

Apache Spark Grundlagen

Seminarunterlage

Version: 1.02



Dieses Dokument wird durch die ORDIX AG veröffentlicht.

Copyright ORDIX AG. Alle Rechte vorbehalten.

Alle Produkt- und Dienstleistungs-Bezeichnungen sind Warenzeichen oder eingetragene Warenzeichen der jeweiligen Firmen und beziehen sich auf Eintragungen in den USA oder USA-Warenzeichen.

Weitere Logos und Produkt- oder Handelsnamen sind eingetragene Warenzeichen oder Warenzeichen der jeweiligen Unternehmen.

Kein Teil dieser Dokumentation darf ohne vorherige schriftliche Genehmigung der ORDIX AG weitergegeben oder benutzt werden.

Adressen der ORDIX AG

Die ORDIX AG besitzt folgende Geschäftsstellen

ORDIX AG
Karl-Schurz-Straße 19a
D-33100 Paderborn
Tel.: (+49) 0 52 51 / 10 63 - 0
Fax.: (+49) 01 80 / 1 67 34 90

ORDIX AG
An der alten Ziegelei 5
D-48157 Münster
Tel.: (+49) 02 51 / 9 24 35 – 00
Fax.: (+49) 01 80 / 1 67 34 90

ORDIX AG
Welser Straße 9
D-86368 Gersthofen
Tel.: (+49) 08 21 / 507 492 – 0
Fax.: (+49) 01 80 / 1 67 34 90

ORDIX AG
Kreuzberger Ring 13
D-65205 Wiesbaden
Tel.: (+49) 06 11 / 7 78 40 – 00
Fax.: (+49) 01 80 / 1 67 34 90

ORDIX AG
Wikingerstraße 18-20
D-51107 Köln
Tel.: (+49) 02 21 / 8 70 61 – 0
Fax.: (+49) 01 80 / 1 67 34 90

ORDIX AG
Südwestpark 67/2
D-90449 Nürnberg
Tel.: (+49) 0 52 51 / 10 63 - 0
Fax.: (+49) 01 80 / 1 67 34 90

Internet: <http://www.ordix.de>

Email: seminare@ordix.de

Inhaltsverzeichnis

1	Einführung	7
1.1	Definition	8
1.2	Spark auf einen Blick	11
1.3	Spark Geschichte	12
1.4	Spark Anwendungsfälle	13
1.5	Spark Performance	14
1.6	Seminar Ablauf.....	15
1.7	Agenda – Einführung in Spark	16
1.8	Spark Überblick.....	17
1.8.1	Spark Engine	18
1.8.2	Spark Bibliotheken	19
1.8.3	Spark Programmierung.....	20
1.8.4	Spark Management	21
1.8.5	Spark Storage	22
1.9	Spark im Hadoop Kontext	23
1.10	Grundproblem Big Data	24
1.11	MapReduce	26
1.11.1	MapReduce Programmiermodell	27
1.11.2	Probleme der Hadoop MapReduce Implementierung.....	28
1.11.3	MapReduce Wordcount Beispiel.....	29
1.12	Lösungen.....	30
1.13	Spark Wordcount Beispiel.....	31
1.14	MapReduce vs. Spark.....	32
1.15	Spark Kernidee	33
1.16	Architektur: Driver und Executors	34
1.17	Arbeiten im Seminar - Infrastruktur	35
2	Spark Core	40
2.1	Agenda.....	41
2.2	Einordnung.....	42
2.3	Resilient Distributed Dataset (RDD)	43
2.4	Konzept	44
2.4.1	Laziness	45
2.4.2	Partitionierung	46
2.4.3	Unveränderlichkeit.....	47
2.4.4	Lineage.....	48
2.5	Programmier-Modell in Spark	49
2.6	SparkContext	50
2.7	Erstellen von RDDs.....	51
2.8	RDD Operationen.....	52
2.9	Shuffling	53
2.10	Transformations	54
2.11	Actions.....	55
2.12	Exkurs: Lambda in Python	56
2.13	Transformations (mit Lambda).....	57
2.14	Actions (mit Lambda)	58
2.15	Key-Value RDDs	59
2.16	Transformations (Key-Value RDDs)	60
2.17	Actions (Key-Value RDDs).....	61
2.18	Best Practice	62
2.18.1	groupByKey vs. reduceByKey.....	62
2.18.2	reduceByKey vs. aggregateByKey.....	63
2.18.3	flatMap – join – groupBy.....	64
2.18.4	Wann lohnt sich Shuffling?.....	65
2.19	Partitionierung	66
2.20	Persistenz.....	67
2.21	Storage Level	68
2.22	Closures	69

