doc. Ing. Pavel Šenovský, Ph.D.

Bezpečnostní informatika 3

skripta
4. vydání

Ostrava, 2018

Bezpečnostní informatika 3
4. rozšířené vydání
tento text neprošel jazykovou úpravou

Vysoká škola báňská - Technická univerzita Ostrava, Fakulta bezpečnostního inženýrství

Obsah

Seznam obrázků **7**

Seznam tabulek **9**

Seznam výpisů kódů **12**

Úvod **13**

1 Základy průmyslové automatizace **17**
1.1 Automatizace . . . 17
1.2 PLC . . . 18
1.3 SCADA . . . 20
1.4 Další zařízení využívána v automatizaci . . . 22
1.5 Průmysl 4.0 . . . 26

2 Real-timové databáze **29**
2.1 Real-time databáze vs relační databáze . . . 29
2.2 Transakce . . . 32
2.2.1 Organizace dat v databázi . . . 32
2.2.2 Jazyk SQL . . . 33
2.2.3 Transakce . . . 37

3 SCADA - příklad v Promotic **41**
3.1 Promotic - instalace a projekt . . . 41
3.2 Promotic verze 8.3 . . . 43
3.2.1 UPS - specifikace podkladů pro tvorbu aplikace . . . 49
3.2.2 Příprava obrazovek aplikace . . . 50
3.2.3 Časovač - programování . . . 54
3.3 Promotic verze 9.0 . . . 56

4 Automatizace - otázky bezpečnosti **63**
4.1 Případové studie bezpečnosti automatizace . . . 64
4.2 Způsoby izolace automatizační sítě . . . 69

5 Ochrana ICS **77**
5.1 Typy CERT a CSIRT . . . 77
5.2 Legislativa kybernetické bezpečnosti . . . 81

6 Data mining **87**
6.1 Postup data miningu . . . 88
6.2 Metodiky dolování dat . . . 92
6.3 Zdroje data miningu . . . 95

7 Úvod do R **99**
7.1 Instalace prostředí . . . 99
7.2 RStudio . . . 100
7.3 Základy jazyka R . . . 103
7.4 Knihovna dplyr . . . 109
7.5 Grafy pomocí knihovny Plotly . . . 114

8 Pravidlové metody **119**
8.1 Příprava dat . . . 120
8.2 Rozhodovací stromy . . . 122
8.3 Případová studie rozhodovacího stromu - AMES dataset . . . 128
8.4 Rozhodovací pravidla . . . 133
8.5 Asociační pravidla . . . 136

9 Bayesovská klasifikace **143**
9.1 Úvod do Bayusovské klasifikace . . . 143
9.2 Případová studie . . . 147

10 Neuronové sítě **151**
10.1 Neuron . . . 152
10.2 Neuronové sítě a jejich adaptace . . . 154
10.3 Případová studie . . . 160

Literatura **172**

Seznam zkratek **175**

Rejstřík **176**

Seznam obrázků

Základy průmyslové automatizace **17**
1.1 Obecné schéma regulační soustavy . . . 18
1.2 Příklad PLC a řídícího systému (převzato z [10]) . . . 19
1.3 Zapojení SCADA systému, databáze, PLC a řízené technologie . . . 21
1.4 Dohledové pracoviště Národní dopravní a informační centrum (NDIC) (převzato z [46]) 22
1.5 Řešení monitoringu fotovoltaické elektrárny (převzato z [31]) . . . 23
1.6 Možná struktura webové aplikace zajišťující rozhraní člověk - stroj . . . 24

Real-timové databáze **29**
2.1 Databázový klastr . . . 31
2.2 ERD diagram metadat příspěvků v síti Twitter (adaptováno z [79]) . . . 32
2.3 Výsledky spojení dvou tabulek . . . 35
2.4 Změna hodnoty transakce v čase . . . 38

SCADA - příklad v Promotic **41**
3.1 Základní rozložení aplikace Promotic - Nový objekt . . . 43
3.2 Promotic - nastavení workspace s nástrojovou lištou . . . 44
3.3 Promotic - vývojové prostředí . . . 45
3.4 PmWorkspace - vlastnosti MainFrame . . . 46
3.5 PmWorkspace - vlastnosti toolbar . . . 46
3.6 PmWorkspace - vlastnosti Main . . . 46
3.7 Promotic - nový objekt . . . 47
3.8 Promotic - PmNumber - objekt typu číslo . . . 48
3.9 Promotic - PmString - objekt typu textový řetězec . . . 48
3.10 Promotic - PmData - sdružující proměnné různého typu . . . 48
3.11 Promotic - objekty projektu UPS . . . 50
3.12 Editor grafického obsahu - paleta prvků . . . 51
3.13 Kruhový měřící přístroj - připojení proměnné . . . 52
3.14 Kruhový měřící přístroj - nastavení vlastností . . . 52
3.15 Kruhový měřící přístroj - doplnění textových popisků . . . 53
3.16 Vizualizace baterie . . . 53
3.17 UPS - vizualizace, celek . . . 54
3.18 Promotic 9.0 - základní rozhraní . . . 57
3.19 Založení projektu v Promotic 9.0 . . . 57
3.20 Průvodce zavedení projektu v Promotic 9.0 - krok 2 . . . 58
3.21 Průvodce zavedení projektu v Promotic 9.0 - rozložení aplikace . . . 58
3.22 Editor Promotic 9.0 . . . 59
3.23 Příprava uživatelské grafiky v Promotic 9.0 . . . 60

Automatizace - otázky bezpečnosti **63**
4.1 Bezpečnost řešená na vnějším perimetru sítě firewallem . . . 70
4.2 Dual home computers . . . 71
4.3 Dual home server . . . 71
4.4 Oddělení sítí pomocí zařízení různých typů . . . 73
4.5 Důvěryhodná vs demilitarizovaná zóna . . . 74
4.6 Důvěryhodná vs demilitarizovaná zóna - řešení s použitím dvojice firewallů . . . 75

Data mining **87**
6.1 Technický pohled na postup data miningu (adaptováno z [23]) . . . 88
6.2 Manažerský pohled na postup data miningu (adaptováno z [23]) . . . 89
6.3 Úlohy data miningu - pokrytí konceptu (adaptováno z [23]) . . . 91
6.4 Proces data miningu v SAS Enterprise Miner (převzato z [69]) . . . 93
6.5 Životní cyklus data miningu (převzato z [41]) . . . 94
6.6 Příklad struktury zjednodušené objednávky . . . 95
6.7 Struktura informačních systémů podniku . . . 96
6.8 Datová krychle v OLAP (adaptováno z [23]) . . . 96

Úvod do R **99**
7.1 Rozhraní RStudio v OS X . . . 101
7.2 Podrobnosti o sloupcích tabulek, matic a dataframů v RStudio . . . 102
7.3 Data Viewer - proměnná tornado_data . . . 102
7.4 Párové srovnání vlastností kosatců v datové sadě iris . . . 108
7.5 Délka vs šířka listu kosatců v datasetu iris (bodový graf) . . . 109
7.6 Dostupné typy vykreslování ve funkci plot . . . 110
7.7 Rozložení délky listu dataset iris (histogram) . . . 111
7.8 Délka listu dataset iris (boxplot) . . . 112
7.9 Rozložení počtu prodejů podle jejich úspěšnosti (pie) . . . 113
7.10 Počet případů COVID-19 v jednotlivých dnech - 7-mi denní klouzavý průměr . . . 115
7.11 Exponenciální nárůst nakažených COVID-19 ve vybraných státech - demonstrace logaritmických měřítek os . . . 117
7.12 Vývoj denního počtu nově diagnostikovaných COVID-19 v ČR za poslední 2 týdny . . . 118

Pravidlové metody **119**
8.1 Filozofie použití trénovací a validační množiny . . . 120
8.2 Klienti banky - ručně vytvořený rozhodovací strom . . . 125
8.3 Klienti banky - strom vygenerovaný toolkitem *Tree* . . . 127
8.4 Regresní strom pro AMES dataset . . . 132
8.5 Vztah velikosti stromu a přesnosti výpočtu pro AMES dataset . . . 133
8.6 Komplexita stromu a jeho přesnost pro AMES dataset měřeno pomocí RMSE . . . 133
8.7 Vztah velikosti stromu a přesnosti výpočtu pro AMES dataset měřeno pomocí RMSE 134
8.8 Hodnocení významnosti parametrů funkcí vip pro AMES data - model rozhodovacího stromu . . . 135
8.9 Asociační pravidla - dataset Titanic (27 základních pravidel) . . . 140
8.10 Asociační pravidla - dataset Titanic (zaměřeno na přeživší podle věku a třídy) . . . 140

Bayesovská klasifikace **143**
9.1 Kosatec (iris) - grafický popis významu sloupců (převzato z [81]) . . . 147

Neuronové sítě **151**
10.1 Schéma neuronu (převzato z [24]) . . . 152
10.2 Neuron vizuálního kortexu (převzato z [43]) . . . 153
10.3 Schématické znázornění modelu perceptronu . . . 154
10.4 Graf sigmoidy . . . 154

10.5 Jednoduchá neuronová síť pro OCR 155
10.6 Schéma vícevrstevné sítě 155
10.7 Neuronová síť pro predikci hodnot funkce $y = x^2$ 157
10.8 Funkce $y = x^2$ - srovnání modelu neuronovou sítí a lineární regresí 158
10.9 Přeučený model 159
10.10 Klasifikace klientů banky neuronovou sítí 160
10.11 RMSE pro různé modely neuronové sítě datasetu AMES 161
10.12 Relativní významnost jednotlivých parametrů modelu neuronové sítě datasetu AMES 162
10.13 Ladění hyperparametrů .size (3, 5, 10, 20) a decay (0,1 - 0,9) pro AMES dataset . . . 163
10.14 Ladění hyperparametrů .size 3-9 pro standardizované prediktory AMES dataset 165
10.15 Srovnání významnosti prediktorů pro nnet síť s normalizovanými prediktory po 1000 iterací (AMES dataset) 166

