O'REILLY®

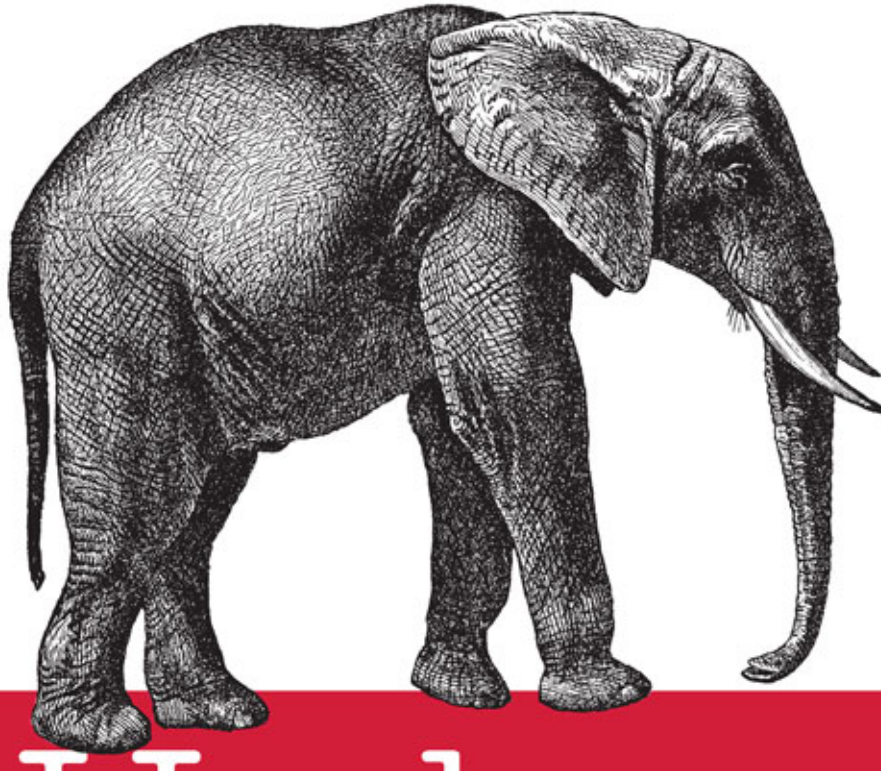

Hadoop

Kompletny przewodnik

ANALIZA I PRZECHOWYWANIE DANYCH

Helion

Tom White

Tytuł oryginału: Hadoop: The Definitive Guide, Fourth Edition

Tłumaczenie: Tomasz Walczak

ISBN: 978-83-283-1457-3

© 2016 Helion SA

Authorized Polish translation of the English edition of Hadoop: The Definitive Guide,
4th Edition ISBN 9781491901632 © 2015 Tom White.

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 jakiejkolwiek postaci jest zabronione. Wykonywanie kopii metodą kserograficzną, fotograficzną, a także kopiowanie książki na nośniku filmowym, magnetycznym lub innym powoduje naruszenie praw autorskich niniejszej publikacji.

Wszystkie znaki występujące w tekście są zastrzeżonymi znakami firmowymi bądź towarowymi ich właścicieli.

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

Wydawnictwo HELION
ul. Kościuszki 1c, 44-100 GLIWICE
tel. 32 231 22 19, 32 230 98 63
e-mail: *helion@helion.pl*
WWW: *http://helion.pl* (księgarnia internetowa, katalog książek)

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

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

Printed in Poland.

• Kup książkę
• Poleć książkę
• Oceń książkę

• Księgarnia internetowa
• Lubię to! » Nasza społeczność

Spis treści

Przedmowa 17

Wprowadzenie 19
Kwestie porządkowe 20
Co nowego znajdziesz w wydaniu czwartym? 20
Konwencje stosowane w tej książce 21
Korzystanie z przykładowego kodu 21
Podziękowania 22

Część I. Podstawy platformy Hadoop 25

Rozdział 1. Poznaj platformę Hadoop 27
Dane! 27
Przechowywanie i analizowanie danych 29
Przetwarzanie w zapytaniach wszystkich danych 30
Poza przetwarzanie wsadowe 30
Porównanie z innymi systemami 31
Systemy RDBMS 32
Przetwarzanie sieciowe 33
Przetwarzanie z udziałem ochotników 34
Krótka historia platformy Apache Hadoop 35
Zawartość książki 38

Rozdział 2. Model MapReduce 41
Zbiór danych meteorologicznych 41
Format danych 41
Analizowanie danych za pomocą narzędzi uniksowych 42
Analizowanie danych za pomocą Hadoopa 44
Mapowanie i redukcja 44
Model MapReduce w Javie 45
Skalowanie 51
Przepływ danych 51
Funkcje łączące 55
Wykonywanie rozproszonego zadania w modelu MapReduce 56

Kup książkę Poleć książkę

Narzędzie Streaming Hadoop ... 57
Ruby ... 57
Python ... 59

Rozdział 3. System HDFS ... 61
Projekt systemu HDFS ... 61
Pojęcia związane z systemem HDFS ... 63
Bloki ... 63
Węzły nazw i węzły danych ... 64
Zapisywanie bloków w pamięci podręcznej ... 65
Federacje w systemie HDFS ... 65
Wysoka dostępność w systemie HDFS ... 66
Interfejs uruchamiany z wiersza poleceń ... 68
Podstawowe operacje w systemie plików ... 69
Systemy plików w Hadoopie ... 70
Interfejsy ... 71
Interfejs w Javie ... 74
Odczyt danych na podstawie adresu URL systemu Hadoop ... 74
Odczyt danych za pomocą interfejsu API FileSystem ... 75
Zapis danych ... 78
Katalogi ... 80
Zapytania w systemie plików ... 80
Usuwanie danych ... 84
Przepływ danych ... 85
Anatomia odczytu pliku ... 85
Anatomia procesu zapisu danych do pliku ... 87
Model zapewniania spójności ... 90
Równoległe kopiowanie za pomocą programu distcp ... 91
Zachowywanie równowagi w klastrach z systemem HDFS ... 92

Rozdział 4. System YARN ... 95
Struktura działania aplikacji w systemie YARN ... 96
Żądania zasobów ... 97
Czas życia aplikacji ... 97
Budowanie aplikacji systemu YARN ... 98
System YARN a implementacja MapReduce 1 ... 99
Szeregowanie w systemie YARN ... 101
Dostępne programy szeregujące ... 101
Konfigurowanie programu szeregującego Capacity ... 103
Konfigurowanie programu szeregującego Fair ... 105
Szeregowanie z opóźnieniem ... 109
Podejście Dominant Resource Fairness ... 109
Dalsza lektura ... 110

Rozdział 5. Operacje wejścia-wyjścia w platformie Hadoop ... 111
Integralność danych ... 111
Integralność danych w systemie HDFS ... 112
Klasa LocalFileSystem ... 112
Klasa ChecksumFileSystem ... 113

Kup książkę Poleć książkę

Kompresja 113
Kodeki 114
Kompresja i podział danych wejściowych 118
Wykorzystywanie kompresji w modelu MapReduce 120
Serializacja 122
Interfejs Writable 123
Klasy z rodziny Writable 125
Tworzenie niestandardowych implementacji interfejsu Writable 132
Platformy do obsługi serializacji 137
Plikowe struktury danych 138
Klasa SequenceFile 138
Klasa MapFile 145
Inne formaty plików i formaty kolumnowe 146

Część II. Model MapReduce 149

Rozdział 6. Budowanie aplikacji w modelu MapReduce 151
API do obsługi konfiguracji 151
Łączenie zasobów 152
Podstawianie wartości zmiennych 153
Przygotowywanie środowiska programowania 154
Zarządzanie konfiguracją 155
GenericOptionsParser, Tool i ToolRunner 158
Pisanie testów jednostkowych za pomocą biblioteki MRUnit 161
Mapper 161
Reduktor 164
Uruchamianie kodu lokalnie na danych testowych 164
Uruchamianie zadania w lokalnym mechanizmie wykonywania zadań 165
Testowanie sterownika 166
Uruchamianie programów w klastrze 167
Tworzenie pakietu z zadaniem 168
Uruchamianie zadania 169
Sieciowy interfejs użytkownika modelu MapReduce 171
Pobieranie wyników 174
Debugowanie zadania 175
Dzienniki w Hadoopie 178
Zdalne diagnozowanie 180
Dostrajanie zadania 181
Profilowanie operacji 181
Przepływ pracy w modelu MapReduce 182
Rozbijanie problemu na zadania w modelu MapReduce 183
JobControl 184
Apache Oozie 185

Rozdział 7. Jak działa model MapReduce? 191
Wykonywanie zadań w modelu MapReduce 191
Przesyłanie zadania 192
Inicjowanie zadania 193
Przypisywanie operacji do węzłów 194

Kup książkę Poleć książkę

Wykonywanie operacji 194
Aktualizowanie informacji o postępie i statusu 196
Ukończenie zadania 197
Niepowodzenia 198
Niepowodzenie operacji 198
Niepowodzenie zarządcy aplikacji 199
Niepowodzenie menedżera węzła 200
Niepowodzenie menedżera zasobów 201
Przestawianie i sortowanie 202
Etap mapowania 202
Etap redukcji 203
Dostrajanie konfiguracji 206
Wykonywanie operacji 208
Środowisko wykonywania operacji 208
Wykonywanie spekulacyjne 209
Klasy z rodziny OutputCommitter 210

Rozdział 8. Typy i formaty z modelu MapReduce 213
Typy w modelu MapReduce 213
Domyślne zadanie z modelu MapReduce 216
Formaty wejściowe 222
Wejściowe porcje danych i rekordy 222
Tekstowe dane wejściowe 232
Binarne dane wejściowe 236
Różne dane wejściowe 237
Dane wejściowe (i wyjściowe) z bazy 238
Formaty danych wyjściowych 238
Tekstowe dane wyjściowe 239
Binarne dane wyjściowe 239
Wiele danych wyjściowych 240
Leniwe generowanie danych wyjściowych 243
Dane wyjściowe dla bazy 244

Rozdział 9. Funkcje modelu MapReduce 245
Liczniki 245
Liczniki wbudowane 245
Zdefiniowane przez użytkowników liczniki Javy 248
Zdefiniowane przez użytkownika liczniki narzędzia Streaming 252
Sortowanie 253
Przygotowania 253
Częściowe sortowanie 254
Sortowanie wszystkich danych 255
Sortowanie pomocnicze 259
Złączanie 264
Złączanie po stronie mapowania 265
Złączanie po stronie redukcji 265
Rozdzielanie danych pomocniczych 268
Wykorzystanie konfiguracji zadania 268
Rozproszona pamięć podręczna 269
Klasy biblioteczne modelu MapReduce 273

Kup książkę Poleć książkę

Część III. Praca z platformą Hadoop 275

Rozdział 10. Budowanie klastra opartego na platformie Hadoop 277
Specyfikacja klastra 278
Określanie wielkości klastra 279
Topologia sieci 280
Przygotowywanie i instalowanie klastra 282
Instalowanie Javy 282
Tworzenie kont użytkowników w Uniksie 282
Instalowanie Hadoopa 282
Konfigurowanie ustawień protokołu SSH 282
Konfigurowanie Hadoopa 283
Formatowanie systemu plików HDFS 283
Uruchamianie i zatrzymywanie demonów 284
Tworzenie katalogów użytkowników 285
Konfiguracja Hadoopa 285
Zarządzanie konfiguracją 286
Ustawienia środowiskowe 287
Ważne właściwości demonów Hadoopa 289
Adresy i porty demonów Hadoopa 296
Inne właściwości Hadoopa 298
Bezpieczeństwo 299
Kerberos i Hadoop 300
Tokeny do delegowania uprawnień 302
Inne usprawnienia w zabezpieczeniach 303
Testy porównawcze klastra opartego na Hadoopie 305
Testy porównawcze w Hadoopie 305
Zadania użytkowników 307

Rozdział 11. Zarządzanie platformą Hadoop 309
System HDFS 309
Trwałe struktury danych 309
Tryb bezpieczny 314
Rejestrowanie dziennika inspekcji 315
Narzędzia 316
Monitorowanie 320
Rejestrowanie informacji w dziennikach 320
Wskaźniki i technologia JMX 321
Konserwacja 322
Standardowe procedury administracyjne 322
Dodawanie i usuwanie węzłów 324
Aktualizacje 327

Kup książkę Poleć książkę

Część IV. Powiązane projekty 331

Rozdział 12. Avro 333
Typy danych i schematy systemu Avro 334
Serializacja i deserializacja w pamięci 337
Specyficzny interfejs API 338
Pliki danych systemu Avro 340
Współdziałanie języków 341
Interfejs API dla Pythona 341
Narzędzia systemu Avro 342
Określanie schematu 343
Porządek sortowania 344
Avro i model MapReduce 346
Sortowanie za pomocą modelu MapReduce i systemu Avro 349
Używanie systemu Avro w innych językach 351

Rozdział 13. Parquet 353
Model danych 354
Kodowanie struktury zagnieżdżonych danych 355
Format plików Parquet 356
Konfiguracja dla formatu Parquet 358
Zapis i odczyt plików w formacie Parquet 358
Avro, Protocol Buffers i Thrift 360
Format Parquet i model MapReduce 362

Rozdział 14. Flume 365
Instalowanie platformy Flume 365
Przykład 366
Transakcje i niezawodność 368
Porcje zdarzeń 369
Ujścia w systemie HDFS 369
Podział na partycje i interceptory 370
Formaty plików 371
Rozsyłanie danych do wielu kanałów 372
Gwarancje dostarczenia 373
Selektory replikacji i rozsyłania 374
Dystrybucja — warstwy agentów 374
Gwarancje dostarczenia danych 376
Grupy ujść 377
Integrowanie platformy Flume z aplikacjami 380
Katalog komponentów 381
Dalsza lektura 382

Kup książkę Poleć książkę

Rozdział 15. Sqoop 383
Pobieranie Sqoopa 383
Konektory Sqoopa 385
Przykładowa operacja importu 385
Formaty plików tekstowych i binarnych 388
Wygenerowany kod 388
Inne systemy serializacji 389
Importowanie — dokładne omówienie 389
Kontrolowanie procesu importu 391
Import i spójność 392
Przyrostowy import 392
Importowanie w trybie bezpośrednim 392
Praca z zaimportowanymi danymi 393
Importowane dane i platforma Hive 394
Importowanie dużych obiektów 396
Eksportowanie 398
Eksportowanie — dokładne omówienie 399
Eksport i transakcje 401
Eksport i pliki typu SequenceFile 401
Dalsza lektura 402

Rozdział 16. Pig 403
Instalowanie i uruchamianie platformy Pig 404
Tryby wykonywania 404
Uruchamianie programów platformy Pig 406
Grunt 406
Edytory kodu w języku Pig Latin 407
Przykład 407
Generowanie przykładowych danych 409
Porównanie platformy Pig z bazami danych 410
Język Pig Latin 411
Struktura 411
Instrukcje 412
Wyrażenia 417
Typy 418
Schematy 419
Funkcje 423
Makra 425
Funkcje zdefiniowane przez użytkownika 426
Funkcje UDF służące do filtrowania 426
Obliczeniowa funkcja UDF 429
Funkcje UDF służące do wczytywania danych 430
Operatory używane do przetwarzania danych 433
Wczytywanie i zapisywanie danych 433
Filtrowanie danych 434
Grupowanie i złączanie danych 436
Sortowanie danych 441
Łączenie i dzielenie danych 442

Kup książkę Poleć książkę

Platforma Pig w praktyce 442
Współbieżność 442
Relacje anonimowe 443
Podstawianie wartości pod parametry 443
Dalsza lektura 444

Rozdział 17. Hive 445
Instalowanie platformy Hive 446
Powłoka platformy Hive 446
Przykład 448
Uruchamianie platformy Hive 449
Konfigurowanie platformy Hive 449
Usługi platformy Hive 451
Magazyn metadanych 453
Porównanie z tradycyjnymi bazami danych 456
Uwzględnianie schematu przy odczycie lub przy zapisie 456
Aktualizacje, transakcje i indeksy 456
Inne silniki obsługujące język SQL w Hadoopie 457
HiveQL 458
Typy danych 458
Operatory i funkcje 462
Tabele 463
Tabele zarządzane i tabele zewnętrzne 463
Partycje i kubełki 464
Formaty przechowywania danych 468
Importowanie danych 472
Modyfikowanie tabel 473
Usuwanie tabel 474
Pobieranie danych 474
Sortowanie i agregacja danych 475
Skrypty modelu MapReduce 475
Złączenia 476
Podzapytania 479
Widoki 480
Funkcje zdefiniowane przez użytkowników 481
Pisanie funkcji UDF 482
Pisanie funkcji UDAF 484
Dalsza lektura 488

Rozdział 18. Crunch 489
Przykład 490
Podstawowe interfejsy API Cruncha 493
Proste operacje 493
Typy 497
Źródłowe i docelowe zbiory danych 500
Funkcje 502
Materializacja 504

Kup książkę Poleć książkę

Wykonywanie potoku 506
Uruchamianie potoku 506
Zatrzymywanie potoku 507
Inspekcja planu wykonania w Crunchu 508
Algorytmy iteracyjne 511
Tworzenie punktów kontrolnych w potokach 512
Biblioteki w Crunchu 513
Dalsza lektura 515

Rozdział 19. Spark 517
Instalowanie Sparka 518
Przykład 518
Aplikacje, zadania, etapy i operacje w Sparku 520
Niezależna aplikacja w języku Scala 520
Przykład napisany w Javie 521
Przykład napisany w Pythonie 522
Zbiory RDD 523
Tworzenie zbiorów RDD 523
Transformacje i akcje 524
Utrwalanie danych 527
Serializacja 529
Zmienne współużytkowane 530
Zmienne rozsyłane 531
Akumulatory 531
Anatomia przebiegu zadania w Sparku 532
Przesyłanie zadań 532
Tworzenie skierowanego grafu acyklicznego 533
Szeregowanie operacji 535
Wykonywanie operacji 536
Wykonawcy i menedżery klastra 536
Spark i YARN 537
Dalsza lektura 540

Rozdział 20. HBase 541
Podstawy 541
Tło historyczne 542
Omówienie zagadnień 542
Krótki przegląd modelu danych 542
Implementacja 544
Instalacja 546
Przebieg testowy 547
Klienty 549
Java 549
Model MapReduce 552
Interfejsy REST i Thrift 553
Budowanie interaktywnej aplikacji do przesyłania zapytań 553
Projekt schematu 554
Wczytywanie danych 555
Zapytania interaktywne 558

Kup książkę Poleć książkę

Baza HBase a bazy RDBMS 561
Historia cieszącej się powodzeniem usługi 562
Baza HBase 563
Bazy HBase w praktyce 563
System HDFS 564
Interfejs użytkownika 564
Wskaźniki 565
Liczniki 565
Dalsza lektura 565

Rozdział 21. ZooKeeper 567
Instalowanie i uruchamianie systemu ZooKeeper 568
Przykład 570
Przynależność do grupy w systemie ZooKeeper 570
Tworzenie grupy 571
Dołączanie członków do grupy 573
Wyświetlanie członków grupy 574
Usuwanie grupy 575
Usługa ZooKeeper 576
Model danych 576
Operacje 578
Implementacja 582
Spójność 583
Sesje 585
Stany 587
Budowanie aplikacji z wykorzystaniem ZooKeepera 588
Usługa do zarządzania konfiguracją 588
Odporna na błędy aplikacja ZooKeepera 591
Usługa do zarządzania blokadami 594
Inne rozproszone struktury danych i protokoły 596
ZooKeeper w środowisku produkcyjnym 597
Odporność a wydajność 598
Konfiguracja 599
Dalsza lektura 600

Część V. Studia przypadków 601

Rozdział 22. Integrowanie danych w firmie Cerner 603
Od integracji procesorów do integracji semantycznej 603
Poznaj platformę Crunch 604
Budowanie kompletnego obrazu 604
Integrowanie danych z obszaru opieki zdrowotnej 607
Możliwość łączenia danych w różnych platformach 610
Co dalej? 611

Kup książkę Poleć książkę

Rozdział 23. Nauka o danych biologicznych — ratowanie życia za pomocą oprogramowania ... 613
Struktura DNA ... 615
Kod genetyczny — przekształcanie liter DNA w białka ... 616
Traktowanie kodu DNA jak kodu źródłowego ... 617
Projekt poznania ludzkiego genomu i genomy referencyjne ... 619
Sekwencjonowanie i wyrównywanie DNA ... 620
ADAM — skalowalna platforma do analizy genomu ... 621
Programowanie piśmienne za pomocą języka IDL systemu Avro ... 621
Dostęp do danych kolumnowych w formacie Parquet ... 623
Prosty przykład — zliczanie k-merów za pomocą Sparka i ADAM-a ... 624
Od spersonalizowanych reklam do spersonalizowanej medycyny ... 626
Dołącz do projektu ... 627

Rozdział 24. Cascading ... 629
Pola, krotki i potoki ... 630
Operacje ... 632
Typy Tap, Scheme i Flow ... 634
Cascading w praktyce ... 635
Elastyczność ... 637
Hadoop i Cascading w serwisie ShareThis ... 638
Podsumowanie ... 642

Dodatki ... 643

Dodatek A. Instalowanie platformy Apache Hadoop ... 645
Wymagania wstępne ... 645
Instalacja ... 645
Konfiguracja ... 646
Tryb niezależny ... 647
Tryb pseudorozproszony ... 647
Tryb rozproszony ... 649

Dodatek B. Dystrybucja firmy Cloudera ... 651

Dodatek C. Przygotowywanie danych meteorologicznych od instytucji NCDC ... 653

Dodatek D. Dawny i nowy interfejs API Javy dla modelu MapReduce ... 657

Skorowidz ... 661

Kup książkę Poleć książkę

Kup książkę Poleć książkę

ROZDZIAŁ 6.

Budowanie aplikacji w modelu MapReduce

W rozdziale 2. znajduje się wprowadzenie do modelu MapReduce. W tym rozdziale zapoznasz się z praktycznymi aspektami budowania w Hadoopie aplikacji w modelu MapReduce.