2.22.1	Closures in Spark	70
2.22.2	Beispiele	71
2.23	Geteilte Variablen	72
2.23.1	Broadcast-Variablen	73
2.23.2	Accumulator-Variablen	74
2.24	Ablauf	75
3	Architektur	76
3.1	Agenda	77
3.2	Spark Applikation – Übersicht	78
3.3	Directed Acyclic Graph (DAG)	79
3.4	Spark Architektur	81
3.5	Deployment	82
3.5.1	Deployment Mode – Local Mode	82
3.5.2	Deployment Mode – Client Mode	83
3.5.3	Deployment Mode – Cluster Mode	84
3.6	Cluster Manager	85
3.6.1	Spark Local Mode	86
3.6.2	Spark mit YARN – Client Mode	87
3.6.3	Spark mit YARN – Cluster Mode	88
3.6.4	Spark mit Mesos	89
3.6.5	Spark Standalone	90
3.7	Pyspark	91
3.8	Exkurs in die Java Welt	92
3.9	Typen von RDDs	93
3.9.1	Typen von RDDs – Beispiele	94
3.9.2	Weitere Typen	95
3.10	RDD Abstract Class	96
3.10.1	Beispiel: HadoopRDD	97
3.10.2	Beispiel: FilteredRDD	98
3.11	Funktionen (Java)	99
3.12	Python vs. Scala vs. Java	100
3.13	Ablauf	101
4	Spark SQL	102
4.1	Ablauf	103
4.2	Agenda	104
4.3	Einordnung	105
4.4	Prozedurale vs. relationale API	106
4.5	DataFrame vs. SQL	107
4.6	DataFrame (relationale API)	108
4.6.1	Caching von DataFrames	109
4.6.2	Repräsentation von DataFrames	110
4.6.3	Datentypen in Spark SQL	111
4.6.4	Datenstruktur in Spark SQL	112
4.6.5	Wo finde ich Funktionen?	113
4.7	Ausführungspläne	114
4.8	Catalyst Optimizer	115
4.9	SparkSession	116
4.10	Zusammenfassung Spark SQL Architektur	117
4.11	Typischer Workflow	118
4.11.1	Workflow: Einlesen	119
4.11.2	Workflow: Transformieren	120
4.12	Typischer Workflow – Einlesen	123
4.12.1	Datenquellen	124
4.12.2	Daten aus dem HDFS laden	125
4.12.3	Daten aus Hive laden	126
4.12.4	Daten aus HBase laden	127
4.12.5	Python Objekte aus dem Driver laden	128
4.12.6	Pandas Dataframe aus dem Driver laden	129

4.12.7	Daten aus einer relationalen Datenbank laden	130
4.12.8	Daten verifizieren	131
4.12.9	Spalten verändern	132
4.12.10	Umgang mit Null-Werten	133
4.13	Typischer Workflow – Transformieren	134
4.13.1	Expressions	135
4.13.2	Zeilen filtern	136
4.13.3	Spalten ändern und hinzufügen	137
4.13.4	Funktionen	138
4.13.5	Bedingte Änderungen	140
4.13.6	Benutzerdefinierte Funktionen	141
4.13.7	Aggregieren	142
4.13.8	Joins	143
4.14	Typischer Workflow – Exportieren	144
4.14.1	Daten speichern	145
4.14.2	Daten schreiben – Pattern	146
4.14.3	Daten in den Driver laden	147
4.15	SQL API	148
4.15.1	Tables und Views	149
4.15.2	Databases und Catalog	150
4.15.3	Tables erstellen	151
4.15.4	Views erstellen	152
4.15.5	Queries	153
4.15.6	Beispiel: Iteratives Vorgehen mit Tables und Views	154
4.16	Nahtlose Integration der APIs	155
4.17	Fazit Spark SQL	156
4.18	Runtime safety: SQL vs. DataFrame vs. Dataset	157
5	Administration	158
5.1	Agenda	159
5.2	Monitoring	160
5.3	Testing	161
5.4	Spark-Konfiguration	162
5.5	Application Properties	163
5.6	Spark Properties	164
5.7	Memory Management	165
5.7.1	OOM Driver	166
5.7.2	OOM Executor	167
5.8	Security	169
5.9	Spark Speculation	170
5.10	Spark mit YARN - Ressourcen	171
5.11	Spark mit YARN – Settings	172
5.12	YARN Scheduler	173
5.12.1	FIFO Scheduler	174
5.12.2	Capacity Scheduler	175
5.12.3	Fair Scheduler	176
5.12.4	YARN Scheduler Konfiguration	177
5.12.5	YARN Scheduler Web UI	178
5.13	„yarn“ Kommando	179
5.14	Ablauf	180
6	Weitere Bibliotheken	181
6.1	Agenda	182
6.2	Spark Streaming	183
6.2.1	Prinzip	184
6.2.2	Streaming Context	185
6.2.3	DStreams	186
6.2.4	Erstellen von DStreams	187
6.2.5	Operationen auf DStreams	188
6.2.6	Data Flow	189

6.2.7	Spark Structured Streaming.....	190
6.2.8	Datenstrom als Tabelle	191
6.2.9	Datenverarbeitung.....	192
6.2.10	Output Modus.....	193
6.3	Machine Learning.....	194
6.3.1	Machine Learning Workflow	195
6.3.2	Spark MLlib	196
6.3.3	ML-Algorithmen	197
6.3.4	Decision Tree	198
6.3.5	Lineare Regression	199
6.3.6	Logistische Regression	200
6.3.7	ML-Datentypen.....	201
6.3.8	Spark MLlib APIs.....	202
6.3.9	MLlib RDD API: Decision Tree.....	203
6.3.10	MLlib RDD API: Lineare Regression.....	204
6.3.11	MLlib DataFrame API	205
6.3.12	ML-Pipelines.....	206
6.3.13	PipelineModel.....	207
6.3.14	Beispiele.....	208
6.4	GraphX.....	209
6.4.1	Graphverarbeitung	210
6.4.2	Beispiele.....	211
6.4.3	GraphX vs. Graphframes	212
6.4.4	Property Graph.....	213
6.4.5	Graph-Operationen	214
6.5	Ablauf.....	215
7	Fazit und Ausblick.....	216
7.1	Agenda.....	217
7.2	Zusammenfassung.....	218
7.3	Ausblick und News.....	219
7.4	Literatur	220