Seznam tabulek

Pravidlové metody **119**
8.1 Přidělování úvěrů banky (převzato z [23]) . . . 123
8.2 Příjem vs úvěr . . . 123
8.3 Přidělování úvěrů - 2. větvení . . . 124
8.4 Přidělování úvěrů - 3. větvení . . . 124
8.5 Binární strom přidělování úvěrů klientům banky - confussion matice . . . 128
8.6 Párek vs hořčice . . . 136
8.7 Rozložení datasetu Titanic . . . 138

Bayesovská klasifikace **143**
9.1 Bayesovná klasifikace pro iris dataset - confussion matice . . . 148

Neuronové sítě **151**
10.1 Trénovací množina funkce $y = x^2$ . . . 156
10.2 Neuronová síť predikce vs realita ($y = x^2$) . . . 159

Seznam výpisů kódů

Real-timové databáze **29**
2.1 SQL: definice tabulek - příklad Twitter . . . 33
2.2 SQL: struktura příkazu CREATE TABLE . . . 34
2.3 SQL: struktura příkazu ALTER TABLE . . . 34
2.4 SQL: výběrový dotaz - příklad výběru konkrétního příspěvku . . . 34
2.5 SQL: výběrový dotaz - příklad výběru příspěvků určitého uživatele . . . 34
2.6 SQL: výběrový dotaz - propojování tabulek vnitřním spojením (INNER JOIN) . . . 35
2.7 SQL: příklad vkládání údajů do tabulek (INSERT INTO) . . . 36
2.8 SQL: struktura příkazu INSERT INTO . . . 36
2.9 SQL: příklad aktualizace zaznamu v databázi (UPDATE) . . . 36
2.10 SQL: příklad výmazu záznamů z databáze (DELETE) . . . 36

SCADA - příklad v Promotic **41**
3.1 Oživení časovače Promotic (příklad) ve Visual Basic . . . 54
3.2 VB: podmínky if .. then ... elseif .. else .. end if . . . 55
3.3 VB: napojení proměnných Promotic . . . 56
3.4 JavaScript: oživení časovače projektu UPS v Promotic 9.0 . . . 60

Úvod do R **99**
7.1 Příklad instalačního skriptu pro Bash instalujícího nástroje R a RStudio pro distribuce OS Linux na bázi Debian Linux . . . 100
7.2 Základní oprátory R a přiřazení výsledku do proměnné . . . 103
7.3 Základní funkce v R . . . 103
7.4 Manipulace s vektory v R . . . 104
7.5 Spojování vektorů v R . . . 104
7.6 Realizace Data framu spojením vektorů v R . . . 104
7.7 Manipulace se sloupci Data framu v R . . . 104
7.8 Aplikace filtrů na sloupce Data framu v R . . . 105
7.9 Řazení v Data framu . . . 105
7.10 Použití faktorů v R . . . 105
7.11 Vytvoření ordinální proměnné v R . . . 105
7.12 Načtení CSV souboru . . . 106
7.13 Zápis dat do textového souboru . . . 106
7.14 Základní statistické funkce v R . . . 107
7.15 Vykreslování základních typů grafů pro dataset IRIS . . . 107
7.16 Funkce *plot* - jednotlivé typy grafů . . . 108
7.17 Tvorba koláčových grafů v R . . . 109
7.18 Načtení dat o COVID z John Hopkins university do R . . . 110
7.19 Zpracování dat o potvrzených případech pomocí R . . . 111
7.20 Zpracování dat o potvrzených případech úmrtí v důsledku COVID-19 pomocí R . . . 113
7.21 Propojení souvisejících dat do jednoho celku pomocí R . . . 114
7.22 Sedmidenní klouzavý průměr nakažených v ČR Nizozemí a Švédsku . . . 115
7.23 Logaritmické osy grafu - demonstrace vizualizace exponenciálního růstu . . . 116
7.24 Sloupcový graf - vývoj denního počtu nově diagnostikovaných COVID-19 v ČR za poslední 2 týdny . . . 116

Pravidlové metody **119**
8.1 Metoda rozděl a panuj - strom klientů banky . . . 124
8.2 Metoda rozděl a panuj - strom klientů banky; převod do podoby rozhodovacího seznamu 124
8.3 Instalace knihovny tree . . . 126
8.4 Binární strom přidělování úvěrů klientům banky . . . 126
8.5 Binární strom přidělování úvěrů klientům banky - metriky a výsledky . . . 127
8.6 Binární strom přidělování úvěrů klientům banky - hodnocení kvality modelu . . . 128
8.7 Regresní strom pro AMES dataset . . . 130
8.8 Rozhodovací pravidla . . . 135
8.9 Načtení datasetu Titanic do R . . . 137
8.10 Ukládání a načítání dat v R . . . 137
8.11 Odvození asociačních pravidel pro dataset Titanic . . . 137
8.12 Asociační pravidla pro děti (dataset Titanic) . . . 139
8.13 Grafická interpretace asociačních pravidel (dataset Titanic) . . . 139

Bayesovská klasifikace **143**
9.1 Naivní Bayesůk klasifikátor pro řešení problému klasifikace klientů banky . . . 146
9.2 Naivní Bayesůk klasifikátor pro řešení problému klasifikace kosatců na základě vlastností jejich okvětních lístků . . . 147

Neuronové sítě **151**
10.1 Řešení funkce druhé mocniny pomocí neuronové sítě . . . 156
10.2 Klienti banky - řešení neuronovou sítí . . . 159
10.3 AMES dataset - řešení pomocí nnet . . . 161
10.4 AMES dataset - řešení pomocí nnet s optimalizací hyperparametrů a vyšším počtem iterací . . . 162
10.5 AMES dataset - řešení pomocí nnet s optimalizací hyperparametrů; vyšším počtem iterací a preprocesingem prediktorů . . . 163

Úvod

Vážený studente, dostává se Vám do rukou učební text předmětu *Bezpečnostní informatika 3* a předmětu *Informatika v bezpečnosti*[1].

Ačkoliv název předmětu má na svém konci číslovku 3, text skript je samonosný a jeho pochopení nevyžaduje předchozí znalosti předmětů Bezpečnostní informatika a Bezpečnostní informatika 2, ačkoliv určitá znalost zejména v oblasti šifrování může poskytnout užitečný kontext pro probíranou problematiku.

Z hlediska požadovaných znalostí je tak žádoucí pouze základní (uživatelské) znalosti v oblasti informační technologie (IT) a ochota naučit se něco nového.

Skripta se zaměřují především do dvou základních oblastí a to *průmyslové automatizace* – především pak systémů pro vizualizaci technologických procesů, tzv. Supervisory Control and Data Acquisition (SCADA) systémů a základů dolování dat. Účelem je umožnit studentům proniknout do nové oblasti řízení (automatizace) procesů, na kterých jsou založeny prakticky všechny výrobní procesy, kritická infrastruktura, ale např. také řízení klimatu v budovách.

Bezpečnost tedy má svou IT složku. Technologie samotná tedy může poskytnout řadu informací o svém stavu. Nehoda v technologii může nastat vlivem řady příčin, pokud však není způsobena vnějšími vlivy, jako je např. povodeň nebo teroristický útok, lze očekávat, že takové nehodě budou předcházet změny ve sledovaných veličinách. Tyto by mělo být možné identifikovat pomocí běžných statistických metod popřípadě metod strojového učení.

Právě metodám strojového učení je věnována druhá polovina skript.

Organizace textu

Pro zpříjemnění čtení jsem se také rozhodl zpracovat tento text formou vhodnou pro „distanční vzdělávání“, tak aby práce s ním byla co možná nejjednodušší. Z tohoto důvodu je text jednotlivých kapitol segmentován do bloků.

Každá kapitola začíná náhledem kapitoly, ve kterém se dozvíte, o čem budeme v kapitole mluvit a proč. V bodech se pokusím shrnout, co byste po prostudování kapitoly měli znát a kolik času by Vám studium mělo zabrat. Mějte prosím na paměti, že tento časový údaj je pouze orientační, nebuďte proto prosím smutní nebo naštvaní, když ve skutečnosti budete kapitole věnovat o něco méně nebo více času.

Za kapitolou následuje shrnutí, ve kterém budou zdůrazněny informace, které byste si rozhodně měli zapamatovat (určitě Vám ale neuškodí, pokud si jich zapamatujete více).

To, že jste správně pochopili probíranou látku, si budete moci ověřit pomocí kontrolních otázek a testů, které by Vám měly poskytnout dostatečnou zpětnou vazbu k rozhodnutí, zdali jít dále nebo si vyhradit delší čas na opakování.

Pokud studujete Bezpečnostní informatiku 1 v rámci celoživotního vzdělávání, tak v průběhu studia narazíte také na tzv. *korespondenční úkoly*. Tyto úkoly je potřeba vypracovat a v termínech daných Vaším studijním harmonogramem je odevzdat. Tyto korespondenční úkoly poslouží k Vašemu závěrečnému hodnocení.

Pokud jste studenty řádného studia v denní nebo kombinované studijní formě, pak i Vy narazíte na korespondenční úkoly, ale můžete je v klidu ignorovat – Vaše hodnocení bude provedeno na základě písemné zkoušky.

Pro zjednodušení orientace v textu jsem zavedl systém ikon:

V novém (už šestém!) vydání skript jsem se rozhodl pro trošičku jiný způsob přípravy skript a celá jsem je přepsal v Desktop Publishing (DTP) systému LaTeX. Důvodem jsou některé schopnosti, které je s běžnými textovými procesory je možné dosáhnout pouze stěží a také to, že řada z vás bude

[1] Předměty Bezpečnostní informatika 3 a Informatika v bezpečnosti jsou obsahově ekvivalentní.

Průvodce studiem
Slouží pro seznámení studentů s látkou, která bude v kapitole probírána.

Čas nutný ke studiu
Představuje odhad doby, který budete potřebovat k prostudování celé kapitoly. Jedná se pouze o orientační odhad, neznepokojujte se proto, pokud Vám studium bude trvat o něco déle nebo budete hotovi rychleji.

Vysvětlení, definice, poznámka
U této ikony najdete vysvětlující text, poznámku k probíranému tématu, která problém uvede do širších souvislostí, popřípadě důležitou definice.

