się na krokach wyodrębniania i wczytywania w potoku (pobieranie danych), podczas gdy analitycy mogą wykorzystać SQL do przekształcenia danych,

które zostały pobrane jako niezbędne na potrzeby raportowania i analizy. Taka separacja jest niemożliwa w przypadku wzorca ETL, ponieważ inżynierowie danych będą potrzebni na każdym etapie działania potoku danych. Jak pokazałem na rysunku 3.3, ELT pozwala zespołom zajmującym się danymi skoncentrować się na swoich umiejętnościach, a mniej na zależnościach i koordynacji.



Rysunek 3.3. Wzorec ELT umożliwia podział odpowiedzialności między inżynierami danych i analitykami (bądź naukowcami). Każdy z nich może działać niezależnie, korzystając z narzędzi i języków, w pracy z którymi czuje się komfortowo

Ponadto wzorec ELT zmniejsza potrzebę dokładnego przewidywania, co analityk będzie robił z danymi w trakcie procesów wyodrębniania i wczytywania. Wprawdzie ogólne zrozumienie sposobu pracy jest niezbędne w celu wyodrębnienia i wczytania poprawnych danych, ale przesunięcie na później kroku przetwarzania zapewnia analitykowi więcej możliwości i dużą elastyczność.

Uwaga

Wraz z pojawieniem się ELT analitycy danych stali się bardziej niezależni i zdolni do lepszego wykorzystania danych, a przy tym nie są „blokowani” przez inżynierów danych. Z kolei inżynierowie danych mogą skoncentrować się na pobieraniu danych i dostarczaniu infrastruktury pozwalającej analitykom na samodzielne tworzenie i wdrażanie utworzonego w SQL kodu przeznaczonego do przekształcania danych. To spowodowało pojawienie się nowych stanowisk, takich jak **inżynier analityk**. W rozdziale 6. dowiesz się więcej o tym, jak ci analitycy danych i inżynierowie danych przekształcają dane w celu tworzenia modeli danych.

ELT dla naukowca

Potoki danych tworzone dla zespołów naukowców są podobne do tych opracowywanych na potrzeby analizy danych w hurtowniach danych. Podobnie jak w przypadku zespołu analityków, tak samo w przypadku zespołu naukowców inżynierowie danych koncentrują się na pobieraniu danych, które następnie trafiają do hurtowni danych bądź jeziora danych. Jednak naukowcy mają wobec danych inne wymagania niż analitycy.

Wprawdzie nauka jest ogólnie dość obszerną dziedziną, ale naukowcy potrzebują dostępu do znacznie dokładniejszych — i czasami niezmo-dyfikowanych — danych niż wymagane przez analityków. Podczas gdy analitycy danych tworzą modele danych przeznaczone do generowania wskaźników i paneli, naukowcy poświęcają czas na poznawanie danych i opracowywanie modeli prognostycznych. Omówienie szczegółowo zadań naukowca wykracza poza zakres tematyczny książki, ale trzeba wiedzieć, że te różnice na wysokim poziomie mają wpływ na projektowanie potoków danych przeznaczonych dla naukowców.

Jeżeli tworzysz potoki danych przeznaczone do używania przez naukowców, przekonasz się, że etapy wyodrębniania i wczytywania we wzorcu ELT pozostaną praktycznie takie same jak w przypadku rozwiązań tworzonych dla analityków. W rozdziale 4. i 5. znacznie dokładniej omówię te kroki pod względem technicznym. Na etapie przekształcania danych w potoku ELT naukowcy mogą mieć pożytek podczas pracy z niektórymi modelami danych opracowanymi dla analityków (zob. rozdział 6.), ale prawdopodobnie będą używać większości danych otrzymanych na etapach wyodrębniania i wczytywania.

ELT dla produktów danych i uczenia maszynowego

Dane są używane nie tylko podczas analizy, raportowania i tworzenia modeli prognostycznych. Znajdują zastosowanie również w **produktach danych**. Do najczęściej stosowanych produktów danych zaliczamy np.:

- silniki rekomendacji stosowane np. w rozwiązaniach strumieniowania wideo,
- spersonalizowane wyniki wyszukiwania w witrynie internetowej typu e-commerce,

- aplikację przeprowadzającą analizę utworzonych przez użytkowników recenzji restauracji.