Pisanie programu w modelu MapReduce odbywa się zgodnie z określonym wzorcem. Najpierw należy przygotować funkcje mapującą i redukującą (najlepiej z testami jednostkowymi sprawdzającymi, czy funkcje działają zgodnie z oczekiwaniami). Następnie trzeba dodać program sterujący, który uruchamia zadanie. Ten program można wywołać w środowisku IDE dla małego podzbioru danych, aby ustalić, czy działa poprawnie. Jeśli wystąpią problemy, należy wykorzystać debuger ze środowiska IDE do wykrycia ich źródła. Na podstawie uzyskanych informacji można rozwinąć testy jednostkowe z uwzględnieniem danej sytuacji i usprawnić mapper lub reduktor, by zapewnić poprawną obsługę używanych danych wejściowych.

Jeżeli program działa prawidłowo dla małego zbioru danych, jest gotowy do uruchomienia w klastrze. Wykonanie programu dla pełnego zbioru danych prawdopodobnie pozwoli odkryć inne problemy. Można je rozwiązać w opisany wcześniej sposób, rozbudowując testy i modyfikując mapper lub reduktor pod kątem obsługi nowych przypadków. Debugowanie błędnych programów w klastrze jest trudne, dlatego dalej opisanych jest kilka popularnych technik, które to ułatwiają.

Gdy program już działa, możesz go dopracować. Najpierw wykonaj standardowe testy związane z przyspieszaniem pracy programów w modelu MapReduce, a następnie przeprowadź profilowanie zadania. Profilowanie programów rozproszonych to skomplikowane zadanie, jednak Hadoop udostępnia mechanizmy ułatwiające ten proces.

Przed rozpoczęciem pisania programu w modelu MapReduce należy zainstalować i skonfigurować środowisko programowania. W tym celu musisz zrozumieć, jak Hadoop przetwarza konfigurację.

API do obsługi konfiguracji

Komponenty w Hadoopie są konfigurowane za pomocą dostępnego w tej platformie specjalnego interfejsu API. Obiekt klasy `Configuration` (z pakietu `org.apache.hadoop.conf`) reprezentuje kolekcję *właściwości* konfiguracyjnych i ich wartości. Każda właściwość ma nazwę (typu `String`), a jako wartości używane są różne typy, w tym typy proste Javy (na przykład `boolean`, `int`, `long` i `float`), typy `String`, `Class` i `java.io.File` oraz kolekcje wartości typu `String`.

Kup książkę Poleć książkę

Obiekt typu `Configuration` wczytuje właściwości z *zasobów* — plików XML o prostej strukturze definiujących pary nazwa-wartość (zobacz listing 6.1).

Listing 6.1. Prosty plik konfiguracyjny configuration-1.xml

```
<?xml version="1.0"?>
<configuration>
  <property>
    <name>color</name>
    <value>yellow</value>
    <description>Color</description>
  </property>

  <property>
    <name>size</name>
    <value>10</value>
    <description>Size</description>
  </property>

  <property>
    <name>weight</name>
    <value>heavy</value>
    <final>true</final>
    <description>Weight</description>
  </property>

  <property>
    <name>size-weight</name>
    <value>${size},${weight}</value>
    <description>Size and weight</description>
  </property>
</configuration>
```

Jeśli dane obiektu typu `Configuration` znajdują się w pliku *configuration-1.xml*, dostęp do właściwości można uzyskać za pomocą następującego kodu:

```
Configuration conf = new Configuration();
conf.addResource("configuration-1.xml");
assertThat(conf.get("color"), is("yellow"));
assertThat(conf.getInt("size", 0), is(10));
assertThat(conf.get("breadth", "wide"), is("wide"));
```

Warto zwrócić uwagę na kilka kwestii. W pokazanym pliku XML nie są przechowywane informacje o typie. Właściwości można interpretować jako wartość danego typu w momencie ich wczytywania. Ponadto metody `get()` umożliwiają określenie wartości domyślnej, używanej, jeśli dana właściwość nie jest zdefiniowana w pliku XML (tak jest z właściwością `breadth` w przykładzie).

Łączenie zasobów

Sytuacja staje się ciekawa, gdy do definiowania obiektu typu `Configuration` używany jest więcej niż jeden zasób. To podejście jest stosowane w Hadoopie do wyodrębniania właściwości domyślnych systemu (zdefiniowanych wewnętrznie w pliku *core-default.xml*) od właściwości specyficznych dla danej jednostki (zdefiniowanych w pliku *core-site.xml*). W pliku z listingu 6.2 zdefiniowane są właściwości `size` i `weight`.

Kup książkę Poleć książkę

Listing 6.2. Drugi plik konfiguracyjny — configuration-2.xml

```
<?xml version="1.0"?>
<configuration>
  <property>
    <name>size</name>
    <value>12</value>
  </property>

  <property>
    <name>weight</name>
    <value>light</value>
  </property>
</configuration>
```

Zasoby są dodawane do obiektu typu `Configuration` po kolei:

```
Configuration conf = new Configuration();
conf.addResource("configuration-1.xml");
conf.addResource("configuration-2.xml");
```

Właściwości zdefiniowane w później dodawanych zasobach zastępują wcześniejsze definicje. Dlatego właściwość `size` ostatecznie przyjmuje wartość z drugiego pliku konfiguracyjnego, *configuration-2.xml*.

```
assertThat(conf.getInt("size", 0), is(12));
```

Jednak właściwości oznaczonych jako `final` nie można zastępować w dalszych definicjach. Właściwość `weight` w pierwszym pliku konfiguracyjnym ma modyfikator `final`, dlatego próba zastąpienia jej wartości w drugim pliku kończy się niepowodzeniem (zachowana zostaje wartość z pierwszego pliku).

```
assertThat(conf.get("weight"), is("heavy"));
```

Próba przesłonięcia właściwości z modyfikatorem `final` zwykle oznacza błąd konfiguracji. Skutkuje to zarejestrowaniem komunikatu ostrzegawczego, co ułatwia późniejszą diagnozę. Administratorzy oznaczają modyfikatorem `final` właściwości w lokalnych plikach demonów, gdy nie chcą, aby użytkownicy zmieniali te właściwości w plikach po stronie klienta lub za pomocą parametrów przekazywanych do zadania.

Podstawianie wartości zmiennych

Właściwości konfiguracyjne można definiować za pomocą innych właściwości i właściwości systemowych. Na przykład właściwość `size-weight` z pierwszego pliku konfiguracyjnego jest zdefiniowana jako `${size},${weight}`. Za te zmienne podstawiane są wartości znalezione w konfiguracji.

```
assertThat(conf.get("size-weight"), is("12,heavy"));
```

Właściwości systemowe są traktowane priorytetowo względem właściwości zdefiniowanych w plikach zasobów.

```
System.setProperty("size", "14");
assertThat(conf.get("size-weight"), is("14,heavy"));
```

Ten mechanizm jest przydatny do zastępowania właściwości w wierszu poleceń za pomocą argumentów maszyny JVM `-D`*`właściwość=wartość`*.

Zauważ, że choć właściwości konfiguracyjne można definiować w kategoriach właściwości systemowych, to jeśli właściwości systemowe nie zostaną zredefiniowane we właściwościach konfiguracyjnych, *nie* będą dostępne za pomocą interfejsu API do obsługi konfiguracji. Dlatego:

Kup książkę Poleć książkę

```
System.setProperty("length", "2");
assertThat(conf.get("length"), is((String) null));
```

Przygotowywanie środowiska programowania

Pierwszy krok polega na utworzeniu projektu. Pozwoli to budować programy w modelu MapReduce i uruchamiać je w trybie lokalnym (niezależnym) z poziomu wiersza poleceń lub środowiska IDE. Plik POM (ang. *Project Object Model*) Mavena z listingu 6.3 pokazuje zależności potrzebne do budowania i testowania programów w modelu MapReduce.

Listing 6.3. Plik POM Mavena potrzebny do budowania i testowania aplikacji w modelu MapReduce

```
<project>
  <modelVersion>4.0.0</modelVersion>
  <groupId>com.hadoopbook</groupId>
  <artifactId>hadoop-book-mr-dev</artifactId>
  <version>4.0</version>
  <properties>
    <project.build.sourceEncoding>UTF-8</project.build.sourceEncoding>
    <hadoop.version>2.5.1</hadoop.version>
  </properties>
  <dependencies>
    <!-- Element głównego klienta Hadoopa -->
    <dependency>
      <groupId>org.apache.hadoop</groupId>
      <artifactId>hadoop-client</artifactId>
      <version>${hadoop.version}</version>
    </dependency>
    <!-- Elementy testów jednostkowych -->
    <dependency>
      <groupId>junit</groupId>
      <artifactId>junit</artifactId>
      <version>4.11</version>
      <scope>test</scope>
    </dependency>
    <dependency>
      <groupId>org.apache.mrunit</groupId>
      <artifactId>mrunit</artifactId>
      <version>1.1.0</version>
      <classifier>hadoop2</classifier>
      <scope>test</scope>
    </dependency>
    <!-- Element testowy Hadoopa do uruchamiania miniklastrów -->
    <dependency>
      <groupId>org.apache.hadoop</groupId>
      <artifactId>hadoop-minicluster</artifactId>
      <version>${hadoop.version}</version>
    <scope>test</scope>
  </dependency>
  </dependencies>
  <build>
    <finalName>hadoop-examples</finalName>
    <plugins>
      <plugin>
        <groupId>org.apache.maven.plugins</groupId>
        <artifactId>maven-compiler-plugin</artifactId>
        <version>3.1</version>
        <configuration>
          <source>1.6</source>
          <target>1.6</target>
```


Kup książkę Poleć książkę

```
        </configuration>
      </plugin>
      <plugin>
        <groupId>org.apache.maven.plugins</groupId>
        <artifactId>maven-jar-plugin</artifactId>
        <version>2.5</version>
        <configuration>
          <outputDirectory>${basedir}</outputDirectory>
        </configuration>
      </plugin>
    </plugins>
  </build>
</project>
```

Interesującą częścią pliku POM jest sekcja z zależnościami (możesz też zastosować inne narzędzie do budowania, takie jak Gradle lub Ant z Ivy, o ile użyjesz zdefiniowanego tu zestawu zależności). Do budowania zadań w modelu MapReduce potrzebny jest tylko element `hadoop-client`, obejmujący wszystkie używane po stronie klienta klasy Hadoopa potrzebne do interakcji z systemem HDFS i modelem MapReduce. Do przeprowadzania testów jednostkowych używany jest tu `junit`, a do pisania testów dla modelu MapReduce — `mrunit`. Biblioteka `hadoop-minicluster` obsługuje miniklastry przydatne do testowania programów na klastrach Hadoopa działających w jednej maszynie JVM.

Wiele środowisk IDE potrafi bezpośrednio wczytywać pliki POM Mavena, dlatego wystarczy wskazać im katalog z plikiem *pom.xml*, po czym można przejść do pisania kodu. Możesz też wykorzystać Mavena do wygenerowania plików konfiguracyjnych dla środowiska IDE. Na przykład poniższy kod tworzy pliki konfiguracyjne dla środowiska Eclipse, co pozwala zaimportować projekt do tego narzędzia.

```
% mvn eclipse:eclipse -DdownloadSources=true -DdownloadJavadocs=true
```

Zarządzanie konfiguracją

W trakcie budowania aplikacji Hadoopa programista często przełącza aplikację między środowiskiem lokalnym a klastrem. Możliwe też, że pracuje z kilkoma klastrami lub używa lokalnego „pseudorozproszonego” klastra, w którym chce przeprowadzać testy (w takim klastrze wszystkie demony działają na jednej maszynie; ustawianie tego trybu opisano w dodatku A).

Jednym ze sposobów na uwzględnienie wszystkich tych sytuacji jest utworzenie plików konfiguracyjnych Hadoopa z ustawieniami połączeń dla każdego używanego klastra. Następnie w momencie uruchamiania aplikacji lub narzędzi Hadoopa należy wskazać potrzebny klaster. Zaleca się przechowywanie wspomnianych plików poza drzewem katalogów instalacji Hadoopa, ponieważ pozwala to na łatwe przełączanie się między wersjami Hadoopa bez powielania lub utraty ustawień.

Na potrzeby książki załóżmy, że istnieje katalog *conf* zawierający trzy pliki konfiguracyjne: *hadoop-local.xml*, *hadoop-localhost.xml* i *hadoop-cluster.xml* (są one dostępne w przykładowym kodzie dołączonym do książki). Zauważ, że w nazwach tych plików nie ma nic specjalnego. Te pliki to tylko wygodny sposób na połączenie wybranych ustawień konfiguracyjnych. Możesz porównać je z plikami z tabeli A.1 z dodatku A, w których umieszczane są analogiczne ustawienia konfiguracyjne po stronie serwera.

Kup książkę Poleć książkę

Plik *hadoop-local.xml* zawiera domyślną konfigurację Hadoopa dla domyślnego systemu plików i lokalnej (z maszyny JVM) platformy do uruchamiania zadań w modelu MapReduce.

```
<?xml version="1.0"?>
<configuration>

  <property>
    <name>fs.defaultFS</name>
    <value>file:///</value>
  </property>

  <property>
    <name>mapreduce.framework.name</name>
    <value>local</value>
  </property>

</configuration>
```

Ustawienia z pliku *hadoop-localhost.xml* określają węzeł nazw i menedżer zasobów systemu YARN działające w hoście lokalnym.

```
<?xml version="1.0"?>
<configuration>

  <property>
    <name>fs.defaultFS</name>
    <value>hdfs://localhost/</value>
  </property>

  <property>
    <name>mapreduce.framework.name</name>
    <value>yarn</value>
  </property>

  <property>
    <name>yarn.resourcemanager.address</name>
    <value>localhost:8032</value>
  </property>

</configuration>
```

Plik *hadoo-cluster.xml* zawiera szczegółowe informacje o adresach węzła nazw i menedżera zasobów systemu YARN z klastra. W praktyce ten plik jest nazywany na podstawie nazwy klastra, a nie, tak jak tutaj, „cluster”.

```
<?xml version="1.0"?>
<configuration>

  <property>
    <name>fs.defaultFS</name>
    <value>hdfs://namenode/</value>
  </property>

  <property>
    <name>mapreduce.framework.name</name>
    <value>yarn</value>
  </property>
  <property>
    <name>yarn.resourcemanager.address</name>
    <value>resourcemanager:8032</value>
  </property>

</configuration>
```


Kup książkę Poleć książkę

W razie potrzeby możesz dodać do tych plików inne właściwości konfiguracyjne.

Ustawianie tożsamości użytkownika

Tożsamość użytkownika używana w Hadoopie do zarządzania uprawnieniami w systemie HDFS jest ustalana za pomocą polecenia `whoami` wywoływanego w systemie klienta. Podobnie nazwy grup są określane na podstawie danych wyjściowych z instrukcji `groups`.

Jeśli jednak tożsamość użytkownika w Hadoopie jest różna od nazwy konta użytkownika na maszynie klienckiej, można bezpośrednio ustawić nazwę użytkownika w Hadoopie za pomocą zmiennej środowiskowej `HADOOP_USER_NAME`. Możesz też zmienić odwzorowania w grupach użytkowników za pomocą właściwości konfiguracyjnej `hadoop.user.group.static.mapping.overrides`. Na przykład wartość `dr.who=;preston=directors,inventors` oznacza, że użytkownik `dr.who` nie jest członkiem żadnej grupy, a użytkownik `preston` należy do grup `directors` i `inventors`.

Tożsamość użytkownika używaną przez interfejsy sieciowe Hadoopa można ustawić za pomocą właściwości `hadoop.http.staticuser.user`. Domyślnie używana jest tożsamość `dr.who`, która nie daje uprawnień administratora, dlatego pliki systemowe nie są dostępne z poziomu interfejsów sieciowych.

Zauważ, że domyślnie w tym modelu uwierzytelnianie nie jest stosowane. Z punktu „Inne usprawnienia w zabezpieczeniach” w rozdziale 10. dowiesz się, jak skonfigurować w Hadoopie uwierzytelnianie oparte na protokole Kerberos.

Przy tych ustawieniach łatwo można wskazać dowolną konfigurację za pomocą opcji `-conf` w wierszu poleceń. Na przykład poniższe polecenie wyświetla zawartość katalogu z serwera HDFS działającego w trybie pseudorozproszonym na hoście lokalnym.

```
% hadoop fs -conf conf/hadoop-localhost.xml -ls .
Found 2 items
drwxr-xr-x   - tom supergroup       0 2014-09-08 10:19 input
drwxr-xr-x   - tom supergroup       0 2014-09-08 10:19 output
```

Jeśli pominiesz opcję `-conf`, użyta zostanie konfiguracja Hadoopa z podkatalogu *etc/hadoop* z katalogu ze zmiennej `$HADOOP_HOME`. Jeżeli jednak ustawiona jest zmienna `HADOOP_CONF_DIR`, pliki konfiguracyjne Hadoopa są wczytywane z podanej w niej lokalizacji.

Oto inny sposób zarządzania ustawieniami konfiguracyjnymi — skopiuj katalog *etc/hadoop* z instalacji Hadoopa w inne miejsce, umieść tam pliki konfiguracyjne **-site.xml* (z odpowiednimi opcjami) i ustaw zmienną środowiskową `HADOOP_CONF_DIR` na tę nową lokalizację. Główna zaleta takiego podejścia polega na tym, że nie trzeba używać opcji `–conf` w każdej instrukcji. Ponadto można wprowadzić zmiany w plikach innych niż pliki XML z konfiguracją Hadoopa (na przykład w pliku *log4j.properties*), ponieważ katalog ze zmiennej `HADOOP_CONF_DIR` zawiera kopię wszystkich plików konfiguracyjnych (zobacz punkt „Konfiguracja Hadoopa” w rozdziale 10.).

Dostępne w Hadoopie narzędzia obsługują opcję `-conf`. Można też łatwo zapewnić jej obsługę we własnych programach (na przykład w programach uruchamiających zadania w modelu MapReduce). Umożliwia to interfejs `Tool`.

Kup książkę Poleć książkę

GenericOptionsParser, Tool i ToolRunner

Hadoop udostępnia kilka klas pomocniczych ułatwiających uruchamianie zadań z poziomu wiersza poleceń. `GenericOptionsParser` to klasa, która interpretuje standardowe opcje Hadoopa podawane w wierszu poleceń i ustawia je w obiekcie typu `Configuration`, tak by można je było potem w dowolny sposób zastosować. Programiści zwykle nie używają bezpośrednio klasy `GenericOptionsParser`, ponieważ wygodniej jest zaimplementować interfejs `Tool` i uruchamiać aplikację za pomocą klasy `ToolRunner`, która wewnętrznie korzysta z klasy `GenericOptionsParser`.

```
public interface Tool extends Configurable {
  int run(String [] args) throws Exception;
}
```

Listing 6.4 przedstawia bardzo prostą implementację interfejsu `Tool`, która wyświetla klucze i wartości wszystkich właściwości z obiektu typu `Configuration`.

Listing 6.4. Przykładowa implementacja interfejsu Tool wyświetlająca właściwości z obiektu typu Configuration

```
public class ConfigurationPrinter extends Configured implements Tool {

  static {
    Configuration.addDefaultResource("hdfs-default.xml");
    Configuration.addDefaultResource("hdfs-site.xml");
    Configuration.addDefaultResource("yarn-default.xml");
    Configuration.addDefaultResource("yarn-site.xml");
    Configuration.addDefaultResource("mapred-default.xml");
    Configuration.addDefaultResource("mapred-site.xml");
  }

  @Override
  public int run(String[] args) throws Exception {
    Configuration conf = getConf();
    for (Entry<String, String> entry: conf) {
      System.out.printf("%s=%s\n", entry.getKey(), entry.getValue());
    }
    return 0;
  }

  public static void main(String[] args) throws Exception {
    int exitCode = ToolRunner.run(new ConfigurationPrinter(), args);
    System.exit(exitCode);
  }
}
```

`ConfigurationPrinter` to klasa pochodna od `Configured` (która implementuje interfejs `Configurable`). Wszystkie implementacje interfejsu `Tool` muszą też implementować interfejs `Configurable`, ponieważ `Tool` to interfejs pochodny od `Configurable`. Utworzenie klasy pochodnej od `Configured` to często najłatwiejszy sposób na zrealizowanie tego wymogu. Metoda `run()` pobiera obiekt typu `Configuration` za pomocą metody `getConf()` z interfejsu `Configurable`, a następnie przechodzi po tym obiekcie i wyświetla każdą właściwość w standardowym wyjściu.

Statyczny blok gwarantuje, że oprócz podstawowych ustawień (znanych już obiektowi klasy `Configuration`) pobrane zostaną konfiguracje systemów HDFS i YARN oraz modelu MapReduce.

Metoda `main()` klasy `ConfigurationPrinter` nie wywołuje bezpośrednio własnej metody `run()`. Zamiast tego uruchamia statyczną metodę `run()` klasy `ToolRunner`, która przed wywołaniem tej metody tworzy obiekt typu `Configuration` na potrzeby interfejsu `Tool`. Klasa `ToolRunner` używa klasy

Kup książkę Poleć książkę

`GenericOptionsParser` do pobierania standardowych opcji z wiersza poleceń i ustawiania ich w obiekcie klasy `Configuration`. Efekt pobrania właściwości podanych w pliku *conf/hadoop-localhost.xml* można zobaczyć dzięki uruchomieniu poniższych instrukcji.

```
% mvn compile
% export HADOOP_CLASSPATH=target/classes/
% hadoop ConfigurationPrinter -conf conf/hadoop-localhost.xml \
  | grep yarn.resourcemanager.address=
yarn.resourcemanager.address=localhost:8032
```

Które właściwości programista może ustawić?

Klasa `ConfigurationPrinter` to przydatne narzędzie do wykrywania, która właściwość jest ustawiona w środowisku. Konfigurację działającego demona (na przykład węzła nazw) można zobaczyć na stronie */conf* serwera WWW. Numery portów znajdziesz w tabeli 10.6.

Aby zobaczyć domyślne ustawienia wszystkich publicznych właściwości Hadoopa, otwórz katalog *share/doc* w instalacji Hadoopa i poszukaj plików *core-default.xml*, *hdfs-default.xml*, *yarn-default.xml* i *mapred-default.xml*. Każda właściwość ma opis wyjaśniający, do czego służy i jakie wartości przyjmuje.