Kontrolní otázky
Na závěr každé kapitoly je zařazeno několik otázek, které prověří, zda jste problematice kapitoly dostatečně porozuměli. Pokud nebudete vědět odpověď na některou otázku, je to signál pro Vás, abyste se ke kapitole vrátili.

Příklad
Příklady obsahují praktické demonstrace diskutovaného problému.

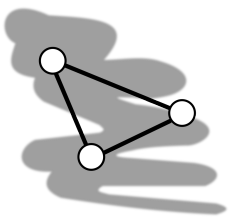

Návaznosti
V tomto segmentu budou zmíněny další návaznosti probíraného tématu na další témata tohoto předmětu, ale také dalších předmětů.

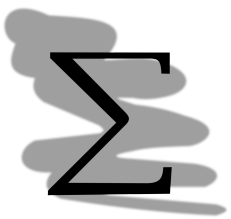

Shrnutí
Obsahuje základní myšlenky kapitoly, kterým by měl být věnována zvláštní pozornost během studia.

studovat tento text přímo v počítači (tabletu, čtečce elektronických knih nebo mobilním telefonu) a v takovém případě budete chtít využít nejspíše všech schopností, která Vám tato zařízení poskytují.

Kolikrát jste si pomysleli - „jaké by to třeba bylo, kdybych mohl klepnout na jednu z těch divných

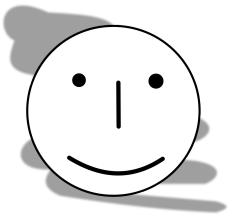

Přestávka
Po obtížné části textu, nebo prostě občas jenom tak je nutné si udělat krátkou přestávku, načerpat síly k novému studiu.

zkratek (které informatici tak milují) a ona by mě přesměrovala automaticky na seznam zkratek“? Nebylo by lepší kdyby na daný literární pramen bylo možné se dostat přímo klepnutím na jeho číslo v textu, nebo aby jste nemuseli vybranou pasáž hledat přes čísla stránek, ale postačovalo by kliknout na jméno kapitoly v obsahu?

Mě jako studentovy by se to líbilo a proto doufám, že je oceníte i Vy, protože všechny výše uvedené možnosti skripta ve formátu Portable Document Format (PDF) obsahují. Aktivní odkazy jsou v textu zvýrazněny červenou (a v případě odkazů na literaturu zelenou) barvou.

Na konec skript byl přidán také rejstřík pojmů. Doporučuji, abyste jej v rámci přípravy na zkoušku prošli - zamyslete se nad tím, zda všechny pojmy, které jsem do něj zařadil, chápete a jste je schopni dát do souvislostí. Pokud ne je vedle pojmu odkaz na číslo stránky, kde je pojem probrán a Vy můžete rychle zaplnit případné mezery ve svých znalostech problematiky informačních systémů.

Přeji Vám, aby čas, který strávíte s tímto textem, byl co možná nejpříjemnější a abyste jej nepovažovali za ztracený.

doc. Ing. Pavel Šenovský, Ph.D.

Poznámka autora:
Právě držíte v rukou (ať iž fyzicky nebo virtuálně) čtvrté rozšířené vydání skript. Je možné, že právě studujete na zkoušku, nebo jste se ke skriptům dostali pouze náhodou po delší době. Z tohoto důvodu by se Vám mohlo hodit stručné shrnutí změn mezi jednotlivými vydáními těchto skript.

Novinky ve 4. vydání skript
- aktualizována sekce věnovaná neuronovým sítím - vylepšena prezentace skriptů v R
- drobné úpravy v textu a opravy chyb
- v části věnované Promotic doplněny poznámky k verzi 9 systému
- upraveny a doplněny příklady v části věnované dataminingu
- doplněny popisky výpisů zdrojových kódů
- doplněn seznam výpisu zdrojových kódů

Novinky v 3. vydání skript
1. použit jiný systém sazby, což umožnilo přiložit je skriptům rejstřík, různé seznamy a to v interaktivní podobě
2. stávající témata prošla revizí
3. skripta byla zcela zásadním způsobem přepsána

Kapitola 1

Základy průmyslové automatizace

Náhled kapitoly
V této kapitole se podíváme na specifika průmyslové automatizace. Zaměříme se přitom zejména na popis různých druhů zařízení a způsobu, jakým se využívají

Po přečtení této kapitoly budete
vědět

1. jaká zařízení se používají pro automatizaci procesů a
2. jakým způsobem se používají (co je jejich účel)

Čas pro studium
Pro prostudování této kapitoly budete potřebovat přibližně hodinu.

1.1 Automatizace

Automatizace je základním nástrojem pro řízení technologických celků. Automatizací rozumíme zavádění automatizovaných systémů pro měření a regulaci procesů. Úkolem regulace je zajistit plynulý (ve smyslu rychlosti procesu i kvality) provoz regulované soustavy.

Nejprve se automatizace zaváděla do velkých výrobních linek, dnes se však automatizují prakticky všechny procesy od procesů výrobních, po systémy klimatizační ve velkých budovách až k regulaci kotle ve Vašem rodinném domě.

Obecně se tedy automatizace stará o automatizovaný chod regulované soustavy tak, že pro řízení jejího provozu automaticky aplikuje předem stanovené postupy a sleduje, zda změna v nastavení vedla k žádoucím změnám v chování regulované soustavy. V případě, že automatizovaná regulace nevede k zastabilizování soustavy, automatizace selhává a na řadu přichází buďto zásah operátora nebo odstavení soustavy. Ta pak musí být následně manuálně znovu spuštěna.

Uvažujme tři základní prvky automatice:

1. regulovaná soustava (to co je regulováno)
2. senzory (čidla schopná sledovat jednotlivé zájmové proměnné v regulované soustavě nebo vlivy na ni působící)
3. regulátor (zařízení, které bude realizovat samotný akt regulace, např. páky, ventily, apod.)

Vizuálně je možné si výše uvedené prvky představit jako na obr. 1.1. Trojici těchto prvků označujeme jako *regulační soustava*. **Regulační soustavou** přitom rozumíme jakoukoliv soustavu, která může být regulována. V regulační soustavě se obvykle používá velké množství různých senzorů, snímající různé veličiny, v různé kvalitě a různých místech regulované soustavy, a často také regulátorů.

Regulovaná soustava (v regulační soustavě) je obvykle pouze jedna, ale v praxi takové soustavy často řadíme za sebe, takže na sebe logicky navazují.

V takovém případě výstup jedné soustavy slouží zároveň také jako vstup soustavy druhé. To je možno si představit např. jako výrobní linku. Regulační soustavu pak bude tvořit každé zastavení dílů na této lince.

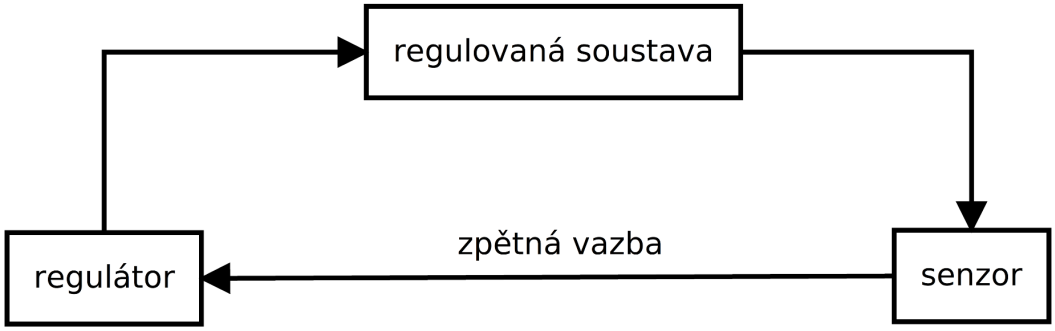

Obrázek 1.1: Obecné schéma regulační soustavy

Příklad
Tento koncept si lze jednoduše představit na příkladu řízení teploty v místnosti pomocí klimatizace. Předpokládejme že tato klimatizace je vybavena kromě schopnosti chlazení také tepelným čerpadlem a tedy schopností přitopit. Pro ni mohou být nastaveny dvě meze - horní a dolní - v případě, že bude přesáhnuta horní mez, spustí se klimatizace. Senzor teploty umožní řídícímu systému rozhodnout, zdali intenzita chlazení je dostačující a v případě potřeby ji upraví.

Obdobným způsobem bude pracovat také teplotní čerpadlo. V případě, že v místnosti poklesne teplota pod stanovenou dolní mez, zapne se přitápění pomocí tepelného čerpadla. Řídící systém opět na základě informací podle údajů získaných ze senzoru teploty v místnosti rozhodne, zda je intenzita vytápění dostatečná, popřípadě zda již není žádoucí vytápění zastavit.

Regulace je tedy z tohoto pohledu závislá na informacích poskytovaných senzorem, v tomto příkladu se jednalo o senzor teplotní. Senzory na řízeném systému jsou vyhodnocovány automaticky v určitém časovém intervalu. To umožňuje řídícímu systému regulovat a zároveň mu poskytuje zpětnou vazbu o tom jaký efekt mají regulační zásahy řídícího systému regulované soustavy.

Existuje nepřeberné množství typů **senzorů** - kromě teplotních čidel, lze měřit tlak, otáčky, vlhkost, výšku hladiny a celou řadu dalších veličin nebo stavů systému. Moderní systémy jsou dokonce v současnosti často schopny vyhodnocovat automaticky obraz zachycený kamerou a získat z něj informace potřebné pro regulaci - často s použitím metod strojového učení.

1.2 PLC

Zařízením, které často zajišťuje automatickou regulaci je **Programmable Logic Controller (PLC)**. Určitou představu o vzhledu PLC si lze udělat z obr. 1.2.

Na obr. 1.2 jsou PLC zařízení uprostřed (pod zásuvkou). Jednotlivé PLC se zasunují do patřičného řídícího systému. Na obr. 1.2 je vidět jedna zatím neobsazená police, kam by případně bylo možné zasunout další jednotku PLC. Počet PLC a velikost řídícího systému se odvíjí od požadavků, které jsou na něj kladeny. Složité technologické celky proto mohou pro svůj provoz vyžadovat klidně i desítky nebo stovky PLC zařízení a sofistikovaný řídící systém.