Każdy z tych produktów danych prawdopodobnie jest wspierany przez jeden lub więcej modeli uczenia maszynowego, które wymagają danych na etapach trenowania i weryfikacji. Takie dane mogą pochodzić z wielu systemów źródłowych i wymagać przekształceń w celu ich przygotowania do użycia w modelu. Wzorzec typu ELT jest doskonale przygotowany do takich potrzeb, choć pojawia się pewna liczba określonych wyzwań na wszystkich etapach działania potoków danych przeznaczonych do obsługi produktów danych.

Etapy potoku danych dla uczenia maszynowego

Podobnie jak w przypadku potoków danych opracowanych dla analizy, na których to skoncentrowałem się w książce, potoki danych przeznaczone dla uczenia maszynowego są opracowywane z zastosowaniem wzorca podobnego do ELT — przynajmniej na początku potoku. Różnica polega na tym, że zamiast etapu przekształcania koncentrującego się na przekształcaniu danych trafiających do modelu danych, gdy dane zostaną wyodrębnione i wczytane do hurtowni danych bądź jeziora danych, mamy wiele kroków zaangażowanych w tworzenie i uaktualnianie modelu ML.

Jeżeli masz doświadczenie w pracy z tworzeniem modeli uczenia maszynowego, wymienione tutaj kroki będą Ci doskonale znane.

Pobieranie danych

W tym kroku jest stosowany dokładnie ten sam proces, który został omówiony w rozdziałach 4. i 5. Wprawdzie pobierane dane mogą się różnić, ale stosowana podczas tej operacji logika pozostaje praktycznie taka sama w potokach danych przeznaczonych dla analizy danych i ML, przy czym w przypadku tych drugich mamy jeszcze kwestie dodatkowe do uwzględnienia — na przykład zagwarantowanie, że pobierane dane są wersjonowane w sposób, dzięki któremu modele uczenia maszynowego mogą później odwoływać się do określonych zbiorów danych podczas trenowania lub weryfikacji. Istnieje wiele narzędzi i podejść stosowanych do wersjonowania

zbiorów danych. Sugeruję zapoznać się z punktem „Więcej zasobów dotyczących potoków danych dla uczenia maszynowego” w dalszej części rozdziału.

Wstępne przetwarzanie danych

Pobierane dane prawdopodobnie nie będą gotowe do użycia w modelach uczenia maszynowego. Na etapie wstępnego przetwarzania danych są one oczyszczane i przygotowywane do wykorzystania w tych modelach. Na przykład to jest w potoku danych etap, w trakcie którego tekst jest tokenizowany, cechy są konwertowane na wartości liczbowe, zaś wartości danych wejściowych są normalizowane.

Trenowanie modelu

Po pobraniu nowych danych i ich wstępnym przetworzeniu konieczne jest ponowne wytrenowanie modeli uczenia maszynowego.

Wdrażanie modelu

Wdrożenie modeli w produkcji może być największym wyzwaniem podczas przejścia z uczenia maszynowego wykorzystywanego podczas badań do rzeczywistego produktu bazującego na danych. Tutaj niezbędne są nie tylko wersjonowane zbiory danych, ale również wytrenowane modele. Bardzo często API REST używa się podczas wykonywania zapytań do wdrożonego modelu, a punkty końcowe API — dla różnych wersji modelu. To całkiem sporo do śledzenia i wymaga koordynacji między naukowcami, inżynierami uczenia maszynowego oraz inżynierami danych, aby otrzymać produkt możliwy do użycia w produkcji. Doskonale opracowany potok danych ma kluczowe znaczenie w spojeniu całości.