Dokumentację plików z ustawieniami domyślnymi znajdziesz w internecie na stronach podanych pod adresem *http://hadoop.apache.org/docs/current/* (poszukaj opcji *Configuration* w nawigacji). By uzyskać szczegółowe informacje o konkretnej wersji Hadoopa, zastąp słowo *current* w podanym adresie URL członem *r<wersja>*, na przykład *http://hadoop.apache.org/docs/r2.5.2/*.

Zauważ, że niektóre właściwości nie mają znaczenia, gdy są ustawione w konfiguracji klienta. Na przykład jeśli przy przesyłaniu zadania ustawisz właściwość `yarn.nodemanager.resource.memory-mb` w oczekiwaniu, że zmieni to ilość pamięci dostępnej menedżerom węzłów wykonujących zadanie, zawiedziesz się, ponieważ ta właściwość jest uwzględniana tylko wtedy, jeżeli ustawiono ją w pliku *yarn-site.xml* menedżera węzła. Zwykle można określić docelowy komponent właściwości na podstawie jej nazwy. Ponieważ nazwa `yarn.nodemanager.resource.memory-mb` rozpoczyna się od członu `yarn.nodemanager`, można się domyślić, że tę właściwość można ustawić tylko dla demona menedżera węzła. Jednak ta reguła nie zawsze się sprawdza, dlatego czasem będziesz musiał posłużyć się metodą prób i błędów lub nawet zajrzeć do kodu źródłowego.

Od wersji Hadoop 2 zmieniono nazwy właściwości konfiguracyjnych na bardziej jednolite. Na przykład właściwości systemu HDFS związane z węzłem nazw mają obecnie przedrostek `dfs.namenode`, dlatego dawna właściwość `dfs.name.dir` to teraz `dfs.namenode.name.dir`. Podobnie właściwości dotyczące modelu MapReduce otrzymały przedrostek `mapreduce` zamiast dawnego przedrostka `mapred`. Dlatego poprzednia nazwa `mapred.job.name` to obecnie `mapreduce.job.name`.

W tej książce używane są nowe nazwy właściwości, co pozwala uniknąć ostrzeżeń o stosowaniu przestarzałych nazw. Dawne nazwy właściwości są jednak wciąż dozwolone i często pojawiają się w starszej dokumentacji. Listę przestarzałych nazw właściwości i ich nowych odpowiedników znajdziesz w witrynie Hadoopa (*http://hadoop.apache.org/docs/current/hadoop-project-dist/hadoop-common/DeprecatedProperties.html*).

W tej książce opisano wiele spośród najważniejszych właściwości konfiguracyjnych Hadoopa.

Klasa `GenericOptionsParser` umożliwia też ustawianie pojedynczych właściwości. Oto przykład:

```
% hadoop ConfigurationPrinter -D color=yellow | grep color
color=yellow
```


Kup książkę Poleć książkę

Tu opcja `-D` jest używana do ustawienia właściwości konfiguracyjnej o kluczu `color` na wartość `yellow`. Ustawienia podane za pomocą opcji `-D` są traktowane priorytetowo względem właściwości z plików konfiguracyjnych. Jest to bardzo przydatne, ponieważ można zapisać w plikach konfiguracyjnych wartości domyślne, a następnie zastępować je za pomocą opcji `-D`. Przykładem jest ustawianie liczby reduktorów dla zadania w modelu MapReduce za pomocą opcji `-D mapreduce.job.`
`↪reduces=n`. Powoduje to zmianę liczby reduktorów ustawionej w klastrze lub w plikach konfiguracyjnych po stronie klienta.

Inne opcje obsługiwane przez klasy `GenericOptionsParser` i `ToolRunner` są wymienione w tabeli 6.1. Więcej informacji o konfiguracyjnym interfejsie API Hadoopa zawiera punkt „API do obsługi konfiguracji".

Tabela 6.1. Opcje dla klas GenericOptionsParser i ToolRunner

Opcja	Opis
`-D` *`właściwość=wartość`*	Ustawia właściwość konfiguracyjną Hadoopa na podaną wartość. Zastępuje konfiguracyjne właściwości domyślne i właściwości witryny, a także właściwości ustawione za pomocą opcji `-conf`.
`-conf` *`nazwa_pliku`* …	Dodaje wskazane pliki do listy zasobów konfiguracyjnych. Jest to wygodny sposób ustawiania właściwości na poziomie witryny lub jednoczesnego określania wielu właściwości.
`-fs` *`uri`*	Ustawia domyślny system plików na podany identyfikator URI. To skrótowy zapis instrukcji `-D fs.defaultFS=`*`uri`*.
`-jt` *`host:port`*	Ustawia menedżera zasobów systemu YARN na określone hosta i port. W Hadoopie 1 instrukcja ustawia adres jobtrackera, stąd jej nazwa. To skrótowy zapis polecenia `-D yarn.resourcemanager.address=`*`host:port`*.
`-files` *`plik1,plik2`*,…	Kopiuje wskazane pliki z lokalnego systemu plików (lub dowolnego systemu plików, jeśli określony jest schemat) do współużytkowanego systemu plików, z którego korzysta platforma MapReduce (zwykle jest to system HDFS). Te pliki są udostępniane programom w modelu MapReduce w katalogu roboczym zadania. Więcej o mechanizmie rozproszonej pamięci podręcznej w kontekście kopiowania plików do maszyn z klastra dowiesz się z punktu „Rozproszona pamięć podręczna" w rozdziale 9.
`-archives` *`archiwum1,archiwum2`*,…	Kopiuje wskazane archiwa z lokalnego systemu plików (lub dowolnego systemu plików, jeśli określony jest schemat) do współużytkowanego systemu plików, z którego korzysta platforma MapReduce (zwykle jest to system HDFS), wypakowuje je i udostępnia programom w modelu MapReduce w katalogu roboczym zadania.
`-libjars` *`jar1,jar2`*,…	Kopiuje wskazane pliki JAR z lokalnego systemu plików (lub dowolnego systemu plików, jeśli określony jest schemat) do współużytkowanego systemu plików, z którego korzysta platforma MapReduce (zwykle jest to system HDFS), i dodaje je do ścieżki do klas zadania w modelu MapReduce. Ta opcja to przydatny sposób przesyłania plików JAR potrzebnych zadaniu.

Nie pomyl ustawiania właściwości Hadoopa za pomocą opcji `–D` *`właściwość=wartość`* na potrzeby klas `GenericOptionsParser` i `ToolRunner` z ustawianiem właściwości systemowych maszyny JVM przy użyciu opcji `–D`*`właściwość=wartość`* w instrukcji `java`. Składnia właściwości systemowych maszyny JVM nie zezwala na używanie spacji między literą `D` a nazwą właściwości, natomiast przy podawaniu właściwości dla klasy `GenericOptionsParser` spacja jest dopuszczalna.

Właściwości systemowe maszyny JVM są pobierane z klasy `java.lang.System`, przy czym właściwości Hadoopa są dostępne tylko za pomocą obiektu typu `Configuration`. Dlatego choć właściwość systemowa `color` została ustawiona (za pomocą zmiennej

Kup książkę Poleć książkę

HADOOP_OPTS), poniższa instrukcja nic nie wyświetla, ponieważ klasa Configuration ↪Printer nie używa klasy System.

```
% HADOOP_OPTS='-Dcolor=yellow' \
  hadoop ConfigurationPrinter | grep color
```

Jeśli chcesz mieć możliwość ustawiania konfiguracji za pomocą właściwości systemowych, musisz umieścić potrzebne z nich w pliku konfiguracyjnym. Więcej dowiesz się z punktu „Podstawianie wartości zmiennych”.

Pisanie testów jednostkowych za pomocą biblioteki MRUnit

Funkcje mapująca i redukująca z modelu MapReduce są łatwe do testowania w izolacji. Wynika to z natury funkcji. MRUnit (*https://mrunit.apache.org/*) to biblioteka do obsługi testów, która ułatwia przekazywanie znanych danych wejściowych do mappera lub reduktora i sprawdzanie, czy dane wyjściowe są zgodne z oczekiwaniami. Biblioteka MRUnit jest używana razem ze standardowymi platformami testowymi (takimi jak JUnit), dlatego można przeprowadzać testy zadań w modelu MapReduce w środowisku programowania. Na przykład wszystkie testy opisane w tym miejscu można uruchomić w środowisku IDE na podstawie instrukcji z punktu „Przygotowywanie środowiska programowania”.

Mapper

Test mappera jest przedstawiony na listingu 6.5.

Listing 6.5. Test jednostkowy klasy MaxTemperatureMapper

```
import java.io.IOException;
import org.apache.hadoop.io.*;
import org.apache.hadoop.mrunit.mapreduce.MapDriver;
import org.junit.*;

public class MaxTemperatureMapperTest {

  @Test
  public void processesValidRecord() throws IOException, InterruptedException {
    Text value = new Text("0043011990999991950051518004+68750+023550FM-12+0382" +
                                                    // Rok ^^^^
        "99999V0203201N00261220001CN9999999N9-00111+99999999999");
                                                 // Temperatura ^^^^^
    new MapDriver<LongWritable, Text, Text, IntWritable>()
      .withMapper(new MaxTemperatureMapper())
      .withInput(new LongWritable(0), value)
      .withOutput(new Text("1950"), new IntWritable(-11))
      .runTest();
  }
}
```

Ten test jest oparty na bardzo prostym pomyśle — należy przekazać rekord z danymi o pogodzie jako dane wejściowe dla mappera i sprawdzić, czy dane wyjściowe to rok i temperatura.

Ponieważ testowany jest mapper, używana jest klasa MapDriver z biblioteki MRUnit. Do tej klasy trzeba przekazać testowany mapper (MaxTemperatureMapper), wejściowe klucz i wartość, a także oczekiwane wyjściowe klucz (obiekt typu Text reprezentujący rok 1950) i wartość (obiekt typu

Kup książkę Poleć książkę

`IntWritable` reprezentujący temperaturę –1,1°C). Na koniec można wywołać metodę `runTest()`, aby przeprowadzić test. Jeśli mapper nie zwraca oczekiwanych danych wyjściowych, biblioteka MRUnit zgłasza niepowodzenie testu. Zauważ, że klucz wejściowy można ustawić na dowolną wartość, ponieważ przedstawiony mapper go ignoruje.

W sposób typowy dla programowania sterowanego testami można następnie utworzyć wersję klasy `Mapper`, która przejdzie test (zobacz listing 6.6). Ponieważ pokazywane klasy są w tym rozdziale stopniowo modyfikowane, każda jest umieszczona w innym pakiecie określającym jej wersję, co ułatwia prezentację kodu. Na przykład `v1.MaxTemperatureMapper` to pierwsza wersja klasy `MaxTemperatureMapper`. Oczywiście w praktyce przy modyfikowaniu klas nie umieszcza się ich w odrębnych pakietach.

Listing 6.6. Pierwsza wersja mappera przechodząca test MaxTemperatureMapperTest

```
public class MaxTemperatureMapper
    extends Mapper<LongWritable, Text, Text, IntWritable> {

  @Override
  public void map(LongWritable key, Text value, Context context)
      throws IOException, InterruptedException {

    String line = value.toString();
    String year = line.substring(15, 19);
    int airTemperature = Integer.parseInt(line.substring(87, 92));
    context.write(new Text(year), new IntWritable(airTemperature));
  }
}
```

To bardzo prosta implementacja, która pobiera pola z rokiem i temperaturą z wiersza i zapisuje je w obiekcie typu `Context`. Dodajmy teraz wykrywanie brakujących wartości, które w surowych danych są reprezentowane jako temperatura `+9999`.

```
@Test
public void ignoresMissingTemperatureRecord() throws IOException,
    InterruptedException {
  Text value = new Text("0043011990999991950051518004+68750+023550FM-12+0382" +
                                // Rok ^^^^
      "99999V0203201N00261220001CN9999999N9+99991+99999999999");
                            // Temperatura ^^^^^
  new MapDriver<LongWritable, Text, Text, IntWritable>()
    .withMapper(new MaxTemperatureMapper())
    .withInput(new LongWritable(0), value)
    .runTest();
}
```

Klasę `MapDriver` można wykorzystać do wykrywania zera, jednego lub większej liczby rekordów wyjściowych — zgodnie z liczbą wywołań metody `withOutput()`. W tej aplikacji rekordy, w których brakuje temperatury, są pomijane, dlatego test sprawdza, czy dla konkretnej wartości wejściowej rzeczywiście nie są zwracane żadne dane wyjściowe.

Nowy test kończy się niepowodzeniem, ponieważ wartość `+9999` nie jest traktowana jak specjalny przypadek. Zamiast dodawać kolejne linie kodu do mappera, można utworzyć odrębną klasę parsera i umieścić w niej kod odpowiedzialny za parsowanie, co przedstawia listing 6.7.

Kup książkę Poleć książkę

Listing 6.7. Klasa do parsowania rekordów z danymi o pogodzie w formacie organizacji NCDC

```
public class NcdcRecordParser {

  private static final int MISSING_TEMPERATURE = 9999;

  private String year;
  private int airTemperature;
  private String quality;

  public void parse(String record) {
    year = record.substring(15, 19);
    String airTemperatureString;
    // Usuwanie początkowego znaku plus, ponieważ metoda parseInt źle sobie z nim radzi (w wersjach sprzed Javy 7)
    if (record.charAt(87) == '+') {
      airTemperatureString = record.substring(88, 92);
    } else {
      airTemperatureString = record.substring(87, 92);
    }
    airTemperature = Integer.parseInt(airTemperatureString);
    quality = record.substring(92, 93);
  }

  public void parse(Text record) {
    parse(record.toString());
  }

  public boolean isValidTemperature() {
    return airTemperature != MISSING_TEMPERATURE && quality.matches("[01459]");
  }

  public String getYear() {
    return year;
  }

  public int getAirTemperature() {
    return airTemperature;
  }
}
```

Wynikowy mapper (wersja 2.) jest znacznie prostszy (zobacz listing 6.8). Wywołuje jedynie metodę `parse()` parsera (która parsuje potrzebne pola z wiersza danych wejściowych), za pomocą metody `isValidTemperature()` sprawdza, czy znaleziono prawidłową temperaturę, i jeśli tak się stało, pobiera rok i temperaturę za pomocą getterów parsera. Zauważ, że za sprawdzanie wartości pola stanu i wykrywanie braku temperatury odpowiada metoda `isValidTemperature()`, pozwalająca odfiltrować nieprawidłowe odczyty temperatury.

Inną korzyścią wynikającą z utworzenia klasy parsera jest to, że pozwala ona na łatwe napisanie powiązanych mapperów dla podobnych zadań bez konieczności duplikowania kodu. Ponadto można pisać testy jednostkowe bezpośrednio dla parsera, dzięki czemu są one bardziej precyzyjne.

Listing 6.8. Mapper używający klasy narzędziowej do parsowania rekordów

```
public class MaxTemperatureMapper
    extends Mapper<LongWritable, Text, Text, IntWritable> {

  private NcdcRecordParser parser = new NcdcRecordParser();
```


Kup książkę Poleć książkę

```
  @Override
  public void map(LongWritable key, Text value, Context context)
      throws IOException, InterruptedException {

    parser.parse(value);
    if (parser.isValidTemperature()) {
      context.write(new Text(parser.getYear()),
          new IntWritable(parser.getAirTemperature()));
    }
  }
}
```

Testy mappera kończą się już powodzeniem, można więc przejść do pisania reduktora.

Reduktor

Reduktor ma znajdować maksymalną wartość dla danego klucza. Oto prosty test tego mechanizmu. Wykorzystano tu klasę `ReduceDriver`.

```
@Test
public void returnsMaximumIntegerInValues() throws IOException,
    InterruptedException {
  new ReduceDriver<Text, IntWritable, Text, IntWritable>()
    .withReducer(new MaxTemperatureReducer())
    .withInput(new Text("1950"),
        Arrays.asList(new IntWritable(10), new IntWritable(5)))
    .withOutput(new Text("1950"), new IntWritable(10))
    .runTest();
}
```

Kod tworzy listę wartości typu `IntWritable`, a następnie sprawdza, czy klasa `MaxTemperatureReducer` wybrała największą liczbę. Kod z listingu 6.9 to implementacja klasy `MaxTemperatureReducer` przechodzącej test.

Listing 6.9. Reduktor z przykładu dotyczącego wyszukiwania maksymalnej temperatury

```
public class MaxTemperatureReducer
    extends Reducer<Text, IntWritable, Text, IntWritable> {

  @Override
  public void reduce(Text key, Iterable<IntWritable> values, Context context)
      throws IOException, InterruptedException {

    int maxValue = Integer.MIN_VALUE;
    for (IntWritable value : values) {
      maxValue = Math.max(maxValue, value.get());
    }
    context.write(key, new IntWritable(maxValue));
  }
}
```

Uruchamianie kodu lokalnie na danych testowych

Skoro mapper i reduktor działają już dla kontrolowanych danych wejściowych, następny krok polega na napisaniu sterownika zadania i uruchomieniu go na danych testowych na maszynie programisty.

Kup książkę Poleć książkę

Uruchamianie zadania w lokalnym mechanizmie wykonywania zadań

Za pomocą przedstawionego wcześniej w rozdziale interfejsu `Tool` łatwo jest napisać sterownik do wykonywania w modelu MapReduce zadania wyszukującego maksymalną temperaturę z poszczególnych lat (zobacz klasę `MaxTemperatureDriver` na listingu 6.10).

Listing 6.10. Aplikacja do wyszukiwania maksymalnej temperatury

```
public class MaxTemperatureDriver extends Configured implements Tool {

  @Override
  public int run(String[] args) throws Exception {
    if (args.length != 2) {
      System.err.printf("Użytkowanie: %s [ogólne opcje] <wejście> <wyjście>\n",
          getClass().getSimpleName());
      ToolRunner.printGenericCommandUsage(System.err);
      return -1;
    }

    Job job = new Job(getConf(), "Max temperature");
    job.setJarByClass(getClass());

    FileInputFormat.addInputPath(job, new Path(args[0]));
    FileOutputFormat.setOutputPath(job, new Path(args[1]));

    job.setMapperClass(MaxTemperatureMapper.class);
    job.setCombinerClass(MaxTemperatureReducer.class);
    job.setReducerClass(MaxTemperatureReducer.class);

    job.setOutputKeyClass(Text.class);
    job.setOutputValueClass(IntWritable.class);

    return job.waitForCompletion(true) ? 0 : 1;
  }

  public static void main(String[] args) throws Exception {
    int exitCode = ToolRunner.run(new MaxTemperatureDriver(), args);
    System.exit(exitCode);
  }
}
```

Klasa `MaxTemperatureDriver` implementuje interfejs `Tool`, dzięki czemu można ustawiać opcje obsługiwane przez klasę `GenericOptionsParser`. Metoda `run()` tworzy obiekt typu `Job` na podstawie konfiguracji jednostki używanej do uruchamiania zadania. Spośród dostępnych parametrów konfiguracji zadania ustawiane są ścieżki do plików wejściowego i wyjściowego, klasy mappera, reduktora i mechanizmu łączenia (ang. *combiner*), a także typy wyjściowe (typy wejściowe są ustalane na podstawie formatu wejściowego; domyślnie używany jest format `TextInputFormat` z kluczami typu `LongWritable` i wartościami typu `Text`). Warto też ustawić nazwę zadania (`Max temperature`), co pozwala znaleźć zadanie na liście w trakcie jego wykonywania i po zakończeniu jego pracy. Domyślnie nazwą jest nazwa pliku JAR, która zwykle nie opisuje dobrze zadania.

Teraz można uruchomić aplikację na plikach lokalnych. Hadoop udostępnia lokalny mechanizm wykonywania zadań, który jest uproszczoną wersją silnika wykonawczego modelu MapReduce, przeznaczoną do uruchamiania zadań w jednej maszynie JVM. Ten mechanizm jest zaprojektowany na potrzeby testów i bardzo łatwo używa się go w środowisku IDE, ponieważ można uruchomić go w debugerze, aby w trybie kroczenia przejść przez kod mappera i reduktora.

Kup książkę Poleć książkę

Lokalny mechanizm wykonywania zadań jest używany, gdy właściwość `mapreduce.framework.name` jest ustawiona na wartość `local` (jest to ustawienie domyślne)[1].

Z poziomu wiersza poleceń można uruchomić sterownik w następujący sposób:

```
% mvn compile
% export HADOOP_CLASSPATH=target/classes/
% hadoop v2.MaxTemperatureDriver -conf conf/hadoop-local.xml \
  input/ncdc/micro output
```

Inna możliwość to zastosowanie opcji `-fs` i `-jt` udostępnianych przez klasę `GenericOptionsParser`.

```
% hadoop v2.MaxTemperatureDriver -fs file:/// -jt local input/ncdc/micro output
```

Ta instrukcja uruchamia sterownik `MaxTemperatureDriver` z wykorzystaniem danych wejściowych z lokalnego katalogu *input/ncdc/micro* i generuje dane wyjściowe w lokalnym katalogu *output*. Zauważ, że choć ustawiona jest opcja `-fs` i używany jest lokalny system plików (`file:///`), lokalny mechanizm wykonywania zadań działa poprawnie dla dowolnego systemu plików, w tym dla systemu HDFS (jest to wygodne, jeśli przechowujesz w nim sporo plików).

Następnie można sprawdzić dane wyjściowe w lokalnym systemie plików:

```
% cat output/part-r-00000
1949 111
1950 22
```

Testowanie sterownika

Zaimplementowanie w aplikacji interfejsu `Tool` zwiększa możliwości w zakresie opcji konfiguracyjnych, a ponadto ułatwia testowanie, ponieważ pozwala wstrzyknąć dowolny obiekt typu `Configuration`. Możesz to wykorzystać do napisania testu, który używa lokalnego mechanizmu wykonywania zadania na znanych danych wejściowych i sprawdza, czy dane wyjściowe są zgodne z oczekiwaniami.

Rozwiązanie można przygotować na dwa sposoby. Pierwszy polega na użyciu lokalnego mechanizmu do uruchomienia zadania na pliku testowym w lokalnym systemie plików. Kod z listingu 6.11 pokazuje, jak to zrobić.