Formálně je PLC počítač. obsahuje tedy procesor, základní desku, paměť a rozhraní umožňující připojování periférií. Existuje zde ale poměrně velké množství rozdílů. K PLC např. není možné připojit běžné periferie jako je monitor, klávesnice a myš. Komunikace s tím se pak děje buďto po síti

Obrázek 1.2: Příklad PLC a řídícího systému (převzato z [10])

nebo zprostředkovaně přes další zařízení jako je SCADA systém nebo RTU (oběma se budeme zabývat za chvíli). Naopak poskytuje připojení pomocí rozhraní, která se u běžných počítačů nepoužívají.

PLC je také přizpůsobeno nasazení v technologických provozech. To znamená, že se předpokládá, že ideálně by se mělo jednat o zařízení bezúdržbové, jehož životnost bude stejná, jako je životnost řízeného systému. PLC tak může pracovat 10, 15 nebo i více let. Životnost PC je v současnosti přibližně odhadována na 6 let (podle konfigurace a způsobu užití).

Delší životnosti je dosahováno tím, že PLC jsou strukturálně jednodušší a obsahují minimum pohyblivých částí, které jsou náchylnější k selhání. Jsou také obvykle umisťována do prostorů, kde existuje určitá kontrola nad provozním prostředím z pohledu vibrací, teploty, vlhkosti, prašnosti apod. Může se jednat např. o speciálně přizpůsobené skříně nebo celé místnosti (serverovny).

PLC také nejsou univerzální, alespoň ne stejným způsobem jako běžné počítače. PLC je sice možné programovat, ale toto programování se děje na běžném počítači ve vývojovém prostředí poskytnuté výrobcem PLC. Připravený program je následně nahráván na PLC pomocí přenosných médií nebo

po síti, podle toho, jak je PLC staré a jakým způsobem je zapojeno, popř. konfigurováno. PLC pak následně bude *vykonávat tento*, ale pozor také *pouze tento* program.

To také ale znamená, že PLC různých výrobců (ani jejich řídící systém) není možné zaměňovat - jedná se o ucelená řešení na míru požadovaného nasazení (řízené technologie). Doba podpory těchto zařízení, ze strany výrobce, ale nepokrývá obvykle celou předpokládanou dobu nasazení PLC. Často přitom nasazení PLC nové generace daného výrobce není možné z důvodu zpětné nekompatibility. U velkých technologických celků organizace řeší tento problém tak, že se prostě předzásobí dostatečným počtem náhradních PLC na začátku životního cyklu celého technologického celku. Následně pak v případě selhání jednotlivých PLC může relativně snadno provést výměnu kus za kus.

Vraťme se ale ke způsobu řízení. PLC je tedy určeno k tomu, aby řízení pokud možno automatizovalo - tedy automaticky prováděla zásahy do technologie s cílem udržet ji v chodu uvnitř nastavených parametrů. Automatizace pokrývá běžné životní situace řízené technologie a je schopna se s nimi automaticky vypořádat. Jelikož ale není možno předem předvídat všechny možné stavy a problémy, kterým technologie z různých důvodů bude v budoucnu vystavena, schopnosti automatizovaného řízení budou vždy omezeny, byť moderní metody strojového učení a širší nasazení technologií tzv. *Průmyslu 4.0* schopnosti autonomní činnosti zařízení výrazně rozšiřuje.

1.3 SCADA

Z předchozích odstavců již víme, že schopnost automatického řízení má řadu omezení a proto pro složitější technologické celky je potřeba tento typ řízení vhodně kombinovat s řízením manuálním. Jelikož tento typ řízení není u řady instalací používán příliš často - bývá realizován obvykle dálkově a centralizovaně formou **dispečerská/dohledové/kontrolní pracoviště**.

Tento typ pracovišť slouží k vizualizaci dat předávaných kontinuálně technologií a její prezentaci tak, aby operátor byl schopen detekovat nežádoucí stavy a efektivně zasáhnout. Pro provoz takového pracoviště je bezpodmínečně nutné, aby dispečer měl přístup k aktuálním datům popisujících *současný stav technologie* a to v takové formě, aby byl schopen:

- identifikovat příčinu problému,
- navrhnout a spustit účinné řešení identifikovaného problému,
- zkontrolovat účinek řídících operací.

To není zcela triviální problém - i jednoduché technologie jsou schopny generovat velké objemy dat z připojených senzorů. To je dáno tím, že údaje ze senzorů jsou snímány v relativně krátkých časových intervalech (od zlomků sekund až po minuty podle toho, co je řízeno) a připojených senzorů je obvykle velké množství. Zobrazení těchto dat v tabelární formě proto nepřichází v úvahu. Data potřebujeme prezentovat „inteligentně“ tak, aby operátor nebyl přetížen přemírou informací a byl schopen efektivně pracovat.

Z tohoto důvodu se často nasazují tzv. **SCADA** systém. Tyto systémy tvoří další vrstvu v logice průmyslové automatizace. Připomeňme si, že tu nejnižší tvoří PLC automaty regulující proces v reálném čase. SCADA systém, jelikož údaje musí, načíst (obvykle po sítí), zpracovat a zobrazit funguje ve skoro reálném čase - tedy čase, který se blíží reálnému času, ale už je zde jisté drobné zpoždění.

SCADA systém přitom informace obvykle nebere přímo ze senzorů (prostřednictvím PLC), ale z nějakého centralizovaného k tomuto účelu určeného místa, často výkonného databázového serveru. Technicky je možno zajistit přímou komunikaci SCADA - PLC, ale takové řešení většinou není dobře škálovatelné a tak se mu dodavatelé technologií snaží vyhnout.

Na databáze, do kterých jsou údaje ze senzorů vkládány jsou kladeny určité specifické nároky. Informace musí poskytovat s minimálním časovým zpožděním. Primárním cílem je pak, aby poskytované údaje byly aktuální, ale nikoliv nutně úplné. To je poměrně zásadní rozdíl oproti nárokům, které jsou kladeny na databáze používané v běžných informačních systémech, kde naopak je primárním úkolem udržet úplnost uchovávaných dat.

Pro tyto specifické nároky jsou někdy tyto databáze označovány jako *real-timové*.

Problematice realtimových databází se budeme věnovat v samostatné kapitole.

Celkové zjednodušené zapojení SCADA systému, databáze, PLC a řízené technologie je znázorněno na obr. 1.3.

Na obr. 1.3 operátoři/dispečeři pracují s informacemi poskytovanými dohledovému pracovišti SCADA systémem. Aktuální data jsou shromažďována z automatizované technologie v realtimové

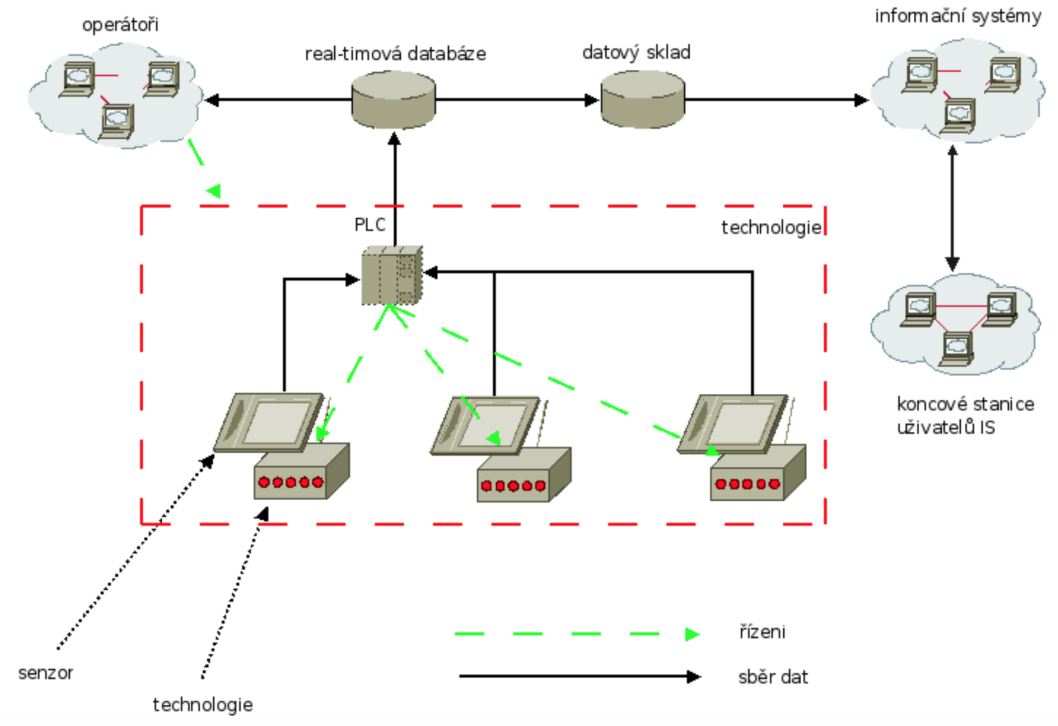

Obrázek 1.3: Zapojení SCADA systému, databáze, PLC a řízené technologie

databázi. Operátoři v případě potřeby mohou do řízené technologie přímo zasáhnout pomocí předem připravených mechanismů dálkového řízení.

V případě, že dálkový zásah není z nějakého důvodu možný, zbývá možnost manuální zásahu, na místě. Manuální zásah je často skutečně až to poslední možné řešení. Je potřeba si uvědomit, že řídící pracoviště může být geograficky vzdálené, např. dohledové pracoviště ŘSD bdící nad celou dálniční sítí včetně všech silničních tunelů je provozována z jediného místa - Ostravy. Pokud je nutný manuální zásah, jsou vysílány na místo problému technici přímo provozovatele dané technologie nebo technici jiných společností, kteří k tomuto účelu byli nasmlouváni. Při zásahu je potřeba počítat s tím, že doba zpohotovení zásahového týmu a jeho dopravení na místo může být poměrně dlouhá podle charakteru problému, vyžadovaném materiálu, zařízení a kompetencí techniků.