WERYFIKACJA POBRANYCH DANYCH

Jak wyjaśnię w rozdziale 8., weryfikacja danych w potoku ma kluczowe znaczenie i powinna być przeprowadzana. W potokach utworzonych na potrzeby analizy danych weryfikacja często odbywa się po pobraniu danych (etapy wyodrębnienia i wczytywania), a także po modelowaniu danych (przekształcanie). W potokach uczenia maszynowego weryfikacja pobranych danych jest również ważna. Nie należy tego istotnego kroku mylić z weryfikacją modelu uczenia maszynowego, który oczywiście jest standardową częścią tworzenia rozwiązań z zakresu uczenia maszynowego.

Wykorzystanie informacji zwrotnych w potoku

Każdy dobry potok dla uczenia maszynowego będzie umożliwiał zbieranie opinii pozwalających na usprawnienie modelu. Rozważmy np. zawartość modelu rekomendacji dla usługi strumieniowania wideo. Aby w przyszłości można było zmierzyć i poprawić model, konieczne jest śledzenie tego, co jest rekomendowane użytkownikom, jakie rekomendacje zostały przez nich kliknięte, które rekomendacje okazały się trafione itd. To wymaga współpracy z zespołem programistów wykorzystującym model w usłudze strumieniowania. Programiści muszą zaimplementować pewnego rodzaju zbieranie zdarzeń w celu śledzenia rekomendacji przekazanych poszczególnym użytkownikom, wersji modelu użytego do rekomendacji, informacji o tym, kiedy rekomendacja została kliknięta. Następnie powinno odbyć się przejście do prawdopodobnie już zebranych danych dotyczących używania określonych treści przez użytkownika.

Wszystkie te informacje mogą być pobrane z powrotem do hurtowni danych oraz wykorzystane w przyszłych wersjach modelu albo jako dane używane do trenowania modeli, albo na potrzeby analizy przeprowadzanej przez człowieka (prawdopodobnie naukowca) w celu wykorzystania w przyszłych modelach bądź eksperymentach.

Ponadto zebrane dane mogą być pobrane, przekształcone i przeanalizowane przez analityków z wykorzystaniem wzorca ELT omówionego w książce. Analitycy często będą sprawdzali efektywność modeli i tworzyli panele w celu dostarczenia organizacji informacji o kluczowych wskaźnikach modelu. Interesariusze mogą korzystać z tych paneli do poznawania efektywności poszczególnych modeli podczas podejmowania decyzji biznesowych oraz dotyczących klientów.

Więcej zasobów dotyczących potoków danych dla uczenia maszynowego

Tworzenie potoków danych przeznaczonych na potrzeby uczenia maszynowego jest rozbudowanym tematem. W zależności od podjętych decyzji w zakresie infrastruktury i stopnia złożoności środowiska uczenia maszynowego warto sięgnąć po inne książki, które gorąco polecam:

Hannes Hapke i Catherine Nelson, *Building Machine Learning Pipelines*, O'Reilly, 2020.

Aurélien Géron *Uczenie maszynowe z użyciem Scikit-Learn i TensorFlow. Wydanie II*, Helion, Gliwice 2020.

Ponadto wymieniona tutaj pozycja jest świetnym wprowadzeniem do tematu uczenia maszynowego:

Andreas C. Müller i Sarah Guido, *Introduction to Machine Learning with Python*, O'Reilly, 2016.

A

- administracja systemem, 16
- adres URL, 119, 123
- Amazon Redshift
 - konfiguracja hurtowni danych, 92
- Apache Airflow, 154
 - API REST, 233
 - baza danych, 156
 - harmonogram, 163
 - instalacja, 155
 - interfejs użytkownika, 159
 - konfiguracja, 155
 - operatory, 165
 - serwer WWW, 159
 - tworzenie skierowanego grafu acyklicznego, 165
 - widok Graph View, 162, 169
 - wykonawca, 164
 - zarządzane opcje, 181
- Apache Kafka, 90
- Apache Kafka Connect, 90
- Apache Zookeeper, 90
- API REST
 - wyodrębnianie danych, 85
- AWS, 49
 - edytor zapytań, 95
 - polecenie COPY, 95, 97

