

Obsah

Kapitola 1 - Projekt EverGreen	9
Kapitola 2 - Úvod do datové vědy (data science)	13
2.1 Koncept velkých dat ve srovnání s tradičními zdroji	13
2.2 Problémy při práci s big daty	15
2.3 Struktura dat a její význam v datové vědě	16
2.4 Strukturovaná data vs. nestrukturovaná data: Překlenutí informační propasti	17
2.5 Odhalení rozmanitosti reprezentace dat	17
2.6 Techniky předzpracování dat	17
2.6.1 Čištění dat (data cleaning)	17
2.6.2 Normalizace dat (data normalization)	18
2.7 Ukládání dat – relační databáze, databáze NoSQL a datová jezera (data lakes)	18
2.8 Techniky zpracování a analýzy dat: poznatky získané pomocí strojového učení, zpracování přirozeného jazyka a technik vizualizace dat	19
Kapitola 3 - Cíle udržitelného rozvoje	21
Kapitola 4 - Propojení statistiky a analýzy dat	25
4.1. Charakteristiky polohy: "srdce" dat	25
4.1.1. Průměr	25
4.1.2. Medián	26
4.1.3. Modus	26
4.2. Míry variability	26
4.2.1. Rozsah	26
4.2.2. Rozptyl	26
4.2.3. Směrodatná odchylka	27
4.2.4. Standardní chyba	27
4.3. Histogramy a krabicové grafy	27
4.4.1. Z – test	31
4.4.2. T-test	31
4.4.3. Chi-kvadrát test	31
4.5. Regresná analýza	33
4.5.1. Lineární regrese	33
4.5.2. Vícenásobná lineární regrese	34
4.5.3. Provedení vícenásobné lineární regrese v aplikaci Excel	34
4.6. Klasifikace a její aplikace	36
4.6.1. Logistická regrese	37
Kapitola 5 - Formáty vstupních údajov	39
5.1 Tabulkový procesor (XLSX)	39
5.2 Hodnoty oddělené čárkou (CSV)	40
5.3 eXtensible Markup Language (XML)	41
5.4 Objektová notace jazyka JavaScript (JSON)	41
5.5 YAML Ain't Markup Language (YAML)	42
5.6 RESTful Services	42
5.7 Digital Video Archive (DVA)	43
5.8 Streamové dátové formáty	44
5.9 Databázové tabulky	44
5.10 Externí tabulky	45
5.11 Další datové formáty	46
Kapitola 6 - Nástroje na analýzu údajov	49
6.1 Microsoft Excel	49
6.2 Python	50
6.3 R	51
6.4 Tableau	52
6.5 Apache Spark	52

6.6	SAS	53
6.7	Power BI	53
6.8	Orange.....	54
6.9	JupyterLab.....	55
6.10	KNIME	55
6.11	Oracle Analytics Cloud.....	56
Kapitola 7 - Analýza dat v SQL	59	
7.1	Podpora transakcí	59
7.2	Normalizace dat	60
7.3	Index	62
7.3.1	ROWID	62
7.3.2	Správa indexů.....	62
7.3.3	Typy indexů.....	63
7.3.4	Metody přístupu	66
7.4	Získání dat - příkaz SELECT	66
7.5	Plán provádění dotazu	67
7.6	Agregační funkce	69
7.6.1	Zohlednění jedinečných hodnot	72
7.6.2	Rozšíření Rollup a Cube.....	72
7.6.3	Omezení na základě aggregačních funkcí	74
7.6.4	Získání hodnoty na základě aggregačních funkcí.....	75
7.6.5	Klauzula Fetch First	77
7.6.6	Třídění na základě nejednotných dat	78
7.7	Analytické funkce	81
7.7.1	Pravidlo Top-N.....	82
7.7.2	Filtrování na základě analytiky	83
7.7.3	NULL hodnoty a analytika	84
7.7.4	Analýza řízení času	85
7.7.5	Nth_value	87
7.7.6	Množina dat.....	89
7.7.7	Půjčovna aut	90
7.7.8	Sledování teploty pomocí analytických funkcí Lead a Lag.....	91
7.7.9	Rozšířené klauzuly analytických funkcí.....	95
7.7.10	Externí tabulky	98
Kapitola 8 - Dátové sklady a tržiště (data warehouses and marts)	101	
8.1	Datový sklad (DWH)	101
8.2	BI.....	106
Kapitola 9 - Oracle Data Integrator	109	
Kapitola 10 - Úvod do programovacieho jazyka Python	125	
10.1	Příkazy a funkce	127
10.2	Knihovny pro analýzu dat v jazyce Python	130
10.2.1	Knihovna NumPy	130
10.2.2	Knihovna Pandas.....	133
10.3	Vizualizace údajů.....	146
10.3.1	Čárový graf (line chart)	146
10.3.2	Sloupcový graf (bar chart).....	147
10.3.3	Bodový graf (scatter plot).....	148
10.3.4	Koláčový graf (pie chart)	149
10.3.5	Histogram	150
10.3.6	Krabicový graf (box plot).....	152
10.3.7	Houslový graf (violin graph)	153
10.3.8	Teplotní mapa (heat-map)	154
10.3.9	Bublinový graf (bubble chart)	155
10.4	Strojové učení v programovaícím jazyce Python	158
10.4.1	Lineárna regrese	158
10.4.2	Neurónová síť	160