Listing 6.11. Test sterownika MaxTemperatureDriver z wykorzystaniem lokalnego, wewnątrzprocesowego mechanizmu wykonywania zadań

```
@Test
public void test() throws Exception {
  Configuration conf = new Configuration();
  conf.set("fs.defaultFS", "file:///");
  conf.set("mapreduce.framework.name", "local");
  conf.setInt("mapreduce.task.io.sort.mb", 1);

  Path input = new Path("input/ncdc/micro");
  Path output = new Path("output");

  FileSystem fs = FileSystem.getLocal(conf);
  fs.delete(output, true); // Usuwanie dawnych danych wyjściowych

  MaxTemperatureDriver driver = new MaxTemperatureDriver();
```

[1] W Hadoopie 1 sposób wykonywania określa właściwość `mapred.job.tracker`. Wartość `local` oznacza użycie lokalnego mechanizmu wykonywania zadań, a rozdzielona przecinkiem para host-port pozwala podać adres jobtrackera.

Kup książkę Poleć książkę

```
    driver.setConf(conf);

    int exitCode = driver.run(new String[] {
        input.toString(), output.toString() });
    assertThat(exitCode, is(0));

    checkOutput(conf, output);
  }
```

Test bezpośrednio ustawia opcje `fs.defaultFS` i `mapreduce.framework.name`, co oznacza, że używany jest lokalny system plików i mechanizm wykonywania zadań. Następnie test uruchamia sterownik `MaxTemperatureDriver` za pomocą interfejsu `Tool` na małym zbiorze znanych danych. W końcowej części testu wywoływana jest metoda `checkOutput()` w celu porównania wiersz po wierszu rzeczywistych danych wyjściowych z oczekiwanymi.

Drugi sposób testowania sterownika polega na uruchomieniu go za pomocą miniklastra. Hadoop udostępnia zestaw klas testowych `MiniDFSCluster`, `MiniMRCluster` i `MiniYARNCluster`, które umożliwiają programowe tworzenie klastrów wewnątrzprocesowych. W odróżnieniu od lokalnego mechanizmu wykonywania zadań te klasy pozwalają na przeprowadzanie testów z użyciem kompletnych systemów HDFS, MapReduce i YARN. Pamiętaj też, że menedżery węzłów w miniklastrach uruchamiają odrębne maszyny JVM do wykonywania zadań, co utrudnia debugowanie.

Miniklaster możesz też uruchomić z poziomu wiersza poleceń za pomocą następującej instrukcji:

```
% hadoop jar \
  $HADOOP_HOME/share/hadoop/mapreduce/hadoop-mapreduce-*-tests.jar \
  minicluster
```

Miniklastry są często używane w zautomatyzowanych pakietach testów Hadoopa, można je jednak stosować także do testowania kodu użytkowników. Klasa abstrakcyjna `ClusterMapReduceTestCase` Hadoopa to użyteczny punkt wyjścia do pisania takich testów. Ta klasa obsługuje uruchamianie (metoda `setUp()`) i zatrzymywanie (metoda `tearDown()`) wewnątrzprocesowych klastrów z systemami HDFS i YARN oraz generuje odpowiedni obiekt typu `Configuration` dostosowany do współpracy z takimi klastrami. W podklasach trzeba tylko umieścić dane w systemie HDFS (na przykład w wyniku skopiowania ich z lokalnego pliku), uruchomić zadanie w modelu MapReduce i sprawdzić, czy dane wyjściowe są zgodne z oczekiwanymi. Przykładowy kod znajdziesz w klasie `MaxTemperature`
`↪DriverMiniTest` dostępnej w plikach dołączonych do książki.

Tego rodzaju testy są używane w testach regresyjnych i stanowią przydatne repozytorium przypadków brzegowych w danych wejściowych razem z oczekiwanymi dla nich wynikami. Gdy natrafisz na kolejne przypadki testowe, wystarczy, że dodasz je do pliku wejściowego i odpowiednio zaktualizujesz plik z oczekiwanymi danymi wyjściowymi.

Uruchamianie programów w klastrze

Gdy już jesteś zadowolony z działania programu dla małego testowego zbioru danych, możesz wypróbować kod na pełnym zbiorze danych w klastrze Hadoopa. Opis budowania w pełni rozproszonego klastra znajdziesz w rozdziale 10. Możesz też wykorzystać informacje z tego punktu i utworzyć pseudorozproszony klaster.

Kup książkę Poleć książkę

Tworzenie pakietu z zadaniem

Lokalny mechanizm wykonywania zadań używa jednej maszyny JVM do wykonywania zadania. Dlatego jeśli wszystkie klasy potrzebne w zadaniu są dostępne w ścieżce do klas, rozwiązanie będzie działać.

W środowisku rozproszonym sytuacja się komplikuje. Klasy zadania trzeba umieścić w *pliku JAR zadania* umieszczanym w klastrze. Hadoop automatycznie znajduje ten plik, wyszukując pliki JAR na podstawie ścieżki do klas sterownika zawierającej klasę ustawioną w metodzie `setJarByClass()` (klasy `JobConf` lub `Job`). Inna możliwość to ustawienie pliku JAR bezpośrednio za pomocą ścieżki do pliku, do czego służy metoda `setJar()`. Ścieżka do pliku JAR może prowadzić do lokalnego systemu plików lub systemu HDFS.

Do tworzenia pliku JAR można wykorzystać wygodne narzędzie do budowania, takie jak Ant lub Maven. Na podstawie pliku POM przedstawionego na listingu 6.3 poniższa instrukcja utworzy w katalogu projektu plik JAR *hadoop-examples.jar* zawierający wszystkie skompilowane klasy.

```
% mvn package -DskipTests
```

Jeśli każdemu zadaniu odpowiada plik JAR, można wskazać przeznaczoną do uruchomienia główną klasę w manifeście pliku JAR. Jeżeli główna klasa nie jest wskazana w manifeście, trzeba ją ustawić w wierszu poleceń (wkrótce w kontekście uruchamiania zadania zobaczysz, jak to zrobić).

Pliki JAR z zależnościami można umieścić w podkatalogu *lib* pliku JAR zadania, przy czym istnieją też inne, opisane dalej sposoby dodawania zależności. Podobnie pliki zasobów można zapisać w podkatalogu *classes* (to rozwiązanie przypomina pliki WAR — ang. *Web application archive* — Javy, przy czym pliki JAR trafiają w nich do podkatalogu *WEB-INF/lib*, a klasy do podkatalogu *WEB-INF/classes*).

Ścieżka do klas po stronie klienta

Ścieżka do klas po stronie klienta ustawiana przez polecenie `hadoop jar <jar>` obejmuje następujące elementy:

- plik JAR zadania,
- pliki JAR z katalogu *lib* z pliku JAR zadania oraz katalog *classes* (jeśli istnieje),
- zawartość zmiennej `HADOOP_CLASSPATH` (jeżeli jest ustawiona).

To wyjaśnia, dlaczego w zmiennej `HADOOP_CLASSPATH` trzeba wskazać klasy i biblioteki z zależnościami, jeśli używany jest lokalny mechanizm uruchamiania zadań bez pliku JAR zadania (wywołanie `hadoop NAZWA_KLASY`).

Ścieżka do klas dla operacji

W klastrze (dotyczy to także trybu pseudorozproszonego) operacje mapowania i redukowania działają w odrębnych maszynach JVM. Ścieżki do klas tych operacji *nie* są kontrolowane za pomocą zmiennej `HADOOP_CLASSPATH`. `HADOOP_CLASSPATH` to ustawienie używane po stronie klienta, określające tylko ścieżkę do klas maszyny JVM sterownika, która zgłasza zadanie.

Kup książkę Poleć książkę

Ścieżka do klas operacji użytkownika obejmuje następujące elementy:

- plik JAR zadania,
- pliki JAR z katalogu *lib* z pliku JAR zadania oraz katalog *classes* (jeśli istnieje),
- pliki dodane do rozproszonej pamięci podręcznej za pomocą opcji `-libjars` (zobacz tabelę 6.1) lub metody `addFileToClassPath()` klasy `DistributedCache` (w dawnym interfejsie API) albo `Job` (w nowym interfejsie API).

Dodawanie zależności do pakietu

Ponieważ istnieją różne sposoby kontrolowania zawartości ścieżki do klas klientów i operacji, dostępne są też odpowiednie techniki dołączania zależności bibliotecznych dla zadań. Możesz:

- wypakować biblioteki i dodać je do pliku JAR zadania,
- umieścić biblioteki w katalogu *lib* pliku JAR zadania,
- przechowywać biblioteki niezależnie od pliku JAR zadania i dodawać je do ścieżki do klas klienta za pomocą zmiennej `HADOOP_CLASSPATH` i do ścieżki do klas operacji przy użyciu opcji `-libjars`.

Ostatnie rozwiązanie, wykorzystanie rozproszonej pamięci podręcznej, jest najprostsze, jeśli chodzi o budowanie, ponieważ zależności nie trzeba dodawać do pliku JAR zadania. Ponadto użycie rozproszonej pamięci podręcznej może oznaczać mniej operacji przenoszenia plików JAR w klastrze, ponieważ pliki między operacjami można przechowywać w pamięci podręcznej w węźle.

Kolejność uwzględniania ścieżek do klas operacji

Pliki JAR użytkownika są dodawane na koniec ścieżek do klas klienta i operacji. W niektórych sytuacjach powoduje to konflikt zależności z wbudowanymi bibliotekami Hadoopa, jeśli Hadoop korzysta z innej, niezgodnej wersji biblioteki używanej w kodzie. Czasem potrzebna jest możliwość kontrolowania kolejności elementów w ścieżce do klas operacji, tak aby potrzebne klasy były wybierane jako pierwsze. Po stronie klienta można wymusić na Hadoopie umieszczenie na początku ścieżki do klas użytkownika. Aby to zrobić, ustaw zmienną środowiskową `HADOOP_USER_CLASSPATH_FIRST` na wartość `true`. Natomiast by na początku wybierana była ścieżka do klas operacji, na wartość `true` należy ustawić właściwość `mapreduce.job.user.classpath.first`. Zauważ, że ustawienie tych opcji powoduje zmianę kolejności wczytywanych klas z zależnościami platformy Hadoop (ale tylko w danym zadaniu). Potencjalnie może to spowodować błąd przesyłania zadania lub wykonywania operacji, dlatego zachowaj ostrożność przy stosowaniu tych opcji.

Uruchamianie zadania

Aby wywołać zadanie, należy uruchomić sterownik, wskazując przy tym za pomocą opcji `-conf` klaster, w którym zadanie ma działać (można też zastosować opcje `-fs` i `-jt`).

```
% unset HADOOP_CLASSPATH
% hadoop jar hadoop-examples.jar v2.MaxTemperatureDriver \
  -conf conf/hadoop-cluster.xml input/ncdc/all max-temp
```


Kup książkę Poleć książkę

Zmienna środowiskowa `HADOOP_CLASSPATH` jest zerowana, ponieważ dla tego zadania nie są używane żadne niestandardowe zależności. Gdyby zmienna pozostała ustawiona na wartość `target/classes/` (tę wartość dodano wcześniej w rozdziale), Hadoop nie znalazłby pliku JAR z zadaniem. Wczytałby klasę `MaxTemperatureDriver` z katalogu *target/classes* zamiast z pliku JAR, przez co zadanie zakończyłoby się niepowodzeniem.

Metoda `waitForCompletion()` klasy `Job` uruchamia zadanie i sprawdza jego postęp. Gdy w operacji mapowania lub redukowania zachodzą zmiany, wspomniana metoda wyświetla informacje na ten temat. Oto dane wyjściowe (część wierszy w celu zachowania przejrzystości usunięto).

```
14/09/12 06:38:11 INFO input.FileInputFormat: Total input paths to process : 101
14/09/12 06:38:11 INFO impl.YarnClientImpl: Submitted application
application_1410450250506_0003
14/09/12 06:38:12 INFO mapreduce.Job: Running job: job_1410450250506_0003
14/09/12 06:38:26 INFO mapreduce.Job:  map 0% reduce 0%
...
14/09/12 06:45:24 INFO mapreduce.Job:  map 100% reduce 100%
14/09/12 06:45:24 INFO mapreduce.Job: Job job_1410450250506_0003 completed
successfully
14/09/12 06:45:24 INFO mapreduce.Job: Counters: 49
    File System Counters
        FILE: Number of bytes read=93995
        FILE: Number of bytes written=10273563
        FILE: Number of read operations=0
        FILE: Number of large read operations=0
        FILE: Number of write operations=0
        HDFS: Number of bytes read=33485855415
        HDFS: Number of bytes written=904
        HDFS: Number of read operations=327
        HDFS: Number of large read operations=0
        HDFS: Number of write operations=16
    Job Counters
        Launched map tasks=101
        Launched reduce tasks=8
        Data-local map tasks=101
        Total time spent by all maps in occupied slots (ms)=5954495
        Total time spent by all reduces in occupied slots (ms)=74934
        Total time spent by all map tasks (ms)=5954495
        Total time spent by all reduce tasks (ms)=74934
        Total vcore-seconds taken by all map tasks=5954495
        Total vcore-seconds taken by all reduce tasks=74934
        Total megabyte-seconds taken by all map tasks=6097402880
        Total megabyte-seconds taken by all reduce tasks=76732416
    Map-Reduce Framework
        Map input records=1209901509
        Map output records=1143764653
        Map output bytes=10293881877
        Map output materialized bytes=14193
        Input split bytes=14140
        Combine input records=1143764772
        Combine output records=234
        Reduce input groups=100
        Reduce shuffle bytes=14193
        Reduce input records=115
        Reduce output records=100
        Spilled Records=379
        Shuffled Maps =808
        Failed Shuffles=0
        Merged Map outputs=808
        GC time elapsed (ms)=101080
```


Kup książkę Poleć książkę

```
        CPU time spent (ms)=5113180
        Physical memory (bytes) snapshot=60509106176
        Virtual memory (bytes) snapshot=167657209856
        Total committed heap usage (bytes)=68220878848
    Shuffle Errors
        BAD_ID=0
        CONNECTION=0
        IO_ERROR=0
        WRONG_LENGTH=0
        WRONG_MAP=0
        WRONG_REDUCE=0
    File Input Format Counters
        Bytes Read=33485841275
    File Output Format Counters
        Bytes Written=90
```

Te dane wyjściowe obejmują wiele przydatnych informacji. Przed rozpoczęciem zadania wyświetlany jest jego identyfikator. Jest on potrzebny, gdy trzeba wskazać zadanie (na przykład w plikach dziennika) lub przy sprawdzaniu go przy użyciu polecenia `mapred job`. Po zakończeniu pracy zadania wyświetlane są dotyczące go statystyki (nazywane licznikami — `counters`). Są one bardzo przydatne do upewniania się, że zadanie wykonało oczekiwane czynności. Na przykład w pokazanym zadaniu przeanalizowano 1,2 miliarda rekordów (`Map input records`) i wczytano dane z około 34 GB skompresowanych plików z systemu HDFS (`HDFS: Number of bytes read`). Dane wejściowe zostały podzielone na 101 plików w formacie gzip o akceptowalnej wielkości, co oznacza, że nie wystąpiły problemy z ich podziałem.

Więcej o znaczeniu poszczególnych liczników dowiesz się z punktu „Liczniki wbudowane” w rozdziale 9.

Sieciowy interfejs użytkownika modelu MapReduce

Hadoop udostępnia sieciowy interfejs użytkownika do wyświetlania informacji na temat zadań. Jest on przydatny do śledzenia postępów zadań w trakcie ich wykonywania, a także wyszukiwania statystyk i dzienników po zakończeniu pracy przez zadanie. Ten interfejs użytkownika jest dostępny pod adresem *http://resource-manager-host:8088/*.

Strona menedżera zasobów

Zrzut strony głównej jest przedstawiony na rysunku 6.1. Sekcja *Cluster Metrics* zawiera przegląd informacji o klastrze. Obejmują one liczbę aplikacji aktualnie działających w klastrze (oraz aplikacji w innym stanie), ilość dostępnych w klastrze zasobów (*Memory Total*) i informacje o menedżerach węzłów.

W głównej tabeli wymienione są wszystkie aplikacje, które zostały wykonane lub działają w klastrze. Dostępne jest pole wyszukiwania przydatne do filtrowania aplikacji w celu znalezienia potrzebnych. W głównym oknie wyświetlanych jest do 100 pozycji na stronę, a menedżer zasobów przechowuje w pamięci jednocześnie do 10 000 ukończonych aplikacji (tę wartość określa właściwość `yarn.resourcemanager.max-completed-applications`); starsze aplikacje są dostępne tylko na stronie historii zadań. Zauważ, że historia zadań jest trwała, dlatego znajdują się w niej także zadania z poprzednich uruchomień menedżera zasobów.

Kup książkę Poleć książkę

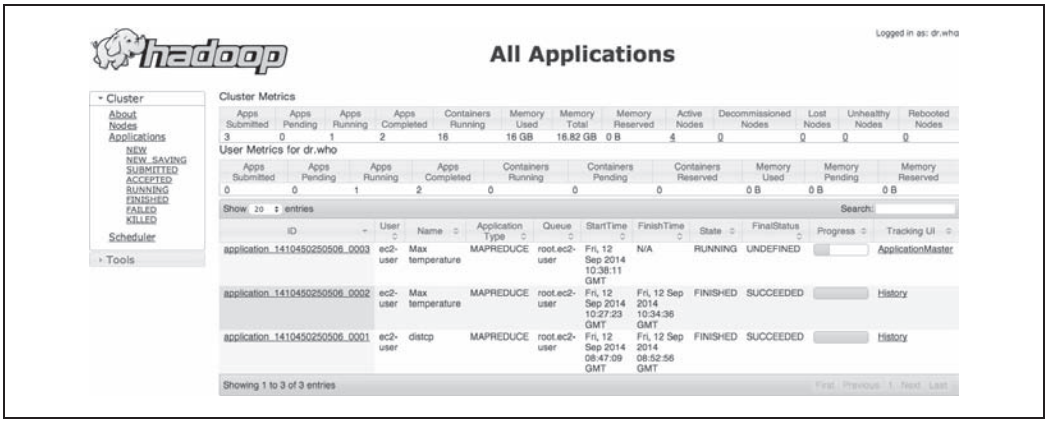

Rysunek 6.1. Zrzut strony menedżera zasobów

Identyfikatory zadania, operacji i prób wykonania operacji

W Hadoopie 2 identyfikatory zadań w modelu MapReduce są generowane na podstawie identyfikatorów aplikacji systemu YARN (te identyfikatory są tworzone przez menedżer zasobów systemu YARN). Identyfikator aplikacji obejmuje czas uruchomienia menedżera zasobów (a nie samej aplikacji) i wartość licznika zwiększaną przez menedżer zasobów. Wartość licznika pozwala w niepowtarzalny sposób identyfikować aplikacje w danym egzemplarzu menedżera zasobów. Oto przykładowy identyfikator aplikacji:

```
application_1410450250506_0003
```

Jest to trzecia (0003; identyfikatory aplikacji rozpoczynają się od wartości 1) aplikacja z danego menedżera zasobów, który rozpoczął pracę w czasie reprezentowanym przez znacznik `1410450250506`. Licznik jest uzupełniany początkowymi zerami, co pozwala na wygodne sortowanie identyfikatorów (na przykład na liście zawartości katalogów). Jednak gdy licznik dojdzie do wartości 10000, *nie* jest resetowany, przez co identyfikatory aplikacji stają się dłuższe. Utrudnia to sortowanie.

Identyfikator zadania jest tworzony w wyniku zastąpienia przedrostka `application` z identyfikatora aplikacji przedrostkiem `job`.

```
job_1410450250506_0003
```

Operacje należą do zadania, a ich identyfikatory są tworzone przez zastąpienie przedrostka `job` w identyfikatorze zadania przedrostkiem `task` i dodanie przyrostka identyfikującego operacje w zadaniu. Oto przykład:

```
task_1410450250506_0003_m_000003
```

Jest to czwarta (000003; identyfikatory operacji są numerowane od 0) operacja mapowania (`m`) w zadaniu o identyfikatorze `job_1410450250506_0003`. Identyfikatory operacji są tworzone dla zadania w momencie ich inicjowania, dlatego nie wyznaczają kolejności wykonywania operacji.

Operacje mogą być wykonywane więcej niż raz, na przykład z powodu błędu (zobacz punkt „Niepowodzenie operacji” w rozdziale 7.) lub spekulacyjnego wykonania (zobacz punkt „Wykonywanie spekulacyjne” w rozdziale 7.). Dlatego aby zidentyfikować różne przypadki wykonania operacji, nadaje się unikatowe identyfikatory próbom wykonania operacji. Oto przykład:

```
attempt_1410450250506_0003_m_000003_0
```

Jest to pierwsza (0; identyfikatory prób wykonania są numerowane od 0) próba uruchomienia operacji `task_1410450250506_0003_m_000003`. Próby wykonania operacji są podejmowane w zależności od potrzeby w trakcie pracy zadania, dlatego ich numery odpowiadają kolejności podejmowania prób.

Kup książkę Poleć książkę

Historia zadań

Historia zadań dotyczy zdarzeń i konfiguracji ukończonych zadań w modelu MapReduce. Jest zachowywana niezależnie od tego, czy zadanie zostało ukończone z powodzeniem, czy nie. Ma zapewniać przydatne informacje użytkownikowi uruchamiającemu zadanie.

Pliki z historią zadań są zapisywane przez zarządcę aplikacji z modelu MapReduce w systemie HDFS w katalogu określonym we właściwości `mapreduce.jobhistory.done-dir`. Pliki historii zadań są przechowywane przez tydzień, po czym są usuwane przez system.

Dziennik z historią obejmuje zdarzenia dotyczące zadań, operacji i prób. Wszystkie te informacje są przechowywane w pliku w formacie JSON. Historię konkretnego zadania można wyświetlić za pomocą sieciowego interfejsu użytkownika serwera historii zadań (odnośnik do niego znajdziesz na stronie menedżera zasobów) lub z poziomu wiersza poleceń przy użyciu instrukcji `mapred job -history` (należy jej wskazać plik z historią zadań).