B

- baza danych
 - Apache Airflow, 156
 - MongoDB, 78
 - MySQL, 52
 - PostgreSQL, 74
- binarny dziennik zdarzeń, 64
- błędy
 - logiczne, 186
 - związane z przetwarzaniem danych, 187

C

- CDC, change data capture, 65
- chmura, 26
 - AWS, 49
- CTE, common table expressions, 135
- czystość danych, 24

D

- dane niemodyfikowalne, 55
- Debezium, 90
- dostosowanie infrastruktury danych, 32
- dziennik zdarzeń
 - CDC, 102
 - replikacji danych, 64, 78
 - WAL, 75

E

- edytor zapytań Redshift, 95
- ELT, extract, load, transform, 33–35
 - dla naukowca, 41
 - dla produktów danych, 41
 - dla uczenia maszynowego, 41
 - pobieranie danych, 46
 - w analizie danych, 39
- EtLT, 38

F

- format JSON, 86
- framework
 - Apache Airflow, 154
 - dbt, 226
- frameworki
 - do weryfikacji danych, 188, 195, 198, 212
 - koordynacji, 182
 - rejestrowanie danych, 236
 - typu open source, 109
- funkcja
 - .dump(), 72
 - .execute(), 62
 - .find(), 82

- doc.get(), 84
- parse_qs(), 120
- PARSE_URL(), 122
- psycpg2.connect(), 97
- urlsplit(), 120

G

- generowanie ostrzeżenia, 196
- grafy
 - koordynacja, 178
 - potoku danych, 154

H

- hurtownia danych, 15, 26, 230
 - Amazon Redshift, 92
 - wczytywanie danych, 94
 - Snowflake, 103
 - wczytywanie danych, 105

I

- IAM, Identity and Access Management, 50
- infrastruktura danych, 19, 231
- interfejs pobierania danych, 21
- inżynieria danych, 14

J

- jakość danych, 185
- jezioro danych, 26, 107
- JSON, 86

K

- Kafka, 90
- kanal Slacka, 199
- katalog danych, 218
- klasa BinLogStream Reader, 69
- kontrakt danych, 216
- koordynacja sposobu pracy, 30
- kubełek S3, 49

L

- logika modelu danych, 222

M

- miejsce zewnętrzne, 104
- modelowanie danych, 28, 124
 - atrybuty, 124
 - jedynie dołączanych, 137
 - Kimballa, 127

- przyrostowe pobieranie, 132
- tabele źródłowe, 125
 - w pełni odświeżonych, 125
- wielokrotne używanie logiki, 222, 223
- wskaźniki, 124
- wymiarowe, 127
- zmiana przechwytywania, 147

MongoDB

- wyodrębnianie danych, 78

MySQL

- format
 - MIXED, 67
 - ROW, 67
 - STATEMENT, 67
- replikacja danych, 64
- wyodrębnianie danych, 52

N

narzędzia

- modelowania, 28
- pobierania danych, 27
- narzędzie virtualenv, 48

O

odświeżanie modelu

- pełne, 130, 140
- przyrostowe, 140
- operator Sensor, 178

P

- parametry UTM, 119

- pełne odświeżenie danych, 130, 140
- platforma narzędzi koordynacji, 30
- plik

- airflow_extract.py, 233
- airflow_load.py, 235
- dag_history_daily.sql, 243
- distinct_orders_1.sql, 116
- distinct_orders_2.sql, 118
- elt_pipeline_sample.py, 171
- extract_mysql_incremental.py, 62
- model_2.sql, 224
- order_dup.sql, 203
- order_full_count.sql, 193
- order_sample_zscore.sql, 207
- order_yesterday_zscore.sql, 205
- orders_contract.json, 216
- pageviews_daily.sql, 139