Všimněte si také druhé linie aktivit využívajících informací z technologie. V tomto případě jsou data o technologii přelévána do datového skladu pro využití v běžných informačních systémech organizace. Technologie může poskytovat řadu cenných informací, např. o spotřebě zdrojů, jejichž dodávky je potřeba plánovat, např. pomocí systémů Enterprise Resource Planning (ERP). Řada výrobních linek může mít také určité schopnosti identifikovat některé vady výrobků. Informace tohoto typu jsou opět velmi cenné a organizace je může (a měla by) chtít s nimi dále pracovat, např. v systému řízení kvality.

Podle charakteru řízené technologie dispečerské pracoviště může vypadat různě. Ředitelství silnic a dálnic třeba provozuje v Ostravě pro celou dálniční síť NDIC. Určitou představu o vzhledu si lze udělat z obr. 1.4.

NDIC zpracovává údaje z řady různých zdrojů zejména pak [80]:

- Detekce intenzit dopravy - cca 200 detektorů
- Silniční meteorologický systém - cca 270 meteohlásek
- Vysokorychlostní váhy - 11 kusů
- Systém elektronického mýta
- Systém sčítání dopravy, detekce kolon a sledování dopravního proudu
- Dohledový kamerový systém - více než 600 kamer

Pro srovnání menší instalace SCADA systému by mohla vypadat podobně jako na obr. 1.5. V tomto případě je monitorována menší fotovoltaická elektrárna.

Vizualizace řízeného technologického procesu je vždy realizována na míru řízené technologii. SCADA systém jako takový je obvykle provozován na běžných počítačích s operačním systémem Microsoft

Obrázek 1.4: Dohledové pracoviště NDIC (převzato z [46])

Windows. Z hlediska údržby se do SCADA systému obvykle nezasahuje, pokud to nevyžadují změny v provozované technologii samotné. Pro řízenou technologii je tedy vyvinuta aplikace ve vývojovém prostředí zvoleného SCADA systému. A následně je tato aplikace dlouhodobě provozována pro monitoring a řízení této technologie.

Ani SCADA systém (jako platforma) není imunní vůči morálnímu zastarávání. Provoz vyvinuté aplikace na novější (podporované) verzi zvoleného SCADA systému může technicky realizovatelné, ale velmi často je taková aktualizace považována za rizikovou. Přechod mezi různými verzemi stejného systému s sebou může totiž nést nekompatibilní změny, které navíc se mohou projevit pouze za určitých specifických podmínek. Odladění takového systému je tak poměrně náročné a vyžaduje čas a peníze.

Z tohoto důvodu jsou aplikace SCADA provozovány obvykle na platformě, pro kterou byly vyvinuty a to i v případě, že již není nadále podporována výrobcem. K aktualizace tak buď nedochází vůbec nebo jsou aplikovány pouze bezpečnostní záplaty v provozované verzi systému (nedohází tedy k povýšení na novou generaci software).

Všimněte si také, že tím, že SCADA systém je provozován na běžném operačním systému, může být náchylný k stejným problémům, jako jsou běžné počítače v počítačové síti. Tyto problémy mohou být umocněny také případným stářím SCADA, popřípadě verzí operačního systému, na kterém je provozován (provozovaná verze SCADA systému např. nemusí podporovat nejnovější verzi operačního systému).

1.4 Další zařízení využívána v automatizaci

Existuje celá řada dalších zařízení, které jsou využívány pro automatizaci technologických procesů. Některými z nich se budeme zabývat v této kapitole.

Pro vzdálenou komunikaci jsou využívány často zařízení **Remote Terminal Unit (RTU)**. Terminálem v tomto případě máme na mysli ovládání pomocí příkazové řádky. V původních UNIXových operačních systémech pohánějících sálové počítače, byla příkazová řádka označována jako terminál. Reflektovala se tím situace, že veškerá práce byla realizována ze vzdáleného fyzického terminálu. Příkazy pak šly po síti do sálového počítače, který je vykonával.

Obrázek 1.5: Řešení monitoringu fotovoltaické elektrárny (převzato z [31])

SCADA aplikace vs platforma
V textu výše se pojem SCADA objevuje ve dvou významech - jednak se jedná o platformu, na které je provozována vizualizace řízeného technologického procesu, jednak se tento pojem používá ve smyslu provozu samotné aplikace - vyvinutá a provozovaná aplikace je označována jako SCADA systém.

Uveďme si příklad: v samostatné kapitole těchto skript a také ve cvičení budeme pracovat se systémem Promotic [55] společnosti Microsys. V tomto systému lze vyvíjet a provozovat vizualizace různých technologických procesů - jedná se tedy o SCADA ve smyslu platformy. V systému Promotic vyvinuté aplikace jsou pak SCADA ve smyslu aplikace.

Efektivita investic vs bezpečnost
Ve výše uvedeném textu se pracuje poměrně extenzivně s životností, podporou apod. Co jsme nezmínili jsou otázky bezpečnosti. **Je možné považovat jednotlivé součásti řídícího systému za bezpečné i v případě, že už nadále nejsou podporované výrobcem?**. Odpověď je poměrně složitá - *ne tak docela.* Co organizace mohou dělat, je pokusit se řídící systém izolovat „zlého vnějšího světa“ a snížit tak riziko spojené s jeho provozem. K tomu je však potřeba dodat, že úplná izolace není také obvykle žádoucí opět z pohledu efektivity investic, zejména pak možnosti dálkové kontroly.

Možnostmi izolace řídícího systému se budeme zabývat později.

Dnes jsou terminály čistě softwarové (někdy se označují také jako emulátory terminálů). Základní idea textové komunikace po síti, ale zůstala stejná. Tato forma komunikace má některé výhody:

- text je dobře komprimovatelný - komunikace tedy vyžaduje pouze minimalní přenosovou kapacitu. Pro komunikaci tak může postačovat mobilní připojení dosluhujících sítí druhé generace např. General Packet Radio Service (GPRS) nebo Enhanced Data Rates for GSM Evolution (EDGE).
- text lze efektivně zpracovávat - RTU jsou proto sice málo výkonná, ale zato levná.
- spojení lze efektivně šifrovat (pokud to podporuje jednotka RTU)

Co do použití představují RTU spojení mezi vzdálenou řízenou technologií a řídícím pracovištěm. Další podstatné vlastnosti vycházejí z jiných výkladů zkratky RTU - někdy jsou totiž tato zařízení

označována jako Remote Telemetry Unit nebo Remote Telecontrol Unit.

Tyto názvy vedou na vlastnosti - poskytování telemetrických dat o kontrolované technologii a možnosti tuto technologii ovládat.

Textový charakter komunikace nutně nemusí být realizován v celém komunikačním procesu. Na straně operátora může třeba fungovat SCADA systém, který příkazy zadávané operátorem v grafickém uživatelském rozhraní převede do textové formy a odešle do vzdáleného RTU. Data předaná zpět v textové podobě pak opět mohou být převedena do grafické podoby.

U rozhraní se na chvíli zastavíme. Problematika **rozhraní člověk - stroj** (Human Machine Interface (HMI)) je totiž také jedním ze zájmů automatizace. Rozhraní může být realizováno mnoha různými způsoby:

- forma
  - grafické uživatelské rozhraní (Graphical User Interface (GUI))
  - textové rozhraní (viz RTU)
- centralizace
  - rozhraní je v řídící místnosti
  - rozhraní je přímo na řízené technologii
- přístupnost
  - přístupné po síti (např. RTU nebo webové rozhraní)
  - místní
- realizace
  - fyzická (tlačítka, páky, přepínače, další fyzicky realizované regulační prvky ...)
  - virtuální (rozhraní je realizováno softwarově)
- a další ...

Většinu z výše uvedených typů rozhraní není potřeba blíže představovat, neboť tvoří každodenní součást našich životů, přesto si dovolím věnovat určité místo webovému rozhraní, které v posledních letech nabylo na popularitě díky své relativní malé náročnosti a možnosti využít takové rozhraní prakticky odkudkoliv po síti. Pokud se ale podrobněji zaměříme na implementaci takového rozhraní, zjistíme, že strukturálně není úplně jednoduché, viz obr. 1.6.

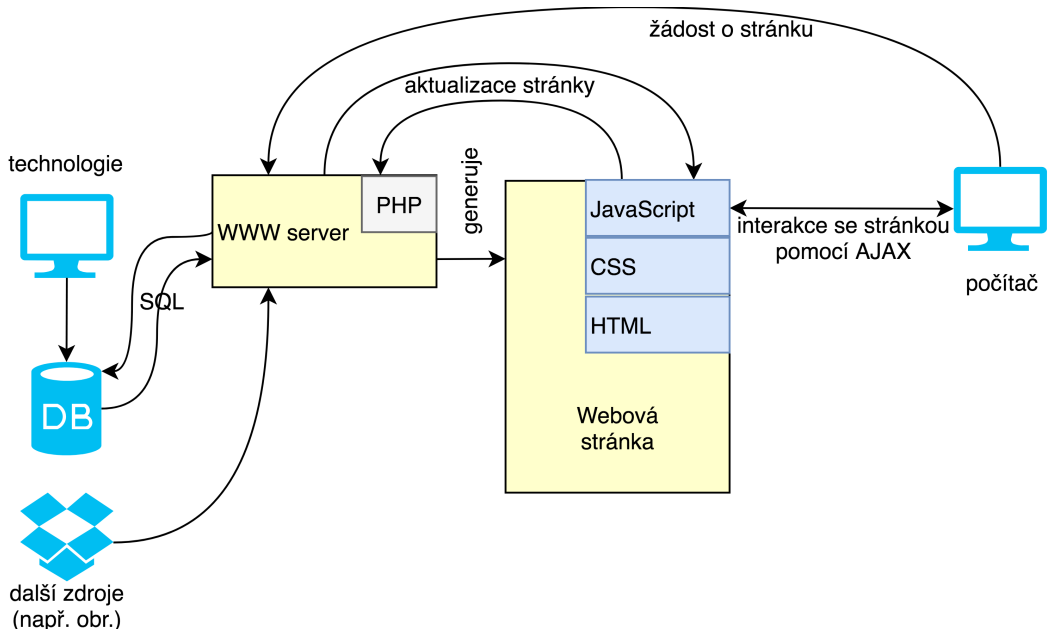

Obrázek 1.6: Možná struktura webové aplikace zajišťující rozhraní člověk - stroj

Jádrem webového rozhraní je webový server obvykle doplněný a zvolenou platformu, na které je rozhraní implementováno. V našem případě se jedná o programovací jazyk PHP. Pokud chceme k rozhraní přistoupit - zadáme adresu zařízení v síti do webového prohlížeče. Webový prohlížeč vyšle požadavek HTTP nebo HTTPS (podle toho, zda je komunikace šifrovaná) GET a webový server odpoví jedním z kódů a pokud je vše v pořádku (kód 200) vrátí i požadovaný zdroj (stránku).