Strona zadania w modelu MapReduce

Gdy klikniesz odnośnik *Tracking UI*, przejdziesz do sieciowego interfejsu użytkownika zarządcy aplikacji (lub do strony z historią, jeśli aplikacja zakończyła pracę). W modelu MapReduce pojawia się wtedy strona zadania taka jak na rysunku 6.2.

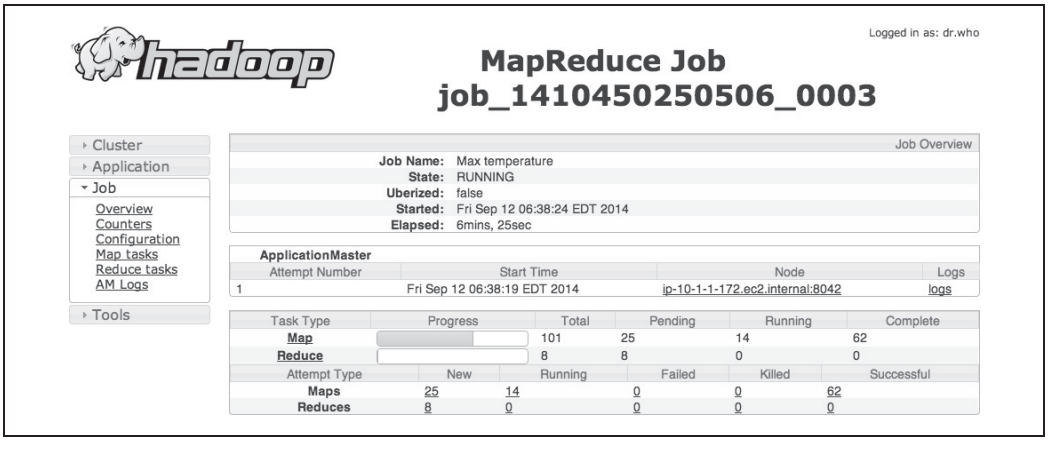

Rysunek 6.2. Zrzuty strony zadania

W trakcie działania zadania można na tej stronie śledzić jego postęp. Tabela w dolnej części strony pokazuje postęp operacji mapowania i redukowania. Kolumna *Total* zawiera łączną liczbę operacji mapowania i redukowania dla danego zadania (dla poszczególnych typów operacji dostępne są odrębne wiersze). Pozostałe kolumny wyświetlają stan operacji — *Pending* (oczekujące na uruchomienie), *Running* (w toku) lub *Complete* (z powodzeniem ukończone).

W dolnej części tabeli widoczna jest łączna liczba nieudanych i zamkniętych prób wykonania operacji mapowania i redukowania. Próby wykonania operacji są oznaczone jako zamknięte, jeśli są duplikatami spekulacyjnych prób wykonania, jeśli ich węzeł przestał działać lub jeśli zostały zamknięte przez użytkownika. Omówienie nieudanych wykonań operacji znajdziesz w punkcie „Niepowodzenie operacji” w rozdziale 7.

Kup książkę Poleć książkę

Ponadto w nawigacji znajduje się wiele przydatnych odnośników. Na przykład odnośnik *Configuration* prowadzi do skonsolidowanego pliku z konfiguracją zadania, zawierającego wszystkie właściwości i ich wartości z czasu wykonywania zadania. Jeśli nie masz pewności, na jaką wartość ustawiona była konkretna właściwość, możesz kliknąć ten odnośnik i sprawdzić wspomniany plik.

Pobieranie wyników

Po zakończeniu wykonywania zadania wyniki można pobrać na kilka sposobów. Każdy reduktor generuje jeden plik wyjściowy. W katalogu *max-temp* pojawia się więc 30 fragmentarycznych plików o nazwach od *part-r-00000* do *part-r-00029*.

Jak wskazuje na to nazwa, fragmentaryczne pliki warto traktować jak fragmenty „pliku" *max-temp*.

Jeśli dane wyjściowe są długie (inaczej niż w omawianym przykładzie), ważne jest używanie wielu fragmentów, dzięki czemu równolegle mogą działać liczne reduktory. Nawet jeśli plik jest podzielony na części, zwykle nadal można z niego łatwo korzystać — na przykład jak z danych wejściowych do innego zadania w modelu MapReduce. W niektórych sytuacjach można wykorzystać strukturę fragmentów do przeprowadzenia złączania na etapie mapowania (zobacz punkt „Złączanie po stronie mapowania" w rozdziale 9.).

Omawiane zadanie generuje bardzo niewielką ilość danych wyjściowych, dlatego można je wygodnie skopiować z systemu HDFS do maszyny programisty. Służy do tego opcja `-getmerge` instrukcji `hadoop fs`, która pobiera wszystkie pliki z katalogu wskazanego za pomocą wzorca wejściowego i scala je w jeden plik w lokalnym systemie plików.

```
% hadoop fs -getmerge max-temp max-temp-local
% sort max-temp-local | tail
1991	607
1992	605
1993	567
1994	568
1995	567
1996	561
1997	565
1998	568
1999	568
2000	558
```

Dane wyjściowe są sortowane, ponieważ fragmenty z danych wyjściowych z etapu redukowania są nieuporządkowane (to efekt działania partycjonującej funkcji skrótu). Przetwarzanie końcowe danych z modelu MapReduce jest bardzo częste, podobnie jak przekazywanie ich do narzędzi analitycznych (takich jak R, arkusze kalkulacyjne, a nawet relacyjne bazy danych).

Inny sposób na pobieranie niewielkich zbiorów danych wyjściowych to użycie opcji `-cat` w celu wyświetlenia plików wyjściowych w konsoli.

```
% hadoop fs -cat max-temp/*
```

Po bliższej analizie okazuje się, że niektóre wyniki wyglądają podejrzanie. Na przykład maksymalna temperatura dla roku 1951 (niepokazana w wynikach) to 590°C! Jak ustalić, co jest tego przyczyną? Czy to efekt błędnych danych wejściowych, czy błędu w programie?

Kup książkę Poleć książkę

Debugowanie zadania

Tradycyjnym sposobem debugowania programów jest używanie instrukcji `print`. Oczywiście w Hadoopie też jest to możliwe. Należy jednak uwzględnić różne komplikacje. Programy działają w dziesiątkach, setkach, a nawet tysiącach węzłów. Jak więc znaleźć i zbadać dane wyjściowe z instrukcji diagnostycznych z rozmaitych węzłów? W omawianym przykładzie szukany jest nietypowy (zdaniem programisty) przypadek. Dlatego można wykorzystać instrukcję diagnostyczną do zarejestrowania informacji w standardowym strumieniu błędów i zaktualizować komunikat o stanie operacji, tak by sugerował zapoznanie się z dziennikiem błędów. Sieciowy interfejs użytkownika pozwala łatwo uzyskać pożądany efekt dzięki przekazaniu odpowiedniego tekstu.

Można też utworzyć niestandardowy licznik określający łączną liczbę rekordów z nierealistycznymi temperaturami w całym zbiorze danych. Zapewnia to cenne informacje na temat tego, jak radzić sobie z takimi danymi. Jeśli się okaże, że błędne temperatury pojawiają się często, konieczne może okazać się sprawdzenie, z czego to wynika, i wymyślenie sposobu na pobieranie temperatury zamiast prostego ignorowania podejrzanych rekordów. W trakcie diagnozowania zadania zawsze należy zadać sobie pytanie, czy można wykorzystać licznik do uzyskania informacji potrzebnych do ustalenia, co się dzieje. Nawet jeśli konieczne są komunikaty o stanie lub rejestrowanie zdarzeń, licznik może okazać się przydatny do oceny powagi problemu. Więcej o licznikach dowiesz się z punktu „Liczniki” w rozdziale 9.

Jeśli w trakcie diagnozowania generowane są duże ilości danych w dzienniku, dostępnych jest kilka możliwości. Jedna polega na zapisaniu informacji w danych wyjściowych etapu mapowania zamiast w standardowym strumieniu błędów. Pozwala to na analizę i agregację danych w ramach operacji redukcji. To podejście zwykle wymaga zmian w strukturze programu, dlatego warto zacząć od innej techniki. Polega ona na napisaniu programu (oczywiście w modelu MapReduce) do analizowania generowanych przez zadanie danych z dziennika.

Kod związany z diagnozowaniem należy dodać do mappera (wersja 3.), a nie do reduktora, ponieważ celem jest ustalenie danych źródłowych prowadzących do uzyskania nieakceptowalnych danych wyjściowych.

```
public class MaxTemperatureMapper
    extends Mapper<LongWritable, Text, Text, IntWritable> {

  enum Temperature {
    OVER_100
  }

  private NcdcRecordParser parser = new NcdcRecordParser();

  @Override
  public void map(LongWritable key, Text value, Context context)
      throws IOException, InterruptedException {

    parser.parse(value);
    if (parser.isValidTemperature()) {
      int airTemperature = parser.getAirTemperature();
      if (airTemperature > 1000) {
        System.err.println("Temperatura ponad 100 stopni dla danych: " + value);
        context.setStatus("Wykryto uszkodzony rekord (patrz dziennik).");
        context.getCounter(Temperature.OVER_100).increment(1);
      }
```


Kup książkę Poleć książkę

```
            context.write(new Text(parser.getYear()), new IntWritable(airTemperature));
        }
    }
}
```

Jeśli temperatura wynosi ponad 100°C (co reprezentują wartości powyżej 1000, ponieważ temperatura jest zapisywana w dziesiętnych częściach stopni), kod zapisuje w standardowym strumieniu błędów podejrzany wiersz, a także za pomocą metody `setStatus()` klasy `Context` aktualizuje komunikat o stanie operacji mapowania, by skierować użytkowników do dziennika. Ponadto zwiększana jest wartość licznika, reprezentowana w Javie za pomocą pola typu wyliczeniowego. W tym programie zdefiniowane jest jedno pole, `OVER_100`, pozwalające zliczyć rekordy z temperaturą przekraczającą 100°C.

Po wprowadzeniu zmian należy ponownie skompilować kod, odtworzyć plik JAR, a następnie uruchomić zadanie i w trakcie jego wykonywania przejść do strony operacji.

Strony operacji i prób wykonania operacji

Strona zadania zawiera szereg odnośników do wyświetlania szczegółowych danych na temat operacji. Na przykład odnośnik *Map* prowadzi do strony z informacjami o wszystkich operacjach mapowania. Zrzut z rysunku 6.3 przedstawia tę stronę dla uruchomionego zadania. W kolumnie *Status* operacji widoczne są komunikaty diagnostyczne.

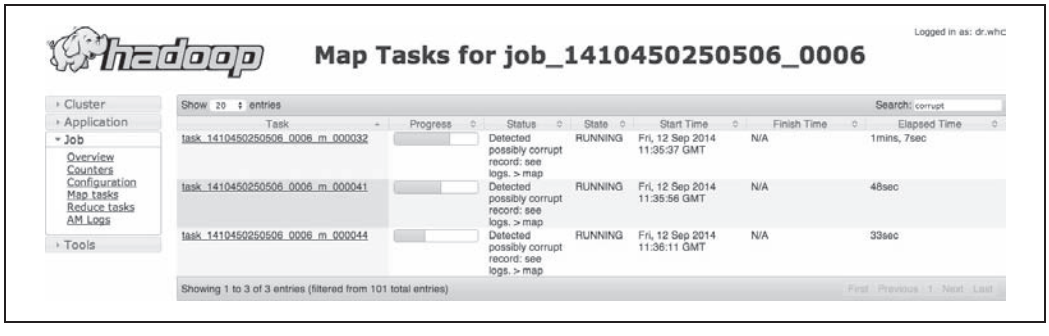

Rysunek 6.3. Zrzut ze stroną operacji

Kliknięcie odnośnika do operacji powoduje przejście do strony z próbami wykonania. Widoczne są na niej wszystkie próby wykonania danej operacji. Przy każdej próbie znajdują się odnośniki do plików dziennika i liczników. Kliknięcie jednego z odnośników do plików dziennika dla udanych prób wykonania zadania pozwala znaleźć zarejestrowane podejrzane rekordy z danych wyjściowych (pokazany wiersz jest podzielony i skrócony, aby zmieścił się na stronie).

```
Temperatura ponad 100 stopni dla danych:
033599999943318195704230200 5+37950+139117SAO   +0004RJSN V020113590031500703569 99
99943320195701010100005+35317+139650SAO +000899999V0200235900265007624 9N0040005...
```

Wygląda na to, że ten rekord ma inny format niż pozostałe. W wierszu występują spacje, co nie jest opisane w specyfikacji.

Po zakończeniu zadania można sprawdzić wartość zdefiniowanego licznika, aby ustalić, ile rekordów z temperaturą powyżej 100°C znajduje się w całym zbiorze danych. Dostęp do liczników jest możliwy za pomocą sieciowego interfejsu użytkownika i wiersza poleceń.

Kup książkę Poleć książkę

```
% mapred job -counter job_1410450250506_0006 \
  'v3.MaxTemperatureMapper$Temperature' OVER_100
3
```

Opcja `-counter` przyjmuje identyfikator zadania, nazwę grupy licznika (tu jest to pełna nazwa klasy) i nazwę licznika (nazwę wyliczenia). W całym zbiorze danych obejmującym ponad miliard rekordów występują tylko trzy błędne rekordy. Usuwanie nieprawidłowych rekordów to standardowe rozwiązanie w wielu problemach związanych z wielkimi danymi, choć tu należy zachować ostrożność, ponieważ szukane są skrajne wartości (maksymalna temperatura), a nie zagregowany wynik. Jednak pominięcie trzech rekordów prawdopodobnie nie zmieni rezultatów.

Obsługa nieprawidłowych danych

Zapisanie danych wejściowych powodujących problem jest przydatne. Można je wykorzystać w teście do sprawdzenia, czy mapper działa prawidłowo. Poniższy test z platformy MRUnit sprawdza, czy licznik jest aktualizowany po wykryciu błędnych danych wejściowych.

```
@Test
public void parsesMalformedTemperature() throws IOException,
    InterruptedException {
  Text value = new Text("0335999999433181957042302005+37950+139117SAO +0004" +
                                  // Rok ^^^^
      "RJSN V020113590031500703569999994332019570101000 05+353");
                            // Temperatura ^^^^^
  Counters counters = new Counters();
  new MapDriver<LongWritable, Text, Text, IntWritable>()
    .withMapper(new MaxTemperatureMapper())
    .withInput(new LongWritable(0), value)
    .withCounters(counters)
    .runTest();
  Counter c = counters.findCounter(MaxTemperatureMapper.Temperature.MALFORMED);
  assertThat(c.getValue(), is(1L));
}
```

Rekord powodujący problem ma odmienny format niż inne przedstawione wcześniej wiersze. Na listingu 6.12 pokazany jest zmodyfikowany program (wersja 4.). Używa on parsera ignorującego każdy wiersz, w którym pole z temperaturą nie jest poprzedzone znakiem plus lub minus. Ponadto dodany został licznik, który określa, ile rekordów zostało pominiętych z tego powodu.

Listing 6.12. Mapper dla przykładu z wyszukiwaniem maksymalnej temperatury

```
public class MaxTemperatureMapper
    extends Mapper<LongWritable, Text, Text, IntWritable> {

  enum Temperature {
    MALFORMED
  }

  private NcdcRecordParser parser = new NcdcRecordParser();

  @Override
  public void map(LongWritable key, Text value, Context context)
      throws IOException, InterruptedException {

    parser.parse(value);
    if (parser.isValidTemperature()) {
      int airTemperature = parser.getAirTemperature();
      context.write(new Text(parser.getYear()), new IntWritable(airTemperature));
```


Kup książkę Poleć książkę

```
      } else if (parser.isMalformedTemperature()) {
        System.err.println("Ignorowanie potencjalnie błędnych danych: " + value);
        context.getCounter(Temperature.MALFORMED).increment(1);
      }
    }
  }
```

Dzienniki w Hadoopie

Hadoop generuje dzienniki w różnych miejscach i dla rozmaitych odbiorców. Przegląd dzienników przedstawia tabela 6.2.

Tabela 6.2. Typy dzienników w Hadoopie

Dzienniki	Główni odbiorcy	Opis	Dodatkowe informacje
Dzienniki demonów systemowych	Administratorzy	Każdy demon w Hadoopie generuje plik dziennika (za pomocą narzędzia log4j) i plik łączący standardowe wyjście i wyjście błędów. Są one zapisywane w katalogu zdefiniowanym przez zmienną środowiskową `HADOOP_LOG_DIR`.	„Pliki dzienników systemowych" w rozdziale 10. i „Rejestrowanie informacji w dziennikach" w rozdziale 11.
Dzienniki inspekcji z systemu HDFS	Administratorzy	Dziennik wszystkich żądań z systemu HDFS (domyślnie wyłączony). Zapisywany w dzienniku węzła nazw, choć można to zmienić.	„Rejestrowanie dziennika inspekcji" w rozdziale 11.
Dzienniki historii zadań z modelu MapReduce	Użytkownicy	Dziennik zdarzeń (takich jak ukończenie operacji) zachodzących w czasie wykonywania zadania. Zapisywany centralnie w systemie HDFS.	„Historia zadań"
Dzienniki operacji z modelu MapReduce	Użytkownicy	Każdy proces potomny operacji generuje za pomocą narzędzia log4j plik dziennika (*syslog*), plik danych przesyłanych do standardowego wyjścia (*stdout*) i plik standardowego strumienia błędów (*stderr*). Są one zapisywane w podkatalogu *userlogs* katalogu zdefiniowanego w zmiennej środowiskowej `YARN_LOG_DIR`.	Ten punkt

System YARN udostępnia usługę **agregowania dzienników**, która przyjmuje dzienniki operacji z ukończonych aplikacji i przenosi je do systemu HDFS, gdzie są zapisywane w archiwalnym pliku kontenerowym. Jeśli usługa jest włączona (wymaga to ustawienia w klastrze właściwości `yarn.log-aggregation-enable` na wartość `true`), dzienniki operacji można wyświetlić za pomocą odnośnika *logs* z sieciowego interfejsu użytkownika dla prób wykonania operacji lub przy użyciu polecenia `mapred job -logs`.

Agregowanie dzienników domyślnie nie jest włączone. Wtedy dzienniki operacji można pobrać za pomocą sieciowego interfejsu użytkownika menedżera węzła (*http://node-manager-host:8042/logs/userlogs*).

Zapis danych w plikach dzienników jest prosty. Wszystko, co jest zapisywane do standardowego wyjścia lub standardowego strumienia błędów, trafia do odpowiedniego pliku dziennika. Oczywiście w narzędziu Streaming standardowe wyjście jest używane dla danych wyjściowych operacji mapowania lub redukowania, dlatego te dane nie pojawiają się w dzienniku standardowego wyjścia.

Kup książkę Poleć książkę

W Javie możesz zapisać informacje w pliku *syslog* operacji za pomocą interfejsu API Apache Commons Logging (lub dowolnego interfejsu API do rejestrowania dzienników współdziałającego z narzędziem log4j). To podejście zastosowano na listingu 6.13.

Listing 6.13. Mapper tożsamościowy zapisujący dane do standardowego wyjścia i używający interfejsu API Apache Commons Logging

```
import org.apache.commons.logging.Log;
import org.apache.commons.logging.LogFactory;
import org.apache.hadoop.mapreduce.Mapper;

public class LoggingIdentityMapper<KEYIN, VALUEIN, KEYOUT, VALUEOUT>
    extends Mapper<KEYIN, VALUEIN, KEYOUT, VALUEOUT> {

  private static final Log LOG = LogFactory.getLog(LoggingIdentityMapper.class);

  @Override
  @SuppressWarnings("unchecked")
  public void map(KEYIN key, VALUEIN value, Context context)
      throws IOException, InterruptedException {
    // Rejestrowanie w pliku stdout
    System.out.println("Klucz z etapu mapowania: " + key);

    // Rejestrowanie w pliku syslog
    LOG.info("Klucz z etapu mapowania: " + key);
    if (LOG.isDebugEnabled()) {
      LOG.debug("Wartość z etapu mapowania: " + value);
    }
    context.write((KEYOUT) key, (VALUEOUT) value);
  }
}
```

Domyślny poziom rejestrowania zdarzeń to `INFO`. Dlatego komunikaty z poziomu `DEBUG` nie pojawiają się w pliku dziennika *syslog* operacji. Jednak czasem programista chce wyświetlać takie komunikaty. W tym celu należy ustawić właściwość `mapreduce.map.log.level` lub `mapreduce.reduce.log.level`. Poniższa instrukcja pokazuje, jak ustawić właściwość dla mappera, aby zobaczyć w dzienniku wartości z etapu mapowania.

```
% hadoop jar hadoop-examples.jar LoggingDriver -conf conf/hadoop-cluster.xml \
  -D mapreduce.map.log.level=DEBUG input/ncdc/sample.txt logging-out
```

Istnieją narzędzia do zmiany czasu przechowywania i wielkości dzienników operacji. Domyślnie dzienniki są usuwane po upływie przynajmniej trzech godzin (tę wartość można ustawić za pomocą właściwości `yarn.nodemanager.log.retain-seconds`, choć jest ona ignorowana, jeśli włączone jest agregowanie dzienników). Można też ustawić limit maksymalnej wielkości każdego dziennika. Służy do tego właściwość `mapreduce.task.userlog.limit.kb`. Jej wartość domyślna, `0`, oznacza brak limitu.

Czasem programista musi zdiagnozować problem, który prawdopodobnie występuje w maszynie JVM uruchamiającej polecenie Hadoopa, a nie w klastrze. Aby przesłać dzienniki z poziomu `DEBUG` do konsoli, należy użyć instrukcji takiej jak poniżej.

```
% HADOOP_ROOT_LOGGER=DEBUG,console hadoop fs -text /foo/bar
```


Kup książkę Poleć książkę

Zdalne diagnozowanie

Gdy operacja kończy się niepowodzeniem i zarejestrowanych jest za mało informacji, aby można było zdiagnozować problem, można uruchomić debuger dla danej operacji. Trudno jest to zrobić, jeśli zadanie działa w klastrze. Nie wiadomo wtedy, które węzły będą przetwarzać poszczególne fragmenty danych wejściowych, dlatego nie można przygotować debugera przed wystąpieniem awarii. Istnieje jednak kilka rozwiązań.