- plik
 - pipeline.conf, 49
 - sekcja [aws_boto_credentials], 52
 - sekcja [mongo_config], 80
 - sekcja [mysql_config], 58
 - sekcja [postgres_config], 76
 - sekcja [snowflake_creds], 105
 - pipeline_performance.py, 249
 - revenue_lastmonth_zscore.sql, 211
 - revenue_sample_zscore.sql, 210
 - revenue_yesterday_zscore.sql, 209
 - sample_mongodb.py, 80
 - simple_dag.py, 166
 - url_parse.sql, 121
 - validator.py, 190, 236
 - validator_logging.py, 238
 - validator_summary_daily.sql, 246
 - zscore_90_twosided.sql, 209
 - pliki CSV, 60
 - plikowy magazyn danych, 49, 107
 - pobieranie danych, 21
 - alternatywy komercyjne, 110
 - narzędzia, 27
 - niebezpieczeństwa, 186
 - powielanie rekordów, 203
 - sprawdzanie wydajności, 232
 - standaryzacja operacji, 219
 - strumieniowane, 89
 - wczytywanie, 92
 - wyodrębnianie, 46
 - zmiana liczby rekordów, 204
 - podwzorzec EtLT, 38
 - połączenie
 - z bazą danych MySQL, 59
 - z egzemplarzem Snowflake, 106
 - z klastrem Redshift, 61, 97
 - PostgreSQL
 - dziennik zdarzeń WAL, 78
 - replikacja danych, 78
 - wyodrębnianie danych, 74, 76
 - potok danych, 13
 - dla uczenia maszynowego, 42, 44
 - generowanie ostrzeżenia, 196
 - informacje zwrotne, 44
 - komunikaty i powiadomienia, 175
 - koordynacja wydajności działania, 248
 - najlepsze praktyki, 214
 - narzędzia instrumentacji, 153
 - przejrzystość wydajności działania, 250
 - tworzenie, 14, 17, 18
 - weryfikacja danych, 176, 184
 - wskaźniki, 229
 - wydajność działania, 242
 - zadania niepołączone, 176
 - zadania połączone, 176
 - przekształcanie, transform, 34
 - przekształcanie danych, 28, 113, 123
 - pozbawione kontekstu, 114
 - przepustowość systemu źródłowego, 25
 - przetwarzanie
 - adresów URL, 119
 - rozproszone, 16
 - Python, 47
 - biblioteka
 - boto3, 51
 - configparser, 49
 - pymysql, 58
 - instalacja bibliotek, 48
 - moduł
 - psycpg2, 158
 - tweepy, 86
 - urllib3, 120
 - polecenie pip, 48
 - środowisko wirtualne env, 48
- ## R
- rejestrwanie danych, 232, 236
 - na dużą skalę, 241
 - replikacja danych
 - binarna, 53
 - binarny dziennik zdarzeń, 64
 - dziennik zdarzeń WAL, 78
 - MySQL, 64
- ## S
- SCD, slowly changing dimension, 130
 - skierowany graf acykliczny, 30, 153, 161
 - czas działania, 244
 - dotyczący wydajności działania, 249
 - dzielenie, 177
 - framework weryfikacji, 195
 - potoku danych ELT, 170
 - prosty, 166
 - tworzenie, 165
 - właściwości, 180
 - wskaźnik sukcesu, 242
 - z wzorcem ELT, 180
 - zadanie weryfikacyjne, 196

Snowflake

- definiowanie FILE FORMAT, 104
- konfiguracja hurtowni danych, 103
- miejsca zewnętrzne, 104
- polecenie COPY INTO, 105

