

Obsah

Kapitola 1	1
Úvod	1
1.1 Cíl kurzu	1
1.2 Základní informace o systému <i>STATISTICA</i>	1
1.3 Produkty řady <i>STATISTICA</i>	2
1.3.1 Analytické moduly	2
1.3.2 Průmyslová řešení a nástroje Six Sigma	3
1.3.3 Podnikové systémy <i>STATISTICA</i>	4
Kapitola 2	7
Data mining	7
2.1 Co je data mining?	7
2.2 Podstata data miningu	7
2.3 Širší pohled na data mining	8
2.4 Data miningový cyklus	8
2.5 Metodika DM	8
2.5.1 Průzkum oblastí a porozumění datům	9
2.5.2 Získávání dat z databází a datových skladů	9
2.5.3 Příprava dat	9
2.5.4 Typy proměnných	9
2.5.5 Proměnné vysvětlující a vysvětlované	10
2.5.6 Typické úlohy	11
2.5.7 Učení a modelování	11
2.5.8 Hlavní techniky data miningu	12
2.5.9 Ověření, nasazení, monitorování a údržba modelu	12
Kapitola 3	15
<i>STATISTICA</i> a data mining	15
3.1 Nástroje řady <i>STATISTICA</i> doporučené pro DM	15
3.2 Dokumenty systému <i>STATISTICA</i>	15
3.2.1 Tabulky	15
3.2.2 Grafy	15
3.2.3 Makra	16
3.2.4 Pracovní sešity	16
3.2.5 Protokoly	16
3.2.6 Data miningové projekty	16
3.3 <i>STATISTICA</i> Data Miner: Přehled	16
3.4 Interaktivní analýzy	17
3.4.1 Příklad	18
3.5 Program <i>STATISTICA</i> Data Miner	19
3.5.1 Příklad	19
3.5.2 Rozsáhlejší projekty	23
3.5.3 Unikátní analytické uzly	24
3.5.4 Instantní projekty	25
Kapitola 4	27
Získávání dat z databází	27
4.1 Co je to databáze	27
4.2 Jazyk SQL	28
4.3 <i>STATISTICA</i> Query	29
4.4 Ukázky SQL dotazů	31
4.5 In-Place Database Processing	34
Kapitola 5	37

Příprava dat	37
5.1 Popis a průzkum dat	37
5.2 Čištění dat, odlehlé hodnoty (outliers)	39
5.3 Chybějící hodnoty	41
5.4 Odvozené proměnné	43
5.5 Normalizace dat	43
5.6 Selekce příznaků	44
5.7 Extrakce příznaků	44
Kapitola 6	47
Tvorba modelu	47
6.1 Nejbližší soused	47
6.1.1 Podobnost, vzdálenost	47
6.1.2 Nejbližší soused formálně	48
6.2 Lineární modely a nejmenší čtverce	49
6.2.1 Lineární model formálně	49
6.2.2 Učení lineárního modelu – metoda nejmenších čtverců	50
6.2.3 Lineární modely pro regresi	50
6.2.4 Lineární modely pro klasifikaci	51
6.3 Logistická regrese	53
6.3.1 Logistická regrese pro dichotomii	54
6.3.2 Učení modelu	54
6.4 Rozšíření báze	54
6.5 Klasifikační a regresní stromy	56
6.5.1 Proč stromy?	56
6.5.2 Není strom jako strom	58
6.5.3 Jak roste strom?	58
6.5.4 Stromy typu CHAID	58
6.5.5 Stromy typu CART	59
6.5.6 Stromy typu QUEST	59
6.5.7 Poznámky	59
6.6 Shluková analýza (clustering)	60
6.6.1 Hierarchické shlukování	60
6.6.2 Metoda k-průměru (k-means)	62
6.6.3 Volba optimálního počtu shluků	63
6.6.4 EM shlukování	63
Kapitola 7	65
Ohodnocení modelu	65
7.1 Ilustrační příklady	65
7.2 Složitost modelu a přeučení modelu	67
7.2.1 Chyba na trénovacích a testovacích datech	67
7.2.2 Chyba a složitost modelu	68
7.3 Volba modelu a jeho ohodnocení	69
7.3.1 Trénovací, ověřovací a testovací data	69
7.3.2 Křížové ověření (Cross-validation)	70
7.4 Grafické metody hodnocení modelu	71
7.4.1 Graf navýšení (Lift chart)	71
7.4.2 ROC křivka	72
Kapitola 8	75
Nasazení modelu	75
8.1 Export modelů	75
8.1.1 Export do SVB	75
8.1.2 Export do C++	75
8.1.3 Export do PMML	76
8.2 Monitorování a údržba	76
8.2.1 Když model nefunguje	76
8.2.2 Když model přestává fungovat	77