Odtworzenie awarii lokalnie

W operacjach problemy często występują dla określonych danych wejściowych. Można spróbować odtworzyć problem lokalnie, pobierając plik, dla którego operacja kończy się niepowodzeniem, i uruchamiając zadanie lokalnie (na przykład za pomocą debugera VisualVM Javy).

Użycie opcji diagnostycznych maszyny JVM

Częstym powodem awarii jest błąd braku pamięci z Javy występujący w maszynie JVM operacji. Możesz dodać do elementu `mapred.child.java.opts` ustawienie `-XX:-HeapDumpOnOutOfMemoryError -XX:HeapDumpPath=/`*`ścieżka/do/zrzutów`*. Generuje ono zrzut sterty, który można potem przeanalizować za pomocą takich narzędzi jak *jhat* lub Eclipse Memory Analyzer. Zauważ, że opcje maszyny JVM należy dodać do istniejących ustawień pamięci określonych w elemencie `mapred.child.java.opts`. Szczegółowe omówienie ustawień znajdziesz w punkcie „Ustawienia pamięci w systemie YARN i modelu MapReduce” w rozdziale 10.

Przeprowadzenie profilowania operacji

Profilery Javy pozwalają dobrze przyjrzeć się pracy maszyny JVM, a Hadoop udostępnia mechanizm profilowania podzbioru operacji z zadania. Zobacz punkt „Profilowanie operacji”.

W niektórych sytuacjach warto przechowywać pliki pośrednie z nieudanych prób wykonania operacji w celu ich późniejszej analizy (zwłaszcza jeśli w katalogu roboczym operacji generowane są pomocnicze pliki zrzutu lub profilowania). Aby zachowywać takie pliki, ustaw właściwość `mapreduce.task.files.preserve.failedtasks` na wartość `true`.

Pośrednie pliki można zachowywać także dla operacji zakończonych powodzeniem. Jest to przydatne, jeśli chcesz zbadać operację, która nie powoduje awarii. Wtedy do właściwości `mapreduce.task.files.`
`↪preserve.filepattern` należy przypisać wyrażenie regularne pasujące do identyfikatorów operacji, których pliki chcesz zachować.

Inną właściwością przydatną w kontekście diagnozowania jest `yarn.nodemanager.delete.debug-delay-sec`. Określa ona liczbę sekund oczekiwania na usunięcie określonych plików prób wykonania operacji (na przykład skryptu używanego do uruchamiania maszyny JVM dla kontenera operacji). Jeśli ta właściwość jest ustawiona w klastrze na wystarczająco wysoką wartość (na przykład `600`, co oznacza 10 minut), programista zapewnia sobie wystarczającą ilość czasu na zapoznanie się z plikami przed ich usunięciem.

Aby zbadać pliki prób wykonania operacji, przejdź do węzła, w którym operacja zakończyła się niepowodzeniem, i poszukaj katalogu dla danej próby. Znajduje się on w jednym z lokalnych katalogów modelu MapReduce zgodnie z ustawieniami właściwości `mapreduce.cluster.local.dir` (opisanej szczegółowo w punkcie „Ważne właściwości demonów Hadoopa” w rozdziale 10.). Jeśli

Kup książkę Poleć książkę

do właściwości przypisana jest lista rozdzielonych przecinkami katalogów (co pozwala rozdzielić obciążenie między fizyczne dyski maszyny), znalezienie folderu dla konkretnej próby wykonania operacji może wymagać sprawdzenia wszystkich tych katalogów. Katalog próby wykonania operacji znajduje się w następującym miejscu:

```
lokalny.katalog.klastra.modelu.mapreduce/usercache/użytkownik/appcache/
ID-aplikacji/output/ID-próby-wykonania
```

Dostrajanie zadania

Gdy zadanie już działa, programista może zacząć się zastanawiać, czy da się je wykonywać szybciej.

Istnieje kilku specyficznych dla Hadoopa „podejrzanych", dla których warto sprawdzić, czy nie powodują problemów z wydajnością. Przejdź przez listę z tabeli 6.3, zanim zajmiesz się profilowaniem lub optymalizowaniem kodu na poziomie operacji.

Tabela 6.3. Lista kontrolna z obszaru dostrajania

Obszar	Zalecana praktyka	Dodatkowe informacje
Liczba mapperów	Jak długo działają mappery? Jeśli średnio jest to tylko kilka sekund, sprawdź, czy nie można używać mniejszej liczby mapperów, które pracują dłużej (około minuty). To, czy jest to możliwe, zależy od formatu danych wejściowych.	„Małe pliki i format CombineFileInputFormat" w rozdziale 8.
Liczba reduktorów	Sprawdź, czy używasz więcej niż jednego reduktora. Zgodnie z ogólną regułą operacje redukcji powinny działać około pięciu minut i generować przynajmniej blok danych.	„Określanie liczby reduktorów" w rozdziale 8.
Mechanizmy łączenia	Sprawdź, czy w zadaniu można wykorzystać mechanizm łączenia do ograniczenia ilości danych w fazie przestawiania.	„Funkcje łączące" w rozdziale 2.
Kompresja danych pośrednich	Czas wykonywania zadania prawie zawsze skraca się dzięki włączeniu kompresji danych wyjściowych z etapu mapowania.	„Kompresja danych wyjściowych z etapu mapowania" w rozdziale 5.
Niestandardowa serializacja	Jeśli używasz niestandardowych obiektów typu `Writable` lub niestandardowych komparatorów, upewnij się, że zaimplementowałeś interfejs `RawComparator`.	„Implementowanie interfejsu RawComparator z myślą o szybkości" w rozdziale 5.
Dostrajanie etapu przestawiania	Przestawianie w modelu MapReduce udostępnia kilkanaście parametrów służących do dostrajania zarządzania pamięcią. Mogą one pomóc w jeszcze większej poprawie wydajności.	„Dostrajanie konfiguracji" w rozdziale 7.

Profilowanie operacji

Profilowanie (podobnie jak diagnozowanie) zadań działających w systemie rozproszonym, na przykład w modelu MapReduce, związane jest z pewnymi trudnościami. Hadoop umożliwia profilowanie niektórych operacji z zadania i po zakończeniu każdej z nich pobiera zebrane informacje na komputer programisty w celu ich późniejszych analiz z użyciem standardowych narzędzi przeznaczonych do profilowania.

Oczywiście możliwe i łatwiejsze jest profilowanie zadania uruchomionego za pomocą lokalnego mechanizmu wykonywania zadań. Jeśli masz wystarczającą ilość danych wejściowych, by zbadać operacje mapowania i redukowania, jest to wartościowy sposób na poprawę wydajności mapperów

Kup książkę Poleć książkę

i reduktorów. Należy jednak pamiętać o kilku zastrzeżeniach. Lokalny mechanizm wykonywania zadań to bardzo odmienne środowisko od klastra, ze zdecydowanie innymi wzorcami przepływu danych. Optymalizowanie wydajności kodu z uwzględnieniem obciążenia procesora może okazać się bezcelowe, jeśli dane zadanie w modelu MapReduce jest ograniczone wydajnością operacji wejścia-wyjścia (co jest prawdą w wielu zadaniach). Aby mieć pewność, że dostrajanie jest skuteczne, należy porównać nowy czas wykonania z dawnym w klastrze. Jednak nie jest to łatwe, ponieważ czas wykonania może się znacznie wahać z powodu współzawodnictwa o zasoby z innymi zadaniami oraz podejmowanych przez program szeregujący decyzji dotyczących lokalizacji operacji. Aby rzetelnie oszacować czas wykonywania zadania w takich warunkach, uruchom je wielokrotnie (przed zmianą i po niej) oraz sprawdź, czy poprawa jest istotna statystycznie.

Niestety, niektóre problemy (na przykład nadmierne wykorzystanie pamięci) można zreprodukować tylko w klastrze. W takich sytuacjach możliwość profilowania zadania w klastrze jest niezbędna.

Profiler HPROF

Istnieje kilka właściwości konfiguracyjnych kontrolujących profilowanie. Można je ustawić także za pomocą metod pomocniczych z klasy `JobConf`. Aby włączyć profilowanie, wystarczy ustawić właściwość `mapreduce.task.profile` na wartość `true`.

```
% hadoop jar hadoop-examples.jar v4.MaxTemperatureDriver \
  -conf conf/hadoop-cluster.xml \
  -D mapreduce.task.profile=true \
  input/ncdc/all max-temp
```

Ta instrukcja powoduje standardowe rozpoczęcie pracy zadania, przy czym dodaje parametr `-agentlib` do polecenia Javy używanego do uruchamiania kontenerów operacji w menedżerach węzłów. Dodawany parametr można ustawić we właściwości `mapreduce.task.profile.params`. Domyślnie używany jest profiler HPROF. Jest to narzędzie do profilowania dostępne razem z platformą JDK. Jest ono proste, ale udostępnia wartościowe informacje na temat użytkowania procesora i sterty przez program.

Profilowanie wszystkich operacji zadania zwykle nie ma sensu. Dlatego domyślnie uwzględniane są tylko operacje mapowania i redukowania o identyfikatorach 0, 1 i 2. Aby to zmienić, użyj właściwości `mapreduce.task.profile.maps` i `mapreduce.task.profile.reduces` do określenia zakresu identyfikatorów profilowanych operacji.

Uzyskane w trakcie profilowania każdej operacji dane wyjściowe są zapisywane razem z dziennikami w podkatalogu *userlogs* lokalnego katalogu dzienników menedżera węzła (razem z plikami *syslog*, *stdout* i *stderr*). Można je pobrać w sposób opisany w punkcie „Dzienniki w Hadoopie” i zależny od tego, czy agregacja dzienników jest włączona, czy nie.

Przepływ pracy w modelu MapReduce

Zobaczyłeś już, jak napisać program działający w modelu MapReduce. Jednak nie opisano jeszcze, jak przekształcić problem z obszaru przetwarzania danych na postać zgodną z modelem MapReduce.

Kup książkę Poleć książkę

Do tego miejsca przetwarzanie danych dotyczyło stosunkowo prostego problemu — znajdowania maksymalnej temperatury zarejestrowanej w poszczególnych latach. Gdy przetwarzanie staje się bardziej skomplikowane, zwykle przejawia się to większą liczbą zadań w modelu MapReduce, a nie bardziej złożonymi funkcjami mapującymi lub redukującymi. Tak więc zgodnie z ogólną regułą programista powinien myśleć o dodaniu *większej liczby* zadań, a nie o dodaniu złożoności *do* zadań.

Dla bardziej skomplikowanych problemów warto rozważyć mechanizm wyższego poziomu niż model MapReduce — na przykład system Pig, Hive, Cascading, Crunch lub Spark. Oczywistą zaletą takiego podejścia jest to, że nie trzeba przekształcać problemu na zadania w modelu MapReduce. Pozwala to skoncentrować się na przeprowadzanych analizach.

Książka *Data-Intensive Text Processing with MapReduce* Jimmy'ego Lina i Chrisa Dyera (Morgan & Claypool Publishers, 2010) to doskonała pozycja pozwalająca lepiej poznać projekt algorytmu MapReduce. Gorąco zachęcamy do jej lektury.

Rozbijanie problemu na zadania w modelu MapReduce

Przyjrzyj się teraz bardziej skomplikowanemu problemowi przekładanemu na przepływ pracy w modelu MapReduce.

Załóżmy, że programista chce znaleźć średnią maksymalną temperaturę zarejestrowaną dla każdego dnia roku w każdej stacji meteorologicznej. Aby wyznaczyć średnią maksymalną temperaturą odnotowaną w stacji 029070-999999 w dniu 1 stycznia, należy obliczyć średnią z maksymalnych temperatur zarejestrowanych w tej stacji 1 stycznia 1901 roku, 1 stycznia 1902 roku itd. aż do 1 stycznia 2000 roku.

Jak to zrobić za pomocą modelu MapReduce? Najbardziej naturalny jest podział obliczeń na dwa opisane poniżej etapy.

1. *Obliczenie maksymalnej dziennej temperatury dla każdej pary stacja-data.*

   Ten program w modelu MapReduce jest odmianą programu obliczającego maksymalną temperaturę, przy czym tu klucze to pary stacja-data, a nie sam rok.

2. *Obliczenie średniej z maksymalnych dziennych temperatur dla każdego klucza stacja-dzień-miesiąc.*

   Mapper przyjmuje wyjściowe rekordy z poprzedniego zadania (stacja-data, maksymalna temperatura) i przekształca je na rekordy (stacja-dzień-miesiąc, maksymalna temperatura), usuwając komponent reprezentujący rok. Funkcja redukująca określa średnią z maksymalnych temperatur dla każdego klucza stacja-dzień-miesiąc.

Otrzymane w pierwszym etapie dane wyjściowe dla analizowanych stacji wyglądają tak (skrypt *mean_max_daily_temp.sh* z przykładowym kodem zawiera implementację opartą na narzędziu Hadoop Streaming):

```
029070-99999 19010101 0
029070-99999 19020101 -94
...
```


Kup książkę Poleć książkę

Dwa pierwsze pola tworzą klucz. Ostatnia kolumna określa maksymalną temperaturę z wszystkich odczytów dla danej stacji i daty. Na drugim etapie dzienne maksima są uśredniane dla wszystkich lat. Oto efekt:

```
029070-99999 0101 -68
```

Oznacza to, że średnia maksymalnych dziennych temperatur 1 stycznia w stacji 029070-99999 dla ubiegłego wieku wynosi –6,8°C.

Te obliczenia można wykonać w jednym etapie modelu MapReduce, co jednak wymaga od programisty więcej pracy[2].

Argumentem na rzecz większej liczby (ale prostszych) etapów w modelu MapReduce jest to, że pozwala to budować łatwiejsze w łączeniu i konserwacji mappery oraz reduktory. W kilku studiach przypadków z części V opisano praktyczne problemy rozwiązane za pomocą modelu MapReduce. Przetwarzanie danych w każdym z tych przykładów jest zaimplementowane za pomocą dwóch lub więcej zadań w modelu MapReduce. Informacje z niniejszego rozdziału są nieocenioną pomocą, jeśli chcesz lepiej zrozumieć przekształcanie problemów na przepływ pracy w modelu MapReduce.

Funkcje mapująca i redukująca mogą być jeszcze łatwiejsze w łączeniu niż w przykładowym kodzie. Mapper często odpowiada za parsowanie danych w wejściowym formacie, projekcję (wybór odpowiednich pól) i filtrowanie (usuwanie zbędnych rekordów). W przedstawionym do tego miejsca kodzie wszystkie te czynności wykonuje jeden mapper. Można jednak rozdzielić je między odrębne mappery połączone w łańcuch za pomocą klasy bibliotecznej `ChainMapper` z Hadoopa. Dodatkowo można zastosować klasę `ChainReducer` i uruchomić w jednym zadaniu w modelu MapReduce łańcuch mapperów, po którym działa reduktor, a następnie inny łańcuch mapperów.

JobControl

Gdy w przepływie pracy w modelu MapReduce występuje więcej niż jedno zadanie, trzeba zastanowić się nad tym, jak zarządzać zadaniami, by były wykonywane w odpowiedniej kolejności. Istnieje kilka rozwiązań. Najważniejszym czynnikiem przy ich wyborze jest to, czy łańcuch zadań jest liniowy, czy tworzy bardziej skomplikowany skierowany graf acykliczny.

Gdy łańcuch jest liniowy, najprostsze podejście polega na uruchamianiu zadań jedno po drugim. Przed uruchomieniem następnego zadania należy poczekać na udane ukończenie poprzedniego.

```
JobClient.runJob(conf1);
JobClient.runJob(conf2);
```

Jeśli zadanie zakończy się niepowodzeniem, metoda `runJob()` zgłosi wyjątek `IOException`, a dalsze zadania z potoku nie zostaną wykonane. W niektórych aplikacjach można przechwytywać ten wyjątek i zerować dane pośrednie wygenerowane przez wcześniejsze zadania.

W nowym interfejsie API modelu MapReduce rozwiązanie wygląda podobnie. Trzeba jednak sprawdzić wartość logiczną zwracaną przez metodę `waitForCompletion()` klasy `Job`. Wartość `true` oznacza, że zadanie zakończyło się powodzeniem, a wartość `false` oznacza błąd.

[2] Jest to ciekawe ćwiczenie. Oto wskazówka — wykorzystaj informacje z punktu „Sortowanie pomocnicze” w rozdziale 9.

Kup książkę Poleć książkę

Gdy łańcuch jest bardziej skomplikowany, można wykorzystać biblioteki pomagające w zarządzaniu przepływem pracy (działają one także dla łańcuchów liniowych, a nawet jednorazowych zadań). Najprostszym narzędziem tego typu jest klasa `JobControl` z pakietu `org.apache.hadoop.mapreduce.jobcontrol`. Dostępna jest też analogiczna klasa w pakiecie `org.apache.hadoop.mapred.jobcontrol`. Obiekt klasy `JobControl` reprezentuje graf zadań do wykonania. Należy podać konfigurację zadań, a następnie poinformować obiekt o zależnościach między zadaniami. Obiekt klasy `JobControl` działa w wątku i uruchamia zadania zgodnie z kolejnością wyznaczaną przez zależności. Można sprawdzać postęp w wykonywaniu zadań, a po ich ukończeniu — sprawdzić status każdego zadania i błędy informujące o niepowodzeniu. Jeżeli zadanie zakończy się błędem, obiekt klasy `JobControl` nie uruchomi powiązanych zadań.

Apache Oozie

Apache Oozie to system uruchamiania przepływu pracy z powiązanymi zadaniami. Obejmuje dwie główne części: **silnik przepływu pracy** (przechowuje i uruchamia przepływy pracy obejmujące różnego rodzaju zadania Hadoopa; mogą to być zadania z technologii MapReduce, Pig, Hive itd.) i **silnik koordynatora** (uruchamia zadania z przepływu pracy na podstawie wstępnie zdefiniowanych harmonogramów i dostępności danych). System Oozie jest zaprojektowany z myślą o skalowaniu i potrafi zarządzać wykonywaniem w klastrze Hadoopa tysięcy przepływów pracy, z których każdy może obejmować dziesiątki zadań.

Oozie ułatwia ponowne wykonywanie przepływów pracy zakończonych niepowodzeniem, ponieważ nie trzeba marnować czasu na powtarzanie poprawnie ukończonych fragmentów przepływu pracy. Każdy, kto zarządzał skomplikowanym systemem wsadowym, wie, jak trudne jest wznawianie pracy na poziomie zadań nieukończonych z powodu błędu lub przestoju maszyny. Wszystkie te osoby docenią wspomniany mechanizm. Ponadto zarządzane przez koordynatora aplikacje tworzące jeden potok danych można umieścić w *pakiecie* i uruchamiać jako połączoną jednostkę.

System Oozie (w odróżnieniu od klasy `JobControl`, która pracuje na maszynie klienckiej przesyłającej zadania) działa jako usługa w klastrze. Klienty przesyłają do niej definicje przepływu pracy w celu natychmiastowego lub późniejszego uruchomienia zadań. W systemie Oozie przepływ pracy to skierowany graf acykliczny **węzłów akcji** i **węzłów sterowania przepływem**.

Węzeł akcji wykonuje operacje z przepływu pracy takie jak: przeniesienie plików w systemie HDFS, uruchomienie zadania w technologii MapReduce, Streaming, Pig lub Hive, zaimportowanie danych w narzędziu Sqoop lub uruchomienie dowolnego skryptu powłoki albo programu w Javie. Węzeł sterowania przepływu zarządza przepływem pracy pomiędzy akcjami i obsługuje logikę warunkową (pozwala to wybierać różne gałęzie programu na podstawie wyników z wcześniejszego węzła akcji) oraz równoległe wykonywanie kodu. Po zakończeniu przepływu pracy system Oozie może skierować wywołanie zwrotne HTTP do klienta, by poinformować go o statusie przepływu pracy. Ponadto można przyjmować wywołania zwrotne za każdym razem, gdy przepływ pracy wchodzi do węzła akcji lub z niego wychodzi.

Kup książkę Poleć książkę

Definiowanie przepływu pracy w systemie Oozie

Definicje przepływu pracy są pisane w XML-u przy użyciu języka Hadoop Process Definition Language (jego specyfikację znajdziesz w witrynie projektu Oozie — *http://oozie.apache.org/*). Listing 6.14 przedstawia prostą definicję przepływu pracy z systemu Oozie przeznaczoną do uruchamiania jednego zadania w modelu MapReduce.

Listing 6.14. Definicja przepływu pracy z systemu Oozie służąca do uruchamiania zadania w modelu MapReduce wyznaczającego maksymalną temperaturę

```
<workflow-app xmlns="uri:oozie:workflow:0.1" name="max-temp-workflow">
  <start to="max-temp-mr"/>
  <action name="max-temp-mr">
    <map-reduce>
      <job-tracker>${resourceManager}</job-tracker>
      <name-node>${nameNode}</name-node>
      <prepare>
        <delete path="${nameNode}/user/${wf:user()}/output"/>
      </prepare>
      <configuration>
        <property>
          <name>mapred.mapper.new-api</name>
          <value>true</value>
        </property>
        <property>
          <name>mapred.reducer.new-api</name>
          <value>true</value>
        </property>
        <property>
          <name>mapreduce.job.map.class</name>
          <value>MaxTemperatureMapper</value>
        </property>
        <property>
          <name>mapreduce.job.combine.class</name>
          <value>MaxTemperatureReducer</value>
        </property>
        <property>
          <name>mapreduce.job.reduce.class</name>
          <value>MaxTemperatureReducer</value>
        </property>
        <property>
          <name>mapreduce.job.output.key.class</name>
          <value>org.apache.hadoop.io.Text</value>
        </property>
        <property>
          <name>mapreduce.job.output.value.class</name>
          <value>org.apache.hadoop.io.IntWritable</value>
        </property>
        <property>
          <name>mapreduce.input.fileinputformat.inputdir</name>
          <value>/user/${wf:user()}/input/ncdc/micro</value>
        </property>
        <property>
          <name>mapreduce.output.fileoutputformat.outputdir</name>
          <value>/user/${wf:user()}/output</value>
        </property>
      </configuration>
    </map-reduce>
    <ok to="end"/>
    <error to="fail"/>
  </action>
```


Kup książkę Poleć książkę

```
  <kill name="fail">
    <message>Błąd zadania w modelu MapReduce.
             Komunikat o błędzie[${wf:errorMessage(wf:lastErrorNode())}]
    </message>
  </kill>
  <end name="end"/>
</workflow-app>
```

Ten przepływ pracy obejmuje trzy węzły sterowania przepływem (`start`, `kill` i `end`) i jeden węzeł akcji (`map-reduce`). Węzły i dozwolone przejścia między nimi są pokazane na rysunku 6.4.

