

Indice generale

Introduzione	xiii
Struttura del libro	xiii
Cosa serve per questo libro	xiv
Lo scopo del libro	xiv
Convenzionixv
Codice degli esempi.....	.xv
Gli autori.....	xvii
I revisori.....	xix
Capitolo 1 Per iniziare.....	1
Una nota sulle versioni.....	1
Panoramica su Hadoop	2
Componenti di Hadoop	3
Componenti comuni	4
Storage	4
Calcolo.....	5
Meglio se insieme	5
Hadoop 2: dov'è l'affare?.....	6
Storage in Hadoop 2.....	6
Calcolo in Hadoop 2	7
Distribuzioni di Apache Hadoop	9
Un doppio approccio.....	10
AWS: infrastruttura on demand di Amazon.....	10
Simple Storage Service (S3)	10
Elastic MapReduce (EMR)	10
Come iniziare	11
Cloudera QuickStart VM.....	11
Amazon EMR.....	11

Utilizzare Elastic MapReduce	12
Rendere Hadoop operativo	12
L'interfaccia AWS a riga di comando.....	14
Eseguire gli esempi	15
Elaborazione dei dati con Hadoop	16
Perché Twitter?	16
Creare il primo dataset.....	16
Accesso programmato con Python	19
Riepilogo	21

Capitolo 2 Storage23

Funzionamento interno di HDFS	23
Avvio del cluster	24
Replica dei blocchi.....	25
Accedere al file system HDFS tramite riga di comando	25
Esplorare il file system HDFS	26
Proteggere i metadati del file system.....	27
Il Secondary NameNode non ci salva	28
NameNode HA di Hadoop 2	28
Configurazione del client.....	29
Come funziona un failover	29
Apache ZooKeeper: un file system diverso	30
Implementare un lock distribuito con ZNode sequenziali	31
Implementare l'adesione a un gruppo e l'elezione di un leader usando ZNode effimeri	32
API Java	33
Componenti.....	33
Per saperne di più	33
Failover automatico dei NameNode.....	33
Snapshot HDFS	34
File system di Hadoop	36
Interfacce di Hadoop	37
Gestire e serializzare i dati	37
L'interfaccia Writable	37
Le classi wrapper.....	38
Classi wrapper per gli array	38
Le interfacce Comparable e WritableComparable	39
Storage dei dati	39
Serializzazione e contenitori	39
Compressione	39
Formati di file general purpose	40
Formati di dati orientati alle colonne	41
Riepilogo	45

Capitolo 3 Elaborazione: MapReduce e oltre.....	47
MapReduce.....	47
API Java per MapReduce.....	48
La classe Mapper.....	49
La classe Reducer	50
La classe Driver.....	51
Combiner.....	52
Partizionamento dei file	53
Implementazione dei mapper e dei reducer forniti da Hadoop	54
Condividere i dati di riferimento	54
Scrivere programmi MapReduce	55
Come iniziare.....	55
Eseguire gli esempi	55
WordCount, l>Hello World di MapReduce.....	56
Co-occorrenze di parole.....	59
Trending topic.....	60
Sentiment degli hashtag	64
Pulizia del testo con ChainMapper	67
Panoramica sull'esecuzione di un job di MapReduce	70
Avvio	70
Suddividere l'input	71
Assegnazione delle attività.....	71
Avvio dell'attività.....	71
Monitorare il lavoro del Job Tracker.....	72
Input della classe Mapper	72
Esecuzione del mapper	72
Output del mapper e input del reducer	73
Input del reducer	73
Esecuzione del reducer	73
Output del reducer.....	73
Chiusura.....	73
Input/Output	74
InputFormat e RecordReader	74
La classe InputFormat fornita da Hadoop.....	75
La classe RecordReader fornita da Hadoop.....	75
OutputFormat e RecordWriter	75
La classe OutputFormat fornita da Hadoop	76
SequenceFile	76
YARN	76
L'architettura di YARN	77
Ciclo di vita di un'applicazione YARN	78
Pensare a livelli	80
Modelli di esecuzione.....	80

YARN nel mondo reale: il calcolo oltre MapReduce	81
Il problema con MapReduce	81
Tez	81
Apache Spark	84
Apache Samza	85
YARN oggi e oltre	86
Riepilogo	86

Capitolo 4 Computazione in tempo reale con Samza89

Elaborazione degli stream con Samza	89
Come funziona Samza	90
L'architettura ad alto livello di Samza.....	90
Il miglior amico di Samza: Apache Kafka.....	91
Integrazione con YARN	92
Un modello indipendente	93
Hello Samza!	93
Creare un job di parsing di un tweet.....	94
Il file di configurazione.....	95
Portare i dati di Twitter in Kafka	97
Eseguire un job di Samza	98
Samza e HDFS	99
Windowing	99
Flussi di lavoro con più job	101
Sentiment analysis dei tweet.....	102
Attività stateful	107
Riepilogo	110

Capitolo 5 Computazione iterativa con Spark.....111

Apache Spark.....	112
Computazione dei cluster con i working set.....	112
Distribuzione.....	114
Iniziare con Spark.....	115
Scrivere ed eseguire applicazioni standalone	116
L'ecosistema di Spark	119
Spark Streaming	119
GraphX	119
MLlib	119
Spark SQL.....	120
Elaborare i dati con Apache Spark	120
Costruire ed eseguire gli esempi	120
Elaborazione dei dati sugli stream.....	123
Analisi dei dati con Spark SQL	125
Spark e Samza Streaming a confronto.....	127
Riepilogo	128