Webová stránka je obvykle generována v reálném čase webovým serverem na základě implementovaného programu, v našem případě v jazyce PHP. Kód aplikace může být poměrně složitý a přistupovat k dalším zdrojům. Může se jednat o fragmenty souborů, ale třeba také data obsažená v nějaké databázi. Schopnost manipulovat s určitým typem databází může být přímo integrální součástí zvoleného programovacího jazyka, nebo se k manipulaci s ní používá obecnější rozhraní jako ODBC nebo JDBC.

Bez ohledu na to, jaké rozhraní k databázi je použito, samotné dotazování bude realizováno (až na určité výjimky) pomocí jazyka Structured Query Language (SQL).

Vygenerovaná stránka pak obvykle obsahuje:

- Hypertext Markup Language (HTML) pro sémantický popis struktury a obsahu stránky
- Cascading Style Sheets (CSS) - přiřazující HTML stránce určitý vzhled
- stránka může být doplněna JavaScriptem umožňujícím implementaci určitých interakcí jinak typickým pro aplikace běžné na desktopu

JavaScript např. může pomocí Asynchronous JavaScript and XML (AJAX) aktualizovat pouze určité specifické části stránky, aniž by bylo nutné načíst znova stránku celou. Tímto způsobem lze poměrně efektivně obejít technické omezení vynucené realizací komunikace na protokolech TCP/IP, které jsou bezstavové. Veškeré interakce se stránkou jsou tak řešeny samostatným požadavkem na server. Při použití AJAX jsou ale tyto požadavky omezené pouze na manipulaci s daty apod. - struktura stránky a větší část jejího obsahu tak obvykle zůstává nezměněna.

AJAX tak nejen, že zvyšuje komfort při použití, ale fungování webové aplikace také výrazně zrychluje.

I pro jednoduché webové rozhraní je nutno najednou provozovat spoustu nástrojů a každý z nich jednotlivě je potřeba specifickým způsobem z podle bezpečnosti udržovat.

Po přečtení předchozích odstavců Vás možná napadne otázka **PROČ?** Proč bych měl vědět něco o struktuře a fungování webových aplikací? Jakou to má souvislost s oborem, který studují? A možná Vás napadnou v podobném duchu i další otázky.

Důvodem, proč zkoumáme strukturu webových aplikací nebo proč se vůbec v tomto předmětu zabýváme problematikou automatizace jsou prosté: V praxi ať už se budete zabývat řešením bezpečnostních plánů, nebo běžnými provozními záležitostmi ve smyslu požární ochrany nebo bezpečnosti práce, nebo dokonce pokud budete řešit bezpečnost systémů kritické infrastruktury - budete muset pro svou práci přijmout jisté předpoklady o způsobu chování řízeného systému.

Bezpečnostní specialista postupuje obvykle tak, že pracuje s různými scénáři možných havárií. Pro každý scénář pak odvozuje riziko a zkoumá způsoby jak s ním naložit. Variant řešení je obvykle k dispozici velké množství. Podobně velké množství je ale také různých scénářů selhání technologie.

Z hlediska možných opatření lze jít po příčinách, tedy zabránit iniciaci nebezpečí nebo lze přerušit popř. minimalizovat následky takové posloupnosti. K tomuto účelu je ale obvykle potřeba do technologie určitým způsobem zasáhnout - tedy regulovat ji.

Jak ale takovou regulaci realizovat? Už víme, že technologické procesy mají řadu vrstev. Některé fungují automaticky (PLC), na základě nahraného programu, jiné předpokládají dohled popř. zásah člověka (SCADA). Pokud budu muset zasáhnout, budu toho schopen? Co dělat v případě, že z nějakého důvodu nelze technologii řídit dálkově? Mám na místě člověka, který může provést požadovaný manuální zásah, nebo budu muset na místo vyslat pracovníka/specialistu? Jak dlouho bude trvat, než se tam dostane a když se dostane na místo, jak dlouho bude trvat, než začne pracovat na lokalizaci problému?

V případě, že bychom nevěděli nic o podstatě automatizace musíme se spolehnout čistě na názor specialisty na automatizaci. Tento specialista může být vynikajícím odborníkem na automatizaci, ale velmi pravděpodobně jeho znalosti z pohledu práce s rizikem nebudou příliš valné. Určitá úroveň porozumění problematice automatizace nám neumožní takového specialistu nahradit, z pohledu řízení bezpečnosti, ale můžeme přestat na něm být zcela závislí - můžeme se stát jeho partnery - pro oblast řízení bezpečnosti.

Získané znalosti z tohoto předmětu by Vám tedy měly umožnit, aby jste mohli klást otázky a abyste, alespoň trochu rozuměli odpovědím. (aby odpověď pro Vás nebyla v řeči vyhynulých kmenů.)

1.5 Průmysl 4.0

V poslední části této kapitoly se zaměříme na pojem *Průmysl 4.0*. Tento pojem je v posledních letech využíván velmi často, obvykle v souvislosti se zdůrazněním změn, které probíhají v současnosti v transformaci procesů ve výrobních, ale také nevýrobních společnostech. Tyto změny jsou někdy označovány také jako *4. průmyslová revoluce*.

Zkusme projít jednotlivé „revoluce“ v minulosti a zkusme odhadnout celkový transformační potenciál revoluce této.

1. průmyslová revoluce proběhla v 18. století a transformovala tehdejší společnost zaměřenou na zemědělství a venkov do podoby inudstrializované společnosti centralizované do měst. Tento přerod byl umožněn nástupem velkých výrobních celků schopných sériové produkce zboží. Jako pohon těchto zařízení sloužily nově vyvinuté parní stroje.

2. průmyslová revoluce, někdy označovaná také jako technologická revoluce, se vyznačuje rychlou standardizací a industrializací. Tuto revoluci obvykle datujeme někdy mezi léta 1870 - 1914 (začátek 1. světové války). Pokroky dosažené ve výrobních procesech umožnily široké nasazení systémů jako je telegraf, železnice, inženýrské sítě (plynovody,vodovody, kanalizace). Taktéž byla představena řada nových technologií z nichž nejvýznamnější je elektrifikace a telefony.

3. průmyslová revoluce se datuje do druhé poloviny 20. století, konkrétně po roce 1969 a je obvykle spojována s elektronizací společnosti. Tato revoluce tak zahájila transformaci společnosti s čistě analogové do digitální. Tato transformace byla umožněna rozvojem výpočetní techniky - především osobních počítačů a jejich propojení počítačovými sítěmi. Ačkoliv proces transformace společnosti do její digitální podoby nebyl zcela dokončen, lze říci, že transformační potenciál nástupu počítačů byl již vyčerpán.

V oblasti průmyslu jsou pro tuto etapu typická zařízení PLC, která jsme již v této kapitole popisovali, a nástup robotizace. Robotizací se rozumí nasazování jednoúčelových automatizovanných systémů, automatizující úkon ve výrobním procesu, který byl do té doby závislý na práci člověka. Tato etapa robotizace však nemá potenciál nahradit člověka ve výrobním procesu zcela. Automatizovány jsou tak především jednoduché kroky ve výrobě, které lze dobře popsat zefektivnit její výkon nasazením automatizovaného systému.

Konečně ***4. průmyslová revoluce*** ... není úplně exaktně definovaná. Jedním z důvodů je, že probíhá v současnosti a tak lze pozorovat jisté počínající revoluční změny ve společnosti, ale zároveň není možné úplně přesně odhadnout kam tyto změny povedou. Co však lze udělat již dnes je popsat hnací motor těchto změn - což jsou čtyři základní komponenty, které lze pak dále rozpracovávat do větších podrobností:

- kyber-fyzické systémy
- Internet of Things (IoT), tedy internet věcí (výměna informací mezi IoT zařízeními v cloudu, big data)
- dostupnost výpočetních zdrojů na vyžádání (cloudové služby, širokopásmové připojení k Internetu)
- strojové učení (big data, metody strojového učení včetně umělé inteligence)

Společně výše uvedené komponenty mají potenciál posunout procesy nejen ve výrobních společnostech na novou úroveň. Shromažďování dat z různých typů senzorů včetně např. obrazové informace pořízené kamerami mohou být zpracovány pomocí pokročilých metod *strojového učení* k odvození požadovaných činností automatizovaného systému.

Průběh procesu tak nemusí být explicitně popsán, musí být pouze kvalitně zachyceny, v dostatečné míře podrobnosti, data popisující tento proces. Metody strojového učení, především pak metody tzv. *hloubkového učení* jsou schopny tento proces formalizovat.

Takový přístup umožňuje automatizovat činnosti, které v minulosti automatizovat nebylo možné. K tomu je ale potřeba dodat, že v současnosti není možné automatizovat všechny činnosti ve výrobních procesech. Výstupem transformace je tak v současnosti pouze užší spolupráce člověka a stroje. V současnosti není zcela jasné, zda se jedná pouze o přechodný stav, který bude postupně s vývojem technologií ustupovat, nebo se jedná o stav trvalejší determinovaný samotnou podstatou používaných procesů.