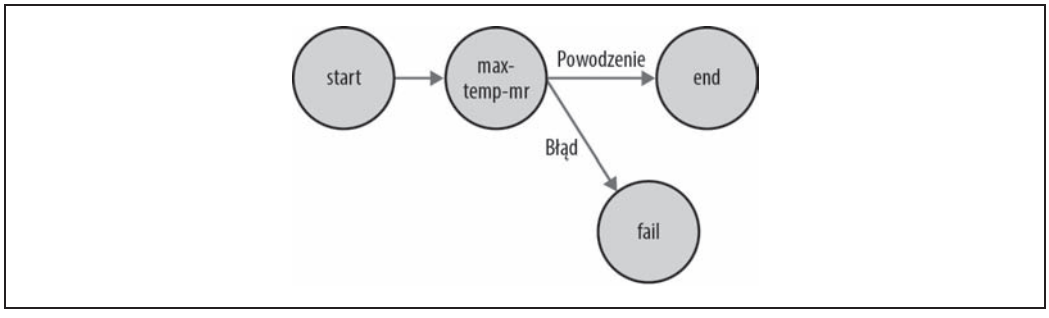

Rysunek 6.4. Diagram przejść w przepływie pracy w systemie Oozie

Wszystkie przepływy pracy muszą mieć jeden węzeł `start` i jeden węzeł `end`. Gdy zadanie w przepływie pracy rozpoczyna działanie, przechodzi do węzła wskazanego w węźle `start` (tu węzłem docelowym jest węzeł akcji `max-temp-mr`). Zadanie w przepływie pracy z powodzeniem kończy działanie, gdy dochodzi do węzła `end`. Jeśli jednak nastąpi przejście do węzła `kill`, jest to uznawane za niepowodzenie. Program zwraca wtedy odpowiedni komunikat o błędzie ustawiony w elemencie `message` w definicji przepływu pracy.

Dużą część tego pliku definicji przepływu pracy zajmuje opis akcji `map-reduce`. Dwa pierwsze elementy, `job-tracker` i `name-node`, określają menedżer zasobów systemu YARN (lub jobtracker w Hadoopie 1), do którego należy przesyłać zadanie, oraz węzeł nazw (jako identyfikator URI z systemu plików Hadoopa) dla danych wejściowych i wyjściowych. Oba elementy są podawane za pomocą parametrów, dzięki czemu ta definicja przepływu pracy nie jest powiązana z żadnym konkretnym klastrem, co pozwala na jej łatwe testowanie. Parametry są podawane jako właściwości zadania z przepływu pracy w momencie jego przesyłania, co zobaczysz dalej.

Element `job-tracker` ma mylącą nazwę i w rzeczywistości służy do określania adresu i portu menedżera zasobów z systemu YARN.

Opcjonalny element `prepare` określa czynności wykonywane przed danym zadaniem w modelu MapReduce i służy na przykład do usuwania katalogów (oraz ich tworzenia, jeśli jest to konieczne, choć tu kod tego nie robi). Dzięki upewnieniu się przed uruchomieniem zadania, że katalog wyjściowy pozostaje w spójnym stanie, system Oozie może bezpiecznie ponownie wykonać akcję, jeśli zadanie zakończy się niepowodzeniem.

Kup książkę Poleć książkę

Zadanie w modelu MapReduce jest wskazywane w elemencie `configuration` przy użyciu zagnieżdżonych elementów określających pary nazwa-wartość z konfiguracji Hadoopa. Sekcję z konfiguracją modelu MapReduce możesz traktować jak deklaratywny zastępnik klas sterowników używanych do uruchamiania programów w modelu MapReduce w innych miejscach książki (na przykład na listingu 2.5).

W kilku miejscach definicji przepływu pracy wykorzystano składnię języka JSP Expression Language (EL). System Oozie udostępnia zestaw funkcji przeznaczonych do interakcji z przepływem pracy. Na przykład funkcja `${wf:user()}` zwraca nazwę użytkownika, który uruchomił bieżące zadanie z przepływu pracy. Tu funkcja jest używana do określenia odpowiedniej ścieżki w systemie plików. W specyfikacji systemu Oozie znajdziesz listę wszystkich funkcji języka EL obsługiwanych w tym systemie.

Pakowanie i instalowanie aplikacji opartej na przepływie pracy z systemu Oozie

Aplikacja oparta na przepływie pracy obejmuje definicję przepływu pracy oraz wszystkie powiązane zasoby (pliki JAR dla modelu MapReduce, skrypty systemu Pig itd.) potrzebne do jej wykonania. Takie aplikacje muszą mieć określoną prostą strukturę katalogów i trzeba je umieścić w systemie HDFS, tak by system Oozie miał do nich dostęp. W omawianej aplikacji wszystkie pliki znajdują się w głównym katalogu *max-temp-workflow*, co pokazano na poniższym schemacie.

```
max-temp-workflow/
    lib/
        hadoop-examples.jar
    workflow.xml
```

Plik z definicją przepływu pracy, *workflow.xml*, musi znajdować się na najwyższym poziomie hierarchii. Pliki Jar z klasami aplikacji dla modelu MapReduce są umieszczone w katalogu *lib*.

Oparte na przepływie pracy aplikacje o tym układzie można zbudować za pomocą różnych narzędzi do obsługi budowania (na przykład przy użyciu Anta lub Mavena). Przykłady znajdziesz w kodzie dołączonym do tej książki. Po zbudowaniu aplikacji należy ją skopiować do systemu HDFS za pomocą standardowych narzędzi Hadoopa. Oto polecenie odpowiednie dla omawianej aplikacji:

```
% hadoop fs -put hadoop-examples/target/max-temp-workflow max-temp-workflow
```

Uruchamianie zadań z przepływu pracy w systemie Oozie

Zobacz teraz, jak uruchomić zadanie z przepływu pracy z wczytanej właśnie do systemu aplikacji. Posłuży do tego uruchamiane z poziomu wiersza poleceń narzędzie *oozie*. Jest to program kliencki przeznaczony do komunikowania się z serwerem systemu Oozie. Dla wygody eksportowana jest zmienna środowiskowa `OOZIE_URL`, informująca polecenie `oozie` o tym, który serwer systemu Oozie należy wybrać (tu używany jest serwer lokalny).

```
% export OOZIE_URL="http://localhost:11000/oozie"
```

Narzędzie *oozie* udostępnia wiele poleceń podrzędnych (ich listę zobaczysz po wpisaniu instrukcji `oozie help`). Tu używane jest polecenie podrzędne `job` z opcją `-run`, które uruchamia zadanie z przepływu pracy.

```
% oozie job -config ch06-mr-dev/src/main/resources/max-temp-workflow.properties \
  -run
job: 0000001-140911033236814-oozie-oozi-W
```


Kup książkę Poleć książkę

Opcja `-config` określa lokalny plik z właściwościami Javy, w którym znajdują się definicje parametrów używanych w pliku XML z przepływem pracy (tu są to parametry `nameNode` i `resourceManager`) oraz ścieżka `oozie.wf.application.path`, informująca system Oozie o lokalizacji opartej na przepływie pracy aplikacji w systemie HDFS. Oto zawartość pliku z właściwościami.

```
nameNode=hdfs://localhost:8020
resourceManager=localhost:8032
oozie.wf.application.path=${nameNode}/user/${user.name}/max-temp-workflow
```

W celu uzyskania informacji o statusie zadania z przepływu pracy należy użyć opcji `-info` i podać identyfikator zadania wyświetlony wcześniej przez polecenie `run` (w celu wyświetlenia listy wszystkich zadań wpisz instrukcję `oozie job`).

```
% oozie job -info 0000001-140911033236814-oozie-oozi-W
```

Dane wyjściowe pokazują status zadań: `RUNNING`, `KILLED` lub `SUCCEEDED`. Wszystkie informacje można też znaleźć za pomocą sieciowego interfejsu użytkownika systemu Oozie (*http://localhost:11000/oozie*).

Po zakończeniu wykonywania zadania można sprawdzić wyniki w standardowy sposób.

```
% hadoop fs -cat output/part-*
1949 111
1950 22
```

Ten przykład pokazuje tylko niewielką część możliwości związanych z pisaniem przepływów pracy w systemie Oozie. W dokumentacji w witrynie tego systemu znajdziesz informacje o tworzeniu bardziej skomplikowanych przepływów pracy, a także o pisaniu i uruchamianiu zadań koordynatora.

Kup książkę Poleć książkę

Kup książkę Poleć książkę

Skorowidz

A

ACL, Access Control List, 572, 576
ADAM, 621
adres URL, 74
agent platformy Flume, 366, 373
agregacja, 526
  danych, 475
  dzienników, 178
akcje, 524
aktualizacja, 456
  kończenie procesu, 330
  opcjonalne finalizowanie, 330
  opcjonalne wycofywanie, 330
  rozpoczynanie, 329
aktualizowanie
  danych, 327
  klastra, 327
  metadanych, 327
akumulatory, 531
algorytm
  PageRank, 511
  Paxos, 583
algorytmy
  iteracyjne, 511
  kompresji, 114
analiza
  danych, 29, 42, 44
  genomu, 621
  wpływu zmian parametrów, 235
  wyrównanych odczytów, 626
anatomia
  odczytu pliku, 85
  przebiegu zadania, 532
Apache
  Avro, 333
  Crunch, 489
  Flume, 365
  Hadoop, 645
  Hive, 445
  Mesos, 537
  Oozie, 185
  Parquet, 353
  Pig, 403
  Spark, 517
  Sqoop, 383
API do obsługi konfiguracji, 151
aplikacja do przesyłania zapytań, 553
aplikacje
  systemu YARN, 95
  w kolejkach, 105
arbitralne modyfikacje plików, 62
architektura platformy Hive, 453
ASCII, 41
asynchroniczne wykonywanie metod, 507
atomowość, 584
Avro, 333
  deserializacja, 337
  model MapReduce, 346
  narzędzia, 342
  pliki danych, 340
  schematy, 343
  schematy systemu, 334
  serializacja, 337
  sortowanie, 344, 349
  typy danych, 334
  używanie systemu, 351
  współdziałanie języków, 341
awaria
  częściowa, 567
  węzła nazw, 66

B

bazy
  danych, 385
  RDBMS, 561
bezpieczeństwo, 299
biblioteka
  Crunch, 490
  libhdfs, 73
  MRUnit, 161
biblioteki
  Cruncha, 513, 514
  FlumeJava, 489
binarne dane wejściowe, 236
BLOB, 396
blokada rozproszona, 594
blokady, 544
bloki systemu HDFS, 63, 233
BookKeeper, 597
budowanie aplikacji, 588
  w modelu MapReduce, 151
budowanie klastra, 277

C

Capacity
  konfigurowanie, 103
Cascading, 629
  elastyczność, 637
  operacje, 632
Crunch, 489
  biblioteki, 513
  funkcje, 502
  inspekcja planu wykonania, 508
  interfejsy API, 493
  materializacja, 504
  potoki, 500

Kup książkę Poleć książkę

Crunch
wykonywanie potoku, 506
zapisywanie danych, 501
zbiory danych, 500
czas
taktu, 586
życia aplikacji, 97
częściowo ustrukturyzowane dane, 33
czujki, 578 580

D

dane, 27
meteorologiczne, 653
nieustrukturyzowane, 33
pogrupowane, 609
pomocnicze, 268
relacyjne, 33
wejściowe, 237
z bazy, 238
wyjściowe, 45
binarne, 239
dla bazy, 244
tekstowe, 239
debugowanie zadania, 175
definiowanie przepływu pracy, 186
dekompresja
pliku, 116
strumieni, 115
delegowanie uprawnień, 302
demony
Hadoopa, 296, 647
systemu HDFS, 284
deserializacja, 122, 337
diagnozowanie, 507
DNA, 615
sekwencjonowanie, 620
wyrównywanie, 620
dodawanie
węzłów, 324
zależności, 169
domyślne zadanie, 220
dopasowywanie do wzorca, 82
dostęp
do danych, 62, 472
do danych kolumnowych, 623
do systemu HDFS, 72
dostrajanie
konfiguracji, 206
zadania, 181
DRF, Dominant Resource Fairness, 109
dynamiczne obiekty wywołujące, 430
dyrektywy pamięci podręcznej, 65
dystrybucja, 374
firmy Cloudera, 651
działanie
bazy HBase, 545
modelu MapReduce, 191
dzielenie danych, 442
dziennik inspekcji, 315
dzienniki w Hadoopie, 178

E

edytory kodu, 407
efekt stada, 595
eksom, 618
eksport, 398–401
elastyczność kolejek, 103

F

Fair
konfigurowanie, 105
rozmieszczanie w kolejkach, 107
szeregowanie z opóźnieniem, 109
włączanie programu, 106
wywłaszczanie, 108
faza
redukcji, 204
scalania, 204
sortowania, 204
federacje, 65
fenotyp, 618
FIFO, 101
filtrowanie, 426, 434
Flume, 365
agent, 373, 376
dystrybucja, 374
gwarancje dostarczenia, 373, 376
instalowanie platformy, 365
integracja z aplikacjami, 380
interceptory, 370
katalog komponentów, 381
konfiguracja platformy, 372, 378, 379
niezawodność, 368
partycje, 370
rozsyłanie danych, 372
transakcje, 368
Flume SDK, 380
format danych, 41, 231
CombineFileInputFormat, 227
DOT, 508
LobFile, 397
ORCFile, 147
Parquet, 147, 353, 356
RCFile, 147
SequenceFile, 144
SerDe, 471
Trevni, 147
formatowanie
systemu plików, 283
systemu plików HDFS, 649
formaty
binarne, 470
danych wyjściowych, 238
kolumnowe, 146, 353
kompresji, 119
plików, 146, 371
wejściowe, 222
wierszowe, 623
funkcja
mapująca, 44, 262
w Javie, 45
w Pythonie, 59
w Ruby, 57
redukująca, 55
w Javie, 46
w Pythonie, 60
w Ruby, 58
funkcje, 502
filtrujące, 423
łączące, 55
modelu MapReduce, 245
obliczeniowe, 423
UDAF, 481, 484, 486
UDF, 426, 430, 481
UDTF, 481
umożliwiające łączenie, 610

Kup książkę Poleć książkę

użytkownika, 426, 481
wczytujące, 423
zapisujące, 423
FUSE, Filesystem in Userspace, 73

G

generowanie danych, 409
genom, 614, 619
genomy referencyjne, 619
grafy acykliczne, 533
Grunt, 406
grupa, 570
dołączanie członków, 573
tworzenie, 571
usuwanie, 575
wyświetlanie członków, 574
grupowanie, 436
grupy ujść, 377
gwarancje dostarczenia danych, 376

H

Hadoop, 25, 36, 70, 275
bezpieczeństwo, 299
budowanie klastra, 277
dzienniki, 178
instalowanie, 282, 645
interfejsy, 71
konfiguracja, 283, 285, 646
odczyt danych, 74
operacje wejścia-wyjścia, 111
specyfikacja klastra, 278
systemy plików, 71
testy porównawcze, 305
tryby, 647
ustawienia środowiskowe, 287
właściwości demonów, 289
właściwości konfiguracyjne, 647
zarządzanie konfiguracją, 286
zarządzanie platformą, 309
haplotyp, 618
HBase, 541
działanie, 545
implementacja, 544
instalacja, 546
interfejs użytkownika, 564
klasy, 552
klienty, 549
liczniki, 565
model danych, 542
narzędzia, 552
skanery, 551
system HDFS, 564
wskaźniki, 565
HDFS, 29, 61
bloki, 63
dostępność, 66
federacje, 65
formatowanie systemu plików, 283
integralność danych, 112
interfejs, 68
operacje, 69
przepływ danych, 85
ujścia, 369
uprawnienia do plików, 70
węzły danych, 64
węzły nazw, 64
zapisywanie bloków, 65
Hedwig, 597
historia zadań, 173
Hive, 394, 445
architektura, 453
format pliku, 468
format wierszy, 468
funkcje, 462
importowanie danych, 472
instalowanie platformy, 446
klienty, 452
konfigurowanie platformy, 449
kubełki, 464
operatory, 462
partycje, 464
powłoka, 446
system typów, 395
tabele, 463
typy danych, 458
typy proste, 459
typy złożone, 461
uruchamianie platformy, 449
usługi, 451
HiveQL, 458
modyfikowanie tabel, 473
HTTP, 72
Hue, 452

I

identyfikator zxid, 584
identyfikatory zadań, 172
IDL, interface description language, 137, 621
implementacja
interfejsu Writable, 132
interfejsu RawComparator, 135
MapReduce 1, 99
typu RecordReader, 229
import przyrostowy, 392
importowanie
danych, 385, 389, 394, 472
dużych obiektów, 396
w trybie bezpośrednim, 392
indeksowanie, 127
zdarzeń, 373
indeksy, 456
indel, 618
informacje
o plikach, 82
o pliku w mapperze, 228
o postępie i statusu, 196
o stanie pliku, 80
inicjowanie zadania, 193
inspekcja planu wykonania, 508
instalowanie
Hadoopa, 282
HBase, 546
klastra, 282
platformy Flume, 365
platformy Hadoop, 645
platformy Hive, 446
Sparka, 518
systemu ZooKeeper, 568
instrukcja
ALTER TABLE, 473
COGROUP, 437
CREATE TABLE…AS SELECT, 473
DROP TABLE, 474
GROUP, 440
INSERT, 472
SET, 450
integracja
danych, 111, 603, 607
procesorów, 603
semantyczna, 603

Kup książkę Poleć książkę

interaktywny SQL, 31
interceptory, 370
interfejs
API, 272, 273, 338
API dla Pythona, 341
API FileSystem, 75
API Javy, 58, 657
API JDBC, 389
CLI, 452
Configurable, 158
JDBC, 238
PathFilter, 83
RawComparator, 135
REST, 553
ResultSet, 391
Seekable, 77
systemu HDFS, 68
Thrift, 553
Tool, 158
użytkownika, 171
w Javie, 74
Writable, 123
WritableComparable, 124
interfejsy
API Cruncha, 493
pępowinowe, 196
intron, 618
iteracje, 129

J

Java, 45, 521
jednostki zapisujące, 62
język
HiveQL, 446, 458
IDL, 137, 605, 621
Pig Latin, 407, 411
Ruby, 57
Scala, 520
SQL, 457
JMX, 321
JobControl, 184
jobtracker, 99
JVM, Java virtual machine, 50

K

kanał
oparty na pamięci, 368
oparty na pliku, 368
katalog, 70, 80
Kerberos, 300
klasa
ActiveKeyValueStore, 593
klasa
AvroAsTextInputFormat, 351
AvroParquetReader, 361
AvroParquetWriter, 360, 361
AvroParquetWriter, 360
BlockManagerInfo, 528
BytesWritable, 130
ChainReducer, 184
ChecksumFileSystem, 113
CodecPool, 118
CompressionCodecFactory, 116, 117
DataByteArray, 428
FileInputFormat, 224, 226
FileOutputFormat, 240
FileStatus, 80
FileSystem, 78
FixedLengthInputFormat, 237
From, 500
FSDataInputStream, 76, 77
FSDataOutputStream, 79, 90
GenericOptionsParser, 158, 159, 272
GenericWritable, 131
InputSplit, 222
IntWritable, 123
KeyValueTextInputFormat, 233
LocalFileSystem, 112
MapDriver, 162
MapFile, 145
MapFileOutputFormat, 239
Mapper, 45, 46
MaxTemperatureDriver, 165
MaxWidgetId, 393, 394
MinimalMapReduceWith ↪Defaults, 218
MultipleOutputs, 241, 242, 243
NLineInputFormat, 234
NullWritable, 131
ObjectWritable, 131
ParquetOutputFormat, 358
ParquetWriter, 360
PigStorage, 433
PObject, 505
ProtoParquetWriter, 360
PType<S>, 497
klasa RDD, 521
Reducer, 220
SequenceFile, 138, 139
SequenceFileAsBinaryInput ↪Format, 236
SequenceFileAsBinaryOutput ↪Format, 239
SequenceFileAsTextInput ↪Format, 236
SequenceFileInputFormat, 236
SequenceFileOutputFormat, 239
StreamXmlRecordReader, 235
String, 130
TableInputFormat, 552
TableOutputFormat, 552
Text, 127
TextInputFormat, 232
ToolRunner, 160
Trash, 299
WholeFileInputFormat, 229
WholeFileRecordReader, 230
klastry, 278
klasy
biblioteczne modelu MapReduce, 273
z rodziny InputFormat, 224
z rodziny OutputCommitter, 210
z rodziny OutputFormat, 238
z rodziny Writable, 125
klauzula ROW FORMAT, 470, 471
klienty, 64
HBase, 549
Hive, 452
klucze, 45, 221
kod genetyczny, 616
kodek, 114
kodeki kompresji, 115
kodon, 616
kodowanie struktury danych, 355
kolejka, 103
danych, 88
potwierdzeń, 88
kolekcja
PCollection, 505
PTable, 503
Writable, 131
kolumna podziału, 391

Kup książkę Poleć książkę

kolumnowa baza danych, 541
kolumny typu BLOB, 396
komparatory, 124
  niestandardowe, 136
komponenty platformy Flume, 381, 382
kompresja, 118
  danych wyjściowych, 121
  plików, 113
  strumieni, 115
konektory Sqoopa, 385
konfigurowanie
  Hadoopa, 283, 285
  klienta ZooKeepera, 585
  platformy Hive, 449
  platformy Flume, 372, 378, 379
  programu Capacity, 103
  programu Fair, 105
  protokołu SSH, 282
  typów, 215, 216
  usługi SSH, 648
  zadania, 268
  ZooKeepera, 599
konserwacja, 322
kontener, 96
kontroler przełączania awaryjnego, 67
kontrolowanie
  procesu importu, 391
  sortowania, 255
konwersje typów, 462
kopie zapasowe
  danych, 323
  metadanych, 322
kopiowanie
  pliku, 79
  równoległe, 91
kosz, 298
krotki, 498, 630
księga główna, 597
księgowi, 597
kubełki, 464, 466
kwalifikator rodziny kolumn, 543