Capitolo 6	Analisi dei dati con Apache Pig.....	129
Panoramica su Pig.....	130	
Per iniziare.....	131	
Eseguire Pig.....	131	
Grunt, la shell interattiva di Pig.....	132	
Fondamenti di Apache Pig.....	133	
Programmare Pig.....	135	
Tipi di dati di Pig	135	
Funzioni di Pig.....	136	
Lavorare con i dati	138	
Estendere Pig (UDF)	141	
Repository di UDF.....	141	
Analizzare lo stream di Twitter.....	142	
Prerequisiti	142	
Esplorazione del dataset	142	
Metadati dei tweet.....	143	
Preparazione dei dati.....	143	
Statistiche top n	144	
Manipolazione di datetime.....	146	
Catturare le interazioni dell'utente	147	
Analisi dei link.....	149	
Utenti influenti.....	150	
Riepilogo	153	
Capitolo 7	Hadoop e SQL.....	155
Perché SQL su Hadoop	156	
Altre soluzioni SQL su Hadoop	156	
Prerequisiti	156	
Panoramica su Hive	158	
La natura delle tabelle di Hive.....	160	
L'architettura di Hive	160	
Tipi di dati	161	
Istruzioni DDL.....	161	
Formati di file e storage	163	
Query	167	
Strutturare le tabelle di Hive per i vari carichi di lavoro.....	169	
Partizionare una tabella	169	
Scrivere degli script	175	
Hive e Amazon Web Services	175	
Hive e S3	175	
Hive su Elastic MapReduce	177	
Estendere HiveQL	177	
Interfacce programmatiche.....	179	
JDBC	179	
Thrift	181	

L'iniziativa Stinger.....	182
Impala	183
L'architettura di Impala	184
Coesistenza con Hive.....	184
Una filosofia diversa.....	185
Drill, Tajo e oltre.....	186
Riepilogo	186
Capitolo 8 Gestione del ciclo di vita dei dati.....	189
Cos'è la gestione del ciclo di vita dei dati	189
Importanza della gestione del ciclo di vita dei dati.....	190
Strumenti di supporto.....	190
Costruire la capacità per l'analisi dei tweet	190
Ottenere i dati dei tweet.....	191
Oozie	191
Produrre dati derivati.....	204
Le sfide dei dati esterni	209
Validazione dei dati.....	210
Gestire le modifiche al formato.....	211
Gestire l'evoluzione dello schema con Avro.....	211
Raccogliere dati supplementari	216
Programmare i workflow	216
Altri trigger di Oozie	218
Assemblare il tutto	219
Altri strumenti di supporto	219
Riepilogo	220
Capitolo 9 Facilitare il lavoro di sviluppo.....	221
Scegliere un framework.....	221
Hadoop Streaming.....	222
Conteggio delle parole in streaming in Python.....	223
Differenze tra i job quando si usa lo streaming	225
Trovare parole importanti nel testo.....	225
Kite Data	231
Data Core.....	231
Data HCatalog.....	232
Data Hive	233
Data MapReduce	233
Data Spark.....	233
Data Crunch	233
Apache Crunch	234
Per iniziare	235
Concetti	235
Serializzazione dei dati.....	236
Pattern di elaborazione dei dati	237

Implementazione ed esecuzione delle pipeline	238
Esempi di Crunch	239
Kite Morphlines	243
Riepilogo	250
Capitolo 10 Eseguire un cluster Hadoop	251
Sono uno sviluppatore, le operations non mi interessano!	251
Best practice per Hadoop e DevOps	252
Cloudera Manager	252
Pagare o non pagare?	253
Gestione dei cluster con Cloudera Manager	253
Monitorare con Cloudera Manager.....	254
API Cloudera Manager.....	255
Il lock-in di Cloudera Manager	255
Ambari, l'alternativa open source	256
Le operations nel mondo di Hadoop 2	256
Condividere le risorse	258
Costruire un cluster fisico	258
Layout fisico	259
Costruire un cluster su EMR	261
Considerazioni sui file system	262
Ottenere i dati in EMR	262
Istanze di EC2 e raffinamento	263
Raffinamento dei cluster.....	263
Considerazioni sulla JVM	263
Ottimizzazione di map e reduce	264
Sicurezza.....	264
Evoluzione del modello di sicurezza di Hadoop	265
Oltre l'autorizzazione di base	265
Il futuro della sicurezza di Hadoop.....	266
Conseguenze dell'uso di un cluster protetto	266
Monitorare	267
Hadoop, dove i fallimenti non contano	267
Monitoraggio integrato	267
Metriche a livello di applicazione.....	268
Risoluzione dei problemi.....	268
Livelli di log	269
Accedere ai logfile	270
ResourceManager, NodeManager e Application Manager	272
NameNode e DataNode.....	279
Riepilogo	279
Capitolo 11 Come proseguire.....	283
Distribuzioni alternative	284
Distribuzione di Cloudera per Hadoop	284
Hortonworks Data Platform	285

MapR	285
E il resto.....	286
Scegliere una distribuzione	286
Altri framework di calcolo	286
Apache Storm	286
Apache Giraph	287
Apache HAMA	287
Altri progetti interessanti.....	287
HBase.....	287
Sqoop.....	288
Whirr.....	288
Mahout	289
Hue.....	289
Altre astrazioni di programmazione	291
Cascading	291
Risorse per gli AWS.....	292
SimpleDB e DynamoDB	292
Kinesis.....	292
Data Pipeline	293
Fonti di informazione	293
Codice sorgente.....	293
Mailing list e forum	293
Gruppi di LinkedIn	294
HUG	294
Conferenze.....	294
Riepilogo	294
Indice analitico.....	295