10.4.3	Algoritmus K-means	162
10.4.4	Algoritmus K-nejbližších sousedů (K-nearest neighbors – KNN)	163
Kapitola 11 -	Analýza dat v Apache Spark.....	167
11.1	Hadoop.....	167
11.2	Klastry pro BigData.....	167
11.3	Apache Spark a programovací jazyky	168
11.4	Základní principy práce s velkými daty (ve Sparku)	172
11.4.1	Základní Python knihovny pro analýzu dat	172
11.4.2	Pandas	173
11.4.3	DataFrames.....	173
11.4.4	DataFrame v systému Spark	176
11.5	Používání jazyka SQL ve Sparku	177
11.6	NumPy	178
11.7	Matplotlib	179
11.8	SciPy.....	179
11.9	TensorFlow, PyTorch a Keras	179
11.10	Externí datové zdroje	180
11.10.1	Soubory CSV	180
11.10.2	Databáze Oracle	180
11.10.3	MS SQL server	180
11.11	Paralelní zpracování.....	180
11.11.1	RDD	180
11.11.2	Map a Reduce	181
11.11.3	Funkce pro transformační struktury	182
11.11.4	Události	182
Kapitola 12 -	Služby Oracle Cloud Infrastructure.....	183
12.1	Specifikace připojení v nástroji SQL Developer Desktop	204
12.2	SQL*Plus - konzolový klient.....	207
12.2.1	Alternativa 1 - úplná definice	208
12.2.2	Alternativa 2 – identifikátory připojení	209
12.2.3	Komentáře	213
12.2.4	Připojení a ukončení relace	213
Kapitola 13 -	Služby OCI Analytics.....	215
13.1	Úvod do analytiky prostřednictvím služeb OCI	215
13.1.1	Význam analýzy dat	215
13.1.2	Integrace analytiky OCI v rámci ekosystému Oracle Cloud	216
13.2	Začínáme s OCI analytikou	216
13.2.1	Nastavení prostředí OCI Analytics	216
13.2.2	Základní pojmy a terminologie	217
13.2.3	Navigace v rozhraní OCI Analytics	218
13.3	Propojení zdrojů dat.....	219
13.3.1	Úvod do zdrojů dat pro analýzu OCI	219
13.3.2	Podrobný průvodce připojením nástroje OCI Analytics k datovým souborům	219
13.3.3	Tipy pro přípravu dat k analýze	221
13.4	Základní analýza a vizualizace dat	221
13.4.1	Jak provádět jednoduchou analýzu dat pomocí nástroje OCI Analytics	222
13.4.2	Porozumění různým typům vizualizací	223
13.4.3	Vytvoření první vizualizace	223
13.4.4	Automatizované přehledy OCI Analytics.....	224
13.4.5	Připojení nástroje OCI Analytics k datovému skladu.....	225
Kapitola 14 -	Vizualizace dat	227
14.1	Vizualizace dat.....	228
14.2	Oracle Analytics	229
Kapitola 15 -	Prípady použití	237
⇒	Případová studie města Kranj	238
15.1	Úvod k případové studii.....	238