L

leniwe generowanie danych wyjściowych, 243
liczba reduktorów, 219
liczniki, 245, 565
  dynamiczne, 251
  narzędzia Streaming, 252
  operacji, 246
  użytkowników, 248
  wbudowane, 245
  zadań, 249
lista
  ACL, 576, 581
  kontroli dostępu, 572
lokalizacje
  docelowe, 501
  wyjściowe, 501
lokalność
  danych, 52
  względem procesu, 535
  względem węzła, 535
lokalny magazynem metadanych, 454

Ł

łańcuch zadań, 638
łączenie
  danych, 442
  danych w różnych platformach, 610
  zasobów, 152

M

macierz RAID, 279
magazyn metadanych, 453
makra, 425
maksymalna długość wierszy, 233
mapowanie, 44, 121, 202
mapper, 161, 266
MapReduce
  budowanie aplikacji, 151
  domyślne zadanie, 216
  formaty, 213
  funkcje, 245
  inicjowanie zadania, 193
  interfejs użytkownika, 171
  klasy biblioteczne, 273
  konfigurowanie typów, 215, 216
  niepowodzenie menedżera węzła, 200
  niepowodzenie menedżera zasobów, 201
  niepowodzenie operacji, 198
  niepowodzenie zarządcy aplikacji, 199
  postęp, 196
  przepływ pracy, 182
  przesyłanie zadania, 192
  przypisywanie operacji, 194
  sortowanie, 630
  typy, 213
  ukończenie zadania, 197
  wykonywanie operacji, 194, 208
  wykonywanie zadań, 191
  zliczanie, 630
maszyna wirtualna Javy, 50, 521
materializacja, 504
mechanizm
  Java Object Serialization, 138
  partycjonowania, 262
  projekcji, 343
menedżer
  klastra, 536
  QJM, 67
  węzłów, 96, 544
  zasobów, 96, 171, 544
Mesos, 537
metadane plików, 80
metoda
  amap(), 658
  asCollection(), 506
  await(), 572
  cache(), 527, 528
  combineValues(), 492, 495, 510
  filter(), 519
  getArgToFuncMapping(), 428
  globStatus(), 82
  groupByKey(), 495, 510
  hadoopFile(), 524
  hflush(), 90
  hsync(), 90
  interrupt(), 591
  main(), 571
  map(), 45, 526
  parallelDo(), 493
  parse(), 163
  read(), 78
  reduce(), 658
  run(), 224, 507

Kup książkę Poleć książkę

metoda
seek(), 77
setJarByClass(), 48
setMapperClass(), 48
setOutputKeyClass(), 48
setOutputPath(), 48
setOutputValueClass(), 48
setReducerClass(), 48
setup(), 223
union(), 493
waitForCompletion(), 48
write(), 134, 593
model
MapReduce, 41, 45, 105, 120, 149
zapewniania spójności, 90, 91
modyfikowanie tabel, 473
monitorowanie, 320

N

nakładki typu Writable, 125
narzędzia
bazy HBase, 552
systemu Avro, 342
uniksowe, 42
ZooKeepera, 575
narzędzie
balancer, 93, 319, 324
Capacity, 103, 104
DAG, 535
dfsadmin, 316
distcp, 91
Fair, 105
fsck, 316, 324
GNU Readline, 406
import, 387
spark-submit, 521
Streaming, 195, 209, 221, 262
Streaming Hadoop, 57
nauka o danych biologicznych, 613
NCDC, 41
NFS, 73
niepowodzenie
menedżera węzła, 200
menedżera zasobów, 201
operacji, 198
zarządcy aplikacji, 199
niezarządzany zarządca aplikacji, 96
normalizowanie danych, 33
numery, 577

O

obiekt typu
ConfigUpdater, 590
Configuration, 550
PipeAssembly, 632
obliczanie średniej, 487
obliczeniowa funkcja UDF, 429
obserwatory, follower, 582
obsługa
kompresji, 117
konfiguracji, 151
nieprawidłowych danych, 177
serializacji, 137
odczyt danych
adres URL, 74
interfejs API FileSystem, 75
z plików, 140, 358
odgradzanie, 67
odmiany klasy MapFile, 146
określanie schematów, 344
Oozie, 186
opcje klasy
GenericOptionsParser, 160
ToolRunner, 160
operacje
mapowania, 51, 52
redukowania, 51
w systemie plików, 69
w usłudze ZooKeeper, 578
wejścia-wyjścia, 111
operacyjny przepływ danych, 605
operator, 433
CROSS, 439
FOREACH…GENERATE, 434
ILLUSTRATE, 409
JOIN, 436
STREAM, 435
operatory języka Pig Latin, 414

P

pakiet Kite SDK, 611
parametry dynamiczne, 444
Parquet, 353
konfiguracja, 358
model MapReduce, 362
odczyt plików, 358
struktura pliku, 357
typy proste, 354
zapis plików, 358
parsowanie rekordów, 163
partycje, 53, 370, 464
zbioru RDD, 529
partycjonowanie, 262
danych, 240
poziome, 238
Pig, 403
bazy danych, 410
filtrowanie danych, 434
Instalowanie platformy, 404
podstawianie wartości, 443
relacje anonimowe, 443
sortowanie danych, 441
tryby wykonywania kodu, 404
uruchamianie platformy, 404
uruchamianie programów, 406
wczytywanie danych, 433
współbieżność, 442
zapisywanie danych, 433
Pig Latin
funkcje, 423
funkcje UDF, 426
instrukcje, 412, 415
makra, 425
operatory, 433
diagnostyczne, 414
relacyjne, 414
schematy, 419
struktura, 411
typy danych, 418
wyrażenia, 417
plan wykonania potoku, 509
platforma
Apache Hadoop, 35
Flume, 365
Hadoop, 25, 275
Hive, 394, 445
Pig, 403
plik, 70
configuration-1.xml, 152
core-site.xml, 69
DOT, 508

Kup książkę Poleć książkę

fsimage, 311
hadoo-cluster.xml, 156
hadoop-local.xml, 156
POM Mavena, 154
tarball, 117
typu SequenceFile, 257
Widget.java, 393
pliki
bardzo duże, 61
binarne, 388
danych systemu Avro, 340, 470
dołączania, 325
dziennika edycji, 310
dzienników systemowych, 288
konfiguracyjne Hadoopa, 285
małe, 227
obrazu, 310
ORCFile, 470
Parqueta, 470
pomocnicze operacji, 212
RCFile, 470
SequenceFile, 470
tekstowe, 388
typu SequenceFile, 140, 231, 389, 401
plikowe struktury danych, 138
pobieranie
danych, 474
wartości liczników, 251
wyników, 174
podstawianie wartości zmiennych, 153
podzapytania, 479
podział
danych wejściowych, 118
na porcje, 228
pojedynczy punkt krytyczny, SPOF, 66
pola, 630
polecenia
języka Pig Latin, 415
narzędzia dfsadmin, 316
ZooKeepera, 569
polecenie
fsck, 64
hadoop, 50, 59
polimorfizm pojedynczego nukleotydu, 618
POM, Project Object Model, 154
pomocniczy węzeł nazw, 65
porcje
danych wejściowych, 51, 233
zdarzeń, 369
POSIX, 64
postęp, 196
potok, 506, 630
punkty kontrolne, 512
uruchamianie, 506
zatrzymywanie, 507
potoki łączące pola i krotki, 630
powłoka
Grunt, 406
platformy Hive, 446
rozproszona, 98
poziomy utrwalania, 528
procedury administracyjne, 322
proces mysqlimport, 400
profiler HPROF, 182
profilowanie operacji, 181
program, *Patrz* narzędzie
programowanie piśmienne, 621
programy szeregujące, 101, 299
projekcja, 361
projekt, 331
Cascading, 629
systemu HDFS, 61
protokół
RPC, 122
SSH, 283, 289
przebieg
testowy, 48
zadania, 532
przechowywanie danych, 29, 468
przełączanie awaryjne, 67, 378
przepływ
danych, 45, 51–54, 85, 485
operacyjny danych, 605
pracy, 182, 184, 188
sterowania, 416
przestawianie, 202
przesyłanie
zadania, 192, 532
zapytań, 553
przetwarzanie
danych, 433
danych z NCDC, 654
dużych zbiorów danych, 614
iteracyjne, 31
pliku jako rekordu, 229
rozproszone, 591
sieciowe, 33
strumieni, 31
w zapytaniach, 30
wsadowe, 30
z udziałem ochotników, 34
zapytań, 413
przypisywanie operacji do węzłów, 194
pula
bloków, 65
pamięci podręcznej, 65
punkt kontrolny, 312, 512
Python, 59, 341, 522

R

RAID, 29, 279
ratowanie życia, 613
RDBMS, 561
redukcja, 44, 203
reduktor, 46, 164
regiony, 543
rejestrowanie, 451
dziennika inspekcji, 315
informacji, 320
rekord, 51, 222, 498
repliki, 89
reprezentacje
generyczne, 336
typów, 336
rodzina kolumn, 543
rozbijanie problemu, 183
rozdzielanie danych pomocniczych, 268
rozkładanie obciążenia, 557
rozproszona pamięć podręczna, 269, 272
rozproszone
struktury danych, 596
systemy plików, 61
zadania, 56
rozsyłanie danych, 372
równowaga w klastrach, 92
równoważenie obciążenia, 380
RPC, remote procedure calls, 122
Ruby, 57

Kup książkę Poleć książkę

S

Scala, 520
scalanie
  plików, 143
  schematów, 422
schemat
  bazy danych, 386
  nadawcy, 343
  odbiorcy, 343
  odczytu, 361
sekwencje ucieczki, 399
selektor
  replikacji, 374
  rozsyłania, 374
serializacja
  danych, 122, 137, 333, 529
  funkcji, 502
serwis ShareThis, 638
sesje, 585
silnik
  koordynatora, 185
  przepływu pracy, 185
  wykonawczy, 451
skalowanie, 51
  systemu RDBMS, 562
skaner bloków, 318
skanery, 551
skrypty modelu MapReduce, 475
słowo kluczowe OVERWRITE, 448
sortowanie, 202, 253, 344, 349, 475
  częściowe, 254
  danych, 441
  plików, 143
  pomocnicze, 259
  temperatur, 260
  wszystkich danych, 255
  wyników, 635
Spark, 517
  aplikacje, 520
  etapy, 520
  instalowanie, 518
  menedżery klastra, 536
  model MapReduce, 525
  operacje, 520
  przebieg zadania, 532
  wykonawcy, 536
  YARN, 537
  zadania, 520
  zmienne współużytkowane, 530
specyfikacja
  klastra, 278
  SAM, 621
  systemu Avro, 333
spekulacyjne wykonywanie
  operacji, 209
SPOF, 66
spójność, 583
  kolejności, 584
sprawdzanie
  aktualizacji, 330
  poprawności, 421
  systemu plików, 316, 324
SQL, 457
Sqoop, 383
  eksport danych, 398
  import danych, 388, 389
  konektory, 385
  pobieranie, 383
  proces importu, 390
  przyrostowy import, 392
  transakcje, 401
  tryb bezpośredni, 393
Sqoop 2, 384
stany, 587
sterownik, 532
  JDBC, 452
  ODBC, 453
strona
  operacji, 176
  zadania, 173, 176
struktura
  DNA, 615
  katalogów węzła danych, 313
  katalogów węzła nazw, 309
struktury danych, 309
strumienie, 62
strumień
  CompressionOutputStream, 115
studia przypadków, 601
sygnatury, 214
system
  EMPI, 608, 609
  HDFS, 61, 290, 309, 564
  Oozie, 188
  RDBMS, 32
  YARN, 51, 95, 292
systemy
  plików w Hadoopie, 70
  serializacji, 333, 389
szafka, 281
szeregowanie, 101
  operacji, 535
  z opóźnieniem, 109

Ś

ścieżka
  do danych wejściowych, 224
  do klas, 168
ślad stosu, 321
środowisko
  programowania, 154
  wykonywania operacji, 208

T

tabela kodonów, 616
tabele, 542
  platformy Hive, 420, 463
  stron internetowych, 541
  zarządzane, 463
  zewnętrzne, 463
tasktracker, 99
technika fan out, 372
technologia
  JMX, 321
  Streaming, 655
tekst z ogranicznikami, 469
tekstowe dane wejściowe, 232
testowanie, 48
  mappera, 161
  sterownika, 166
testy
  jednostkowe, 161, 640
  porównawcze, 306
  porównawcze klastra, 305
token dostępu do bloku, 303
tokeny, 302
topologia sieci, 86, 280
transakcje, 368, 401, 456
transformacje, 524
transkrypcja, 616
translacja, 616

Kup książkę Poleć książkę

tryb
bezpieczny, 314
bezpośredni, 393
klastra z systemem YARN, 539
klienta systemu YARN, 537
niezależny, 582, 647
pseudorozproszony, 647
replikacji, 582
rozproszony, 649
tryby wykonywania kodu, 404
tworzenie
funkcji łączącej, 56
grupy, 571
katalogów, 80
katalogów użytkowników, 285
katalogu użytkownika, 649
kont użytkowników, 282
pakietu z zadaniem, 168
punktów kontrolnych, 512
punktu kontrolnego, 312
skierowanego grafu acyklicznego, 533
węzła znode, 571
zbiorów RDD, 523
tymczasowe węzły znode, 577
typ
Flow, 634
PCollection<S>, 497
Scheme, 634
Tap, 634
typy
danych platformy Hive, 460
danych systemu Avro, 334
danych w języku IDL, 605
operacji, 633
potoków, 631
w modelu MapReduce, 213

U

ujście typu hdfs, 370
ukończenie zadania, 197
Unicode, 128
uprawnienia
do plików, 70
z list ACL, 582
uruchamianie
demonów, 284, 649
interfejsu HDFS, 68
kodu, 164
platformy Hive, 449
potoku, 506
programów w klastrze, 167
systemu ZooKeeper, 568
wykonawców Sparka, 538, 539
zadania, 169
usługa
rejestrująca zdarzenia, 597
SSH, 648
ZooKeeper, 567, 576
usługi platformy Hive, 451
usprawnienia
w zabezpieczeniach, 303
ustawianie tożsamości użytkownika, 157
ustawienia
pamięci, 293
protokołu SSH, 289
systemu YARN, 295
ustrukturyzowane dane, 33
usuwanie
danych, 84
grupy, 575
rekordów, 427
tabel, 474
węzłów, 324, 325
utrwalanie
danych, 527
partycji, 528
uwzględnianie schematu
przy odczycie, 456
przy zapisie, 456
używanie
schematu, 433
ujść, 378

W

warstwy agentów, 374
wartości, 221
wartości liczników, 251
wartość null, 421
wczytywanie
danych, 430, 433, 555
masowe danych, 557
wejście STDIN, 57
wejściowe porcje danych, 222
węzeł
akcji, 185
danych, 64, 544
dziennika, 67
nadrzędny, 544
nazw, 64, 544
pasywny obserwujący, 598
rezerwowy, 66
sekwencyjny, 577
sterowania przepływem, 185
trwały, 572
tymczasowy, 572
tymczasowy znode, 577
znode, 570
widoki, 480
wielkość
bloku, 298
bufora, 298
klastra, 279
sterty, 288
strony słownika, 357
wiersz poleceń, 68
właściwości
demona systemu HDFS, 292
demona systemu YARN, 293
Hadoopa, 298
klasy ParquetOutputFormat, 358
kodeków, 117
kompresji, 121
kompresji danych wyjściowych, 122
magazynu metadanych, 455
serwera HTTP, 297
serwera RPC, 296
związane z trybem bezpiecznym, 314
właściwość
dfs.replication, 68
fs.defaultFS, 68
wolumin przestrzeni nazw, 65
wskaźniki, 321, 565
współbieżność, 442
współczynnik scalania, 204
współdziałanie języków, 341
wstawianie danych do wielu tabel, 473
wyjątek
InterruptedException, 591
KeeperException, 591
SessionExpiredException, 594

Kup książkę Poleć książkę

wyjątki
umożliwiające wznowienie pracy, 592, 596
związane ze stanem, 592
wykonawcy, 532, 536
wykonywanie
grup operacji, 579
operacji, 194, 208, 536
potoku, 506
spekulacyjne, 209
wykorzystywanie
kompresji, 120
wielokrotne obiektów, 503
wyrażenia, 417
wyszukiwanie, 31
bloków pliku, 318
maksymalnej temperatury, 270, 521
wyświetlanie
członków grupy, 574
list plików, 81
zawartości plików, 143
wywłaszczanie, 108
wyznaczanie maksymalnej temperatury, 490
wyzwalacze czujek, 580
wzorce reprezentujące pliki, 82

X

XML, 235

Y

YARN, 95, 537
budowanie aplikacji, 98
struktura działania aplikacji, 96
szeregowanie, 101
żądania zasobów, 97

Z

zadania użytkowników, 307
zadanie, 51
domyślne, 216
zagregowane dane, 606
zapis
bloku, 65
danych, 78, 433
do pliku, 87, 139
plików, 358
zapytania
interaktywne, 558
o odczyty, 559
o stacje, 558
w systemie plików, 80
zarządca aplikacji, 96
zarządzanie
blokadami, 594
konfiguracją, 155, 588, 593
platformą Hadoop, 309
zatrzask, latch, 572
zatrzymywanie
demonów, 284, 649
potoku, 507
zbiory
danych
docelowe, 500
źródłowe, 500
zbiory RDD, 523, 534
zdalne
diagnozowanie, 180
wywołania procedur, RPC, 122
zdalny magazyn metadanych, 455
zestaw, ensemble, 582
zgodność, 328
zliczanie
k-merów, 624
słów, 635
złączanie, 264
danych, 436
po stronie mapowania, 265
po stronie redukcji, 265
złączenia, 476
częściowe, 478
na etapie mapowania, 479
wewnętrzne, 264, 476
zewnętrzne, 478
zmienna
HADOOP_CLASSPATH, 50
zmienne
rozsyłane, 531
środowiskowe, 209
współużytkowane, 530
znacznik synchronizacji, 340
znaki Unicode, 128
ZooKeeper, 567
aktualizacja, 584
budowanie aplikacji, 588
implementacja, 582
instalowanie, 568
interfejsy API, 579
konfiguracja, 599
model danych, 576
odporność, 598
operacje, 578
przynależność do grupy, 570
rozproszone struktury danych, 596
sesje, 585
spójność, 583
stany, 587
środowisko produkcyjne, 597
uruchamianie, 568
wydajność, 598
wyjątki, 591

Ź

źródło, 502

Ż

żądania zasobów, 97

Kup książkę Poleć książkę

PROGRAM PARTNERSKI

GRUPY WYDAWNICZEJ HELION

1. ZAREJESTRUJ SIĘ
2. PREZENTUJ KSIĄŻKI
3. ZBIERAJ PROWIZJĘ

Zmień swoją stronę WWW
w działający bankomat!

Dowiedz się więcej i dołącz już dzisiaj!

http://program-partnerski.helion.pl

GRUPA WYDAWNICZA
Helion SA

O'REILLY®

Analiza danych z Hadoopem — i wszystko staje się prostsze!

Platforma Apache Hadoop to jedno z zaawansowanych narzędzi informatycznych. Dzięki niej można przeprowadzać różne operacje na dużych ilościach danych i znacznie skrócić czas wykonywania tych działań. Wszędzie tam, gdzie potrzebne jest szybkie sortowanie, obliczanie i archiwizowanie danych – np. w dużych międzynarodowych sklepach internetowych, serwisach społecznościowych lub wyszukiwarkach, takich jak Amazon, Facebook, Yahoo!, Apache Hadoop sprawdza się znakomicie. Jeśli potrzebne Ci narzędzie do poważnej analizy dużych zbiorów danych, nie znajdziesz lepszego rozwiązania!

Tę książkę napisał wytrawny znawca i współtwórca Hadoopa. Przedstawia w niej wszystkie istotne mechanizmy działania platformy i pokazuje, jak efektywnie jej używać. Dowiesz się stąd, do czego służą model MapReduce oraz systemy HDFS i YARN. Nauczysz się budować aplikacje oraz klastry. Poznasz dwa formaty danych, a także wykorzystasz narzędzia do ich pobierania i transferu. Sprawdzisz, jak wysokopoziomowe narzędzia do przetwarzania danych współdziałają z Hadoopem. Zorientujesz się, jak działa rozproszona baza danych i jak zarządzać konfiguracją w środowisku rozproszonym. Przeczytasz również o nowinkach w Hadoopie 2 i prześledzisz studia przypadków ilustrujące rolę tej platformy w systemach służby zdrowia i przy przetwarzaniu danych o genomie.

Tom White – jeden z czołowych ekspertów w zakresie obsługi platformy Hadoop. Członek Apache Software Foundation, inżynier oprogramowania w firmie Cloudera.

Przeczytaj i poznaj:

- Hadoop i model MapReduce
- Systemy HDFS i YARN
- Avro, Parquet, Flume i Sqoop – metody pracy z danymi
- Pig, Hive, Crunch i Spark – wysokopoziomowe narzędzia do przetwarzania danych

Helion

38625 numer katalogowy

księgarnia internetowa

http://helion.pl

zamówienia telefoniczne

0 801 339900

0 601 339900

Sprawdź najnowsze promocje:
● http://helion.pl/promocje
Książki najchętniej czytane:
● http://helion.pl/bestsellery
Zamów informacje o nowościach:
● http://helion.pl/nowosci

Helion SA
ul. Kościuszki 1c, 44-100 Gliwice
tel.: 32 230 98 63
e-mail: helion@helion.pl
http://helion.pl

Informatyka w najlepszym wydaniu

sięgnij po WIĘCEJ

KOD KORZYŚCI

ISBN 978-83-283-1457-3

9 788328 314573

cena: 89,00 zł