Z výše uvedeného je potřeba si vzít jisté poučení. Lze předpokládat, že transformace společnosti vyvolaná nástupem různých technologií a postupů souhrnně označovaných jako Průmysl 4.0 zasáhne všechny aspekty společnosti a to včetně oblasti bezpečnosti, která je primárním předmětem zájmu našeho studia.

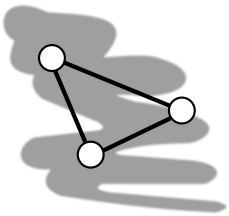

Metody strojového učení
V tomto předmětu se budeme vybranými metodami strojového učení zabývat v druhé polovině semestru a tím pádem také druhé polovině těchto skript.

V budoucnu tak budeme pravděpodobně mít k dispozici výrazně větší množství dat popisující chování zájmových systémů nebo situace v zájmovém prostoru. To ale automaticky neznamená, že tato informace bude zpřístupněna všem osobám, které by z ní mohly profitovat - tedy např. bezpečnostním pracovníkům. Aplikace pro bezpečnost proto budou muset být teprve vyvinuty. Takový vývoj je však možný pouze v úzké spolupráci mezi výrobci/dodavateli těchto systémů a specialisty na bezpečnost.

Technologie je pouze nástroj a my musíme najít efektivní způsob jak jej využít.

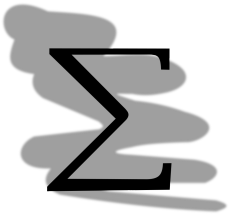

Shrnutí
V této kapitole jsme se seznámili s řadou různých zařízení, které jsou využívány pro automatizaci technologických procesů. **PLC** slouží pro automatizované řízení technologie, na základě předem připraveného programu. Podstatou takového řízení jsou změny v nastavení regulačních prvků na základě údajů ze senzorů popisující stav řízené technologie a následné kontroly vývoje hodnot senzory monitorovaných veličin - zda regulace vede k cíli.
Ne vždy je možno technologii uregulovat čistě automaticky, proto zejména pro složitější systémy se používá systém SCADA, který umožňuje stav řízené technologie v člověkem snadno pochopitelné podobě vizualizovat. Operátor/dispečer pak může případný problém v technologii identifikovat a manuálně jej korigovat. Vzhledem k tomu, že řízení je většinou centralizované a často také geograficky vzdálené, je nutné řešit způsob, jakým může být řízení realizováno dálkově. Vzdálené připojení lze realizovat pomocí běžně dostupných síťových technologií (které nebyly probírány v této kapitole :-), v automatizaci se ale využívá také zařízení **RTU** umožňující řízení připojené technologie v čistě textovém režimu, pomocí „terminálu“.
Ovládání systému může ale nabývat různých podob. Všechny systému umožňující člověku manipulovat se systémem souhrnně označujeme jako **HMI** - rozhraní člověk - stroj.

Kontrolní otázky

1. Co je automatizace a k čelu slouží?
2. Vysvětlete regulační smyčku.
3. Co je PLC?
4. K čemu slouží SCADA systém?
5. Co je RTU?

Správné odpovědi

1. Jedná se o technologie a postupy umožňující automaticky řídit systém, tak aby jeho chod byl udržován v určitých (předem stanovených parametrech).
2. Regulace je prováděna na základě snímání veličin ze senzorů instalovaných na řízené technologii, jejich vyhodnocování a automatizovaných změnách v nastavení provozu technologie. Senzory jsou zpětně sledovány pro zjištění zda regulace konverguje k cíli.
3. Zjednodušené odpovědi na otázky 3 - 5 naleznete také ve shrnutí kapitoly.

Kapitola 2

Real-timové databáze

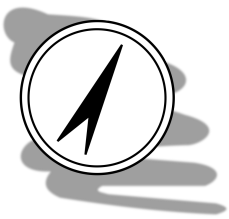

Náhled kapitoly
V této kapitole navážeme na kapitolu předchozí a zaměříme se především na funkci databáze umožňující shromáždit a spravovat informace o stavu technologie na jednom místě - v databázi. Na databáze plnící tuto úlohu jsou ale kladeny odlišné nároky, proto hovožíme o tzv. *realtimových databázích.*

Po přečtení této kapitoly budete
vědět

1. čím se liší databáze pracující v reálném čase od běžně používaných databází
2. jaké nástroje a strategie lze použít pro zrychlení databázových operací

Získáte

1. základní znalosti o funkci SQL jazyka

Čas pro studium
Pro prostudování této kapitoly budete potřebovat přibližně hodinu.

2.1 Real-time databáze vs relační databáze

V minulé kapitole jsme se seznámili se základní funkcí některých zařízení pro automatizaci technologií. Nutnost řídit technologii nám ale vyvolala jeden poměrně závažný problém - *efektivní řízení je možné pouze pokud je prováděno na základě aktuálních údajů.* Tedy řízení může uspět pouze pokud víme v jakém stavu se nachází technologie teď, v okamžiku řízení.

Jak ale takový požadavek zajistit? Požadavek očividně vyvíjí tlak na to, aby údaje ze senzorů byly ukládány co možná nejdříve od okamžiku jejich vzniku (pořízení) tak, aby řídící systém s nimi mohl dále pracovat. Existuje řada možností, jak toto zajistit - řídící systém může třeba pracovat se senzory přímo, ale takové řešení obvykle není dobře škálovatelné a tak obvykle přistupujeme k takovým údajům spíše zprostředkovaně. Data ze senzorů jsou v takovém případě konsolidována na jednom místě, které bývá označováno jako třeba *data historian.*

Data historian může být organizován různě - může se jednat o „ploché“ textové soubory obsahující data v tabelární formě (např. ve formátu CSV), pro složitější technologie se ale častěji používají databáze. Databáze jsou rutinně využívány většinou informačních systémů pro ukládání dat, která tyto systémy spravují. S provozem databázových systémů jsou tak rozsáhlé zkušenosti. Oproti požadavkům, které jsou ale kladeny na ukládání dat v běžných, provozních informačních systémech, klademe na zpracování dat pro účely řízení technologií poněkud jiné požadavky. Zkusme tyto požadavky porovnat.

Požadavky běžného informačního systému

1. všechny údaje musí být uloženy do databáze (údaje nelze vynechat)
2. hodnota dat v čase je konstantní (neklesá v čase)
3. vysoká rychlost uložení je žádoucí, nikoliv však nezbytně nutná

Požadavky na data historiana (real-timová databáze)

1. hodnota dat v čase klesá
2. ne všechny data je nutné ukládat, byť zajištění co možná největší kompletnosti databáze je žádoucí
3. vysoká rychlost manipulace s daty je nutnost

Požadavky kladené na databázi jsou tedy poměrně odlišné, což vede k tomu, že někdy databáze pro automatizaci jsou označovány jako realtimové, tedy databáze pracující s daty v reálném čase.

Pokud se ale nad tím zamyslíme je samotný název *realtimová databáze* více méně protimluv. Každý proces měření a následného ukládání dat vyžaduje určitý čas. Tím v celém procesu nevyhnutelně vznikají různé prodlevy, latence. V zájmu efektivity řízení, je, aby tyto prodlevy byly co možná nejmenší - odtud tedy tlak na zpracování v reálném čase. Existence latence ale způsobuje, že zpracování dat databází nebude nikdy ve zcela reálném čase, maximálně se můžeme přiblížit ke *skoro reálnému času* zpracování.

Takový čas znamená, že data nejsou sice zpracována v reálném čase, prodlevy a latence v systému jsou ale zanedbatelné z pohledu efektivity řízení. To co je a není zanedbatelné se přitom bude lišit technologie od technologie.

Technicky jsou realtimové databáze, alespoň v současnosti, *databázemi relačními*. Otázka tedy je vzhledem k tomu, že potřebujeme zajistit zpraocvání dat v co možná nejkratším čase, jak postupovat, abychom práci databáze urychlili? Metod, které k tomuto účelu lze použít je velké množství: volbou vhodné databáze a její správné nastavení, investicí do výkonnějšího hardware, na kterém bude databáze provozována, apod.

Postup je vždy stejný. V každém systému existují určitá úzká hrdla, která je následně možné řešit, aby mohlo být dosaženo vyššího výkonu. Z hlediska hardware může být problém v:

- šířce použité přenosové cesty
- rychlost operací Input-Output (IO)
- kapacita paměti
- počet procesorů a jejich vlastnosti (např. počet jader procesoru, provozní frekvence atd.)
- apod.

V případě software pak může být problém:

- volba/nastavení operačního systému (v nastavení např. volba souborového systému)
- volba/nastavení databázového systému
- volba rozhraní, které bude využíváno pro manipulaci s databází (např. Open Database Connect (ODBC) nebo Java Database Connect (JDBC))
- apod.

Výkonnost systému manipulace s daty je tedy závislá na kombinaci řady faktorů - neexistuje jedno „univerzálně správné řešení“, které by bylo možné aplikovat na všechny situace bez rozdílu.

Z hlediska možných řešení ve výše uvedeném seznamu není obsažena možnost škálovaní výkonu pomocí použití tzv. *databázového klastru*. Hlavní myšlenka tohoto řešení je ta, že možnost navyšování databázového serveru jako jednoho zařízení je omezená. Je možno zvětšit paměť, použít výkonnější procesor, nebo přidat další procesoru, pokud to motherboard podporuje apod. Ve finále jsme ale vždy limitovaní technickými možnostmi rozšiřitelnosti daného systému.

Pokud ale nestačí jeden server, může být výhodnější použít servery dva, nebo tři nebo ještě více. Takové nasazení je obvykle realizováno pomocí databázového klastru. Vizuálně bychom si mohli takový klastr představit jako na obr. 2.1.

Klíčovou roli v klastru hraje tzv. *load balancer*. Jedná se o zařízení, které kontroluje rozložení zátěže serverů, v tomto případě tedy serverů databázových. Práce na jednotlivé servery je přidělována podle aktuálního zatížení serverů tomu nejméně zatíženému. Účelem rozkládání zátěže, je zajistit, že všechny servery v klastru jsou využívány rovnoměrně.

To ale znamená, že databázové operace nejsou prováděny zároveň na obou databázových serverech. Load balancer představuje určitou úroveň abstrakce databázové architektury. Externí zařízení vnímají

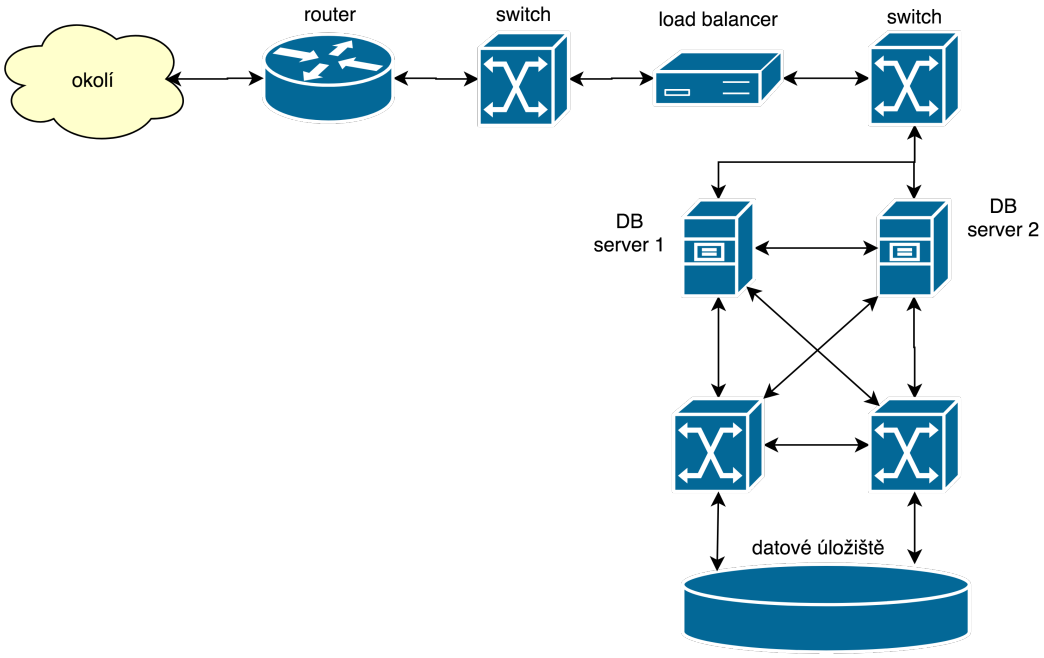

Obrázek 2.1: Databázový klastr

celý klastr jako jedno zařízení - nevidí do vnitřní organizace klastru. To nám dává poměrně široké možnosti pro škálování výkonu, ale také přípravu na případná selhání jednotlivých komponent klastru. V takovém případě obvykle také zároveň řešíme vzájemnou zastupitelnost uzlů v klastru v případě výpadku což na jedné straně v běžném provozu zvyšuje celkový výkon klastru, na druhé straně v případě selhání komponent umožňuje postupně degradovat výkon na místo totálního výpadku služby v tomto případě databázového systému.

Synchronizace dat napříč databázemi pak probíhá procesem nazývaným *replikace dat* s tím, že replikovány jsou pouze změny v uložených datech. Tímto způsobem se minimalizují požadavky na datové přenosy mezi jednotlivými uzly klastru.

Kromě možnosti navýšení výkonu je také výhodou vzájemná zastupitelnost těchto zařízení i v případě výpadku. Např. pokud v klastru selže jeden z databázových serverů, load balancer rozdělí jeho zátěž na zbývající servery. Řešení pomocí klastru je tak z mnoha pohledů odolnější (ne jen výkonnější). Realizace klastru je jednou z metod jak zvýšit resilienci provozovaného systému.

Všimněte si také, že na obr. 2.1 data nejsou uložena přímo na databázovém serveru, ale na připojeném datovém úložišti. Takové úložiště bývá realizováno často pomocí diskového pole. Disková pole lze pak poměrně jednoduše škálovat z pohledu požadovaného výkonu, ale také odolnosti proti hardwarovému selhání jednotlivých disků.

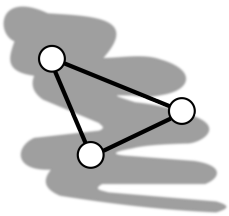

Klastry, souvislosti
Architektura představená na obr. 2.1 je použitelná univerzálně pro různé typy serverů. Podobným způsobem tak lze škálovat např. servery webové a nejen je.

Rozdíl mezi realtimovou a běžnou databází je taktéž v samotné organizaci dat. K tomu ale abychom plně ocenili důsledky těchto rozdílů, je potřeba pochopit způsob, jakým jsou v databázích realizovány tzv. *transakce*.

2.2 Transakce

2.2.1 Organizace dat v databázi

Relační databáze mají dva konstruktory - *tabulky*, kde jsou shromažďována data, a *relace* definující vazby mezi jednotlivými tabulkami. Vzhledem k tomu, že z předchozí kapitoly už víme, že pro účely automatizace potřebujeme velmi specifická data, je otázka, zda tato specifičnost se projeví také na struktuře dat ukládaných v databázi a pokud ano, tak jakým způsobem?

Zkusme vizualizovat základní údaje udržované sociální sítí Twitter, viz obr. 2.2. Vizualizaci prosím berte jako ilustrativní. Je zjednodušená, tak aby obsahovala pouze metainformace o tweetech, nikoliv text tweetu, případně další média s ním spojená.

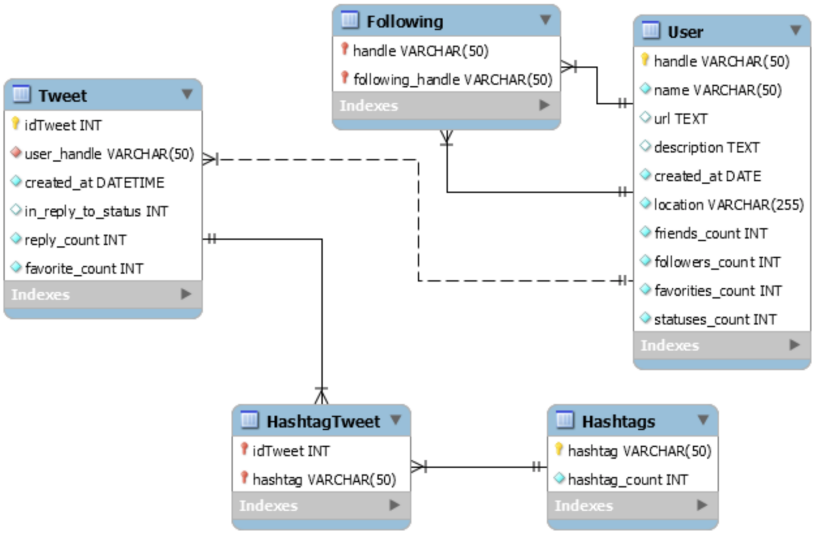

Obrázek 2.2: ERD diagram metadat příspěvků v síti Twitter (adaptováno z [79])

Databáze z obr. 2.2 by mohla být použita např. pro analýzu vazeb mezi jednotlivými uživateli. Na obr. hrají hlavní roli tabulky User a Tweet, vše ostatní se pak vztaženo k nim. Propojení tabulek se děje pomocí relací. Úkolem relace je specifikovat způsob, jakým spolu souvisí tabulky na obou stranách definovaných relací.

Relace mezi tabulkami Tweet a User je definovaná přes položky user handle z tabulky Tweet a handle z tabulky User. Získávání dat z databáze se pak děje právě přes tyto související sloupce tabulek - propojení je tak obvykle realizováno tam, kde jsou hodnoty souvisejících polí stejné.

Relace tedy umožňují vytvářet komplexní 2D struktury v datech, a to v okamžiku kdy to potřebujeme.

Jaké informace ale do databáze ukládá automatizovaná technologie? To bude samozřejmě záviset na charakteru technologie a zvolených senzorech, které ji monitorují. V obecné rovině budou ale data následujícího charakteru:

- údaj ze senzoru (může se jednat o text, číslo, nebo třeba binární data, jako jsou fotografie)
- údaj o čase, kdy bylo provedeno měření
- případně údaj o senzoru jako takovém (např. identifikátor)

Lze uvažovat o různých přístupech. Jednotlivým senzorům můžeme např. vytvořit samostatné tabulky. Struktura takové tabulky by mohla být následující: Senzor1(DatumAČas, hodnota). Jméno tabulky pak identifikuje senzor, ze kterého bylo pořízeno měření.

Jinou možností by bylo zobecnění výše uvedeného řešení pro větší množství senzorů měřících stejnou veličinu. Struktura tabulky by mohla vypadat následovně: SenzoryTeploty(DatumAČas, teplota, IDSenzoru). K identifikaci senzoru pak slouží sloupec IDSenzoru. K IDSenzoru lze také případně vést relaci k další tabulce se servisními informacemi k senzoru, popř. dalšími informacemi nutnými k řízení.

Třetí možností je konstrukce tabulky: Hodnoty(DatumAČas, HodnotaSenzor1, HodnotaSenzor2, ..., HodnotaSenzorN). V této konfiguraci jsou hodnoty senzorů evidovány samostatně v jednotlivých

sloupcích tabulky. Tato konfigurace ale předpokládá, že interval měření bude konstantní a univerzální pro všechny v tabulce zavedené senzory.

Z pohledu databázové teorie je optimální pouze druhé řešení a např. řešení třetí nerespektuje ani základní požadavky na konzisteci dat formulované do tzv. *první normální formy*. Ta říká, že tabulka by neměla obsahovat opakující se sloupce, což není v posledním případě splněno, protože účel všech sloupců HodnotaSenzorX je stejný - evidovat hodnotu určitého senzoru.

Jelikož je ale použití databáze pro účely řízení v reálném čase odlišné, mohou být všechny výše uvedené možnosti (a řada dalších) přijatelné. Oproti použití databáze jako backendu běžného informačního systému lze předpokládat pouze minimální zásahy do struktury tabulek. Ta tak zůstane neměnná prakticky po celou dobu provozu řízené technologie. Z tohoto důvodu nemusí fakt, že databáze není ani v první normální formě, představovat závažnější problém.