15.1.1	Kranj jako inteligentní město	238
15.1.2	Index kvality ovzduší (AQI - Air Quality Index)	239
15.1.3	Analýza údajů o životním prostředí v MKO	239
15.2	Příprava souboru dat pro analýzu v systému OAC	240
15.2.1	Příprava dat v prostředí Oracle APEX	240
15.2.2	Příprava počátečního souboru údajů IOC v systému OAC	240
15.3	Vizualizace environmentálních dat MOV.....	245
⇒ World Ocean Database ↵	260
15.4	Úvod k případové studii.....	260
15.4.1	Světová databáze oceánů – World Ocean Database - WOD	260
15.4.2	Datové formáty pro vědecká data.....	261
15.5	Příprava databáze pro analýzu v systému OAC	261
15.5.1	Získávání dat ze služby Oracle Open Data.....	261
15.5.2	Extrakce a transformace dat v souborech .nc	262
15.5.3	Ukládání povrchových teplot do databáze OCI.....	263
15.5.4	Příprava počáteční sady dat WOD v systému OAC	265
15.6	Vizualizace oceánografických dat WOD	268
⇒ Využití volně dostupných údajů o životním prostředí pro komplexní analýzu ↵	280
15.7	Vyhledávání a používání volně dostupných údajů o životním prostředí	280
15.8	Snadná integrace dat	283
15.9	Základy vizualizace dat	285
15.10	Základní analytika	287
15.11	Shrnutí toho, co jsme se naučili s nástrojem Oracle Analytics	293
⇒ Správa zaměstnanců ↵	300
15.12	Používání nástroje OCI Analytics.....	300
⇒ ⇒ Vytváření a nasazení modelů Oracle Machine Learning ↵	313
15.13	Získávání a načítání dat pro předpověď teploty	313
15.14	Vytvoření modelu pro předpověď teploty	321
15.15	Nasazení modelu v prostředí Oracle APEX.....	325
Kapitola 16 - Využívání dat (data exploitation)	345
16.1	Sběr dat	345
16.2	Příprava dat	346
16.3	Analýza dat	346
16.4	Generování zprávy	347
16.5	Rozhodování	347
16.6	Neustálé zlepšování	347
16.7	Etické aspekty	347
16.8	Tvorba hodnoty	348
16.9	Budoucnost	348
16.9.1	Využití dat pro udržitelnost	348
16.9.2	Zelená průmyslová krajina	349
16.10	Budoucnost využívání dat v zeleném průmyslu	349
16.11	Závěry	350
Kapitola 17 - Strategie obchodních dat (business data strategy)	351
17.1	Soulad s obchodními cíli.....	351
17.2	Správa regulačních údajů.....	351
17.3	Sběr a integrace dat.....	351
17.4	Ukládání dat a infrastruktura	352
17.5	Analytické a datové přehledy	353
17.6	Životní cyklus dat	353
17.7	Zabezpečení dat a ochrana soukromí	353
17.8	Spolupráce a sdílení dat	354
17.9	Monetizace dat.....	355
17.10	Technologie a nástroje	355
17.11	Metriky a měření výkonu.....	356

17.12	Neustálé zlepšování	357
17.13	Výhody dobré datové strategie	357
17.13.1	Klíčové součásti účinné datové strategie	358
17.13.2	Přístupy k tvorbě datové strategie	358
17.13.3	Kdo vytváří strategii podnikových dat?	359
17.14	Závěry.....	359
Kapitola 18 -	Excelentní data (data excellence).....	361
18.1	Kvalita	361
18.2	Relevance.....	361
18.3	Dostupnost	361
18.4	Konzistence	361
18.5	Včasnost.....	361
18.6	Bezpečnost a ochrana soukromí.....	361
18.7	Správa regulačních údajů.....	361
18.8	Integrace dat	362
18.9	Analýza dat a zprávy	362
18.10	Neustálé zlepšování	362
18.11	Výhody excelence dat.....	362
18.12	Zásady excelence dat	363
18.13	Jak měřit a zlepšovat kvalitu dat?	363
18.14	Excelentní zelená data	364
18.15	Závěry.....	366
Kapitola 19 -	Shrnutí, závěr	367