SQL, 15

klauzula

GROUP BY, 116

HAVING, 116

operacja TRUNCATE, 117

polecenie

CREATE TABLE, 75

DROP, 126

wyodrębnianie danych, 52

zapytanie SELECT, 59

standaryzacja pobierania danych, 219

struktura danych, 21

strumieniowane pobieranie danych, 89

system

CDC, 89

zarządzania sposobem pracy, WMS, 30,
153

systemy źródłowe

obsługa

kontraktów danych, 215

zmian, 214

schemat przy odczycie, 217

wprowadzenie abstrakcji, 214

Ś

środowisko wirtualne

Apache Airflow, 156

env, 48

T

tabela

usuwanie duplikatów, 114

tabele źródłowe, 125

test

dwustronny, 205

weryfikacyjny, 188, 192, 194, 202, 245

tworzenie

FILE FORMAT, 104

miejsca zewnętrznego, 104

przychodzącego złączenia sieciowego, 198

roli IAM, 92

skierowanego grafu acyklicznego, 165

użytkownika IAM, 51

U

uczenie maszynowe, 41

UTM, urchin tracking module, 119

uwierzytelnianie IAM, 94

W

WAL, write-ahead log, 75

wczytywanie, load, 34

wczytywanie danych

do hurtowni Redshift, 94

do hurtowni Snowflake, 105

pełne, 99

przyrostowe, 99

wyodrębnionych z CDC, 102

weryfikacja danych, 24, 184

fluktuacje wartości wskaźników, 207

framework weryfikacji, 188, 212

przez analityka, 187

właściciel źródła danych, 20

WMS, workflow management systems, 153

wolumen danych, 23

wskaźnik sukcesu, 242, 245

wydajność działania potoków, 242, 248, 250

wymiar o niewielkiej zmienności, SCD, 130

wyodrębnianie, extract, 34

wyodrębnianie danych

pełne, 54, 76

przyrostowe, 55, 62, 76

replikacja binarna, 64

replikacja z użyciem WAL, 78

z API REST, 85

z MongoDB, 78

z MySQL, 52

z PostgreSQL, 74

wyrażenie nazwane, CTE, 135

wzorzec potoków danych

ELT, 33

ETL, 33

Z, Ż

zaczep sieciowy, 198

zarządzanie danymi, 219

zdarzenie

DELETE_ROWS_EVENT, 68


UPDATE_ROWS_EVENT, 68

WRITE_ROWS_EVENT, 68

źródła danych, 20

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 

Poznaj najlepsze praktyki projektowania i implementacji potoków danych!

Poprawnie zaprojektowane i wdrożone potoki danych mają kluczowe znaczenie dla pomyślnej analizy danych, a także w trakcie uczenia maszynowego. Pozyskanie ogromnych ilości danych z różnych źródeł najczęściej nie stanowi problemu. Nieco trudniejsze jest zaprojektowanie nie procesu ich przetwarzania w celu dostarczenia kontekstu w taki sposób, aby efektywnie korzystać z posiadanych danych w codziennej pracy organizacji i podejmować dzięki nim rozsądne decyzje.

Oto zwięzły przewodnik przeznaczony dla inżynierów danych, którzy chcą poznać zasady implementacji potoków danych. Wyjaśnia najważniejsze pojęcia związane z potokami danych, opisuje zasady ich tworzenia i implementacji, prezentuje także najlepsze praktyki stosowane przez liderów w branży analizy danych. Dzięki książce zrozumiesz, w jaki sposób potoki danych działają na nowoczesnym stosie danych, poznasz też typowe zagadnienia, które trzeba przemyśleć przed podjęciem decyzji dotyczących implementacji. Dowiesz się, jakie są zalety samodzielnego opracowania rozwiązania, a jakie — zakupu gotowego produktu. Poznasz również podstawowe koncepcje, które mają zastosowanie dla frameworków typu open source, produktów komercyjnych i samodzielnie opracowywanych rozwiązań.

Dowiedz się:

- czym jest potok danych i na czym polega jego działanie
- jak się odbywa przenoszenie i przetwarzanie danych w nowoczesnej infrastrukturze
- jakie narzędzia są szczególnie przydatne do tworzenia potoków danych
- jak używać potoków danych do analizy i tworzenia raportów
- jakie są najważniejsze aspekty obsługi potoków, ich testowania i rozwiązywania problemów

James Densmore

jest dyrektorem do spraw infrastruktury danych na potrzeby analityki biznesowej w HubSpot, a także założycielem i głównym konsultantem w Data Liftoff. Od ponad dziesięciu lat kieruje zespołami inżynierów danych i zajmuje się projektowaniem infrastruktury danych.

Helion



helion.pl



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

KOD KORZYŚCI
Sięgnij po więcej! ▶



ISBN 978-83-8322-338-4



9 788383 223384

Cena: 49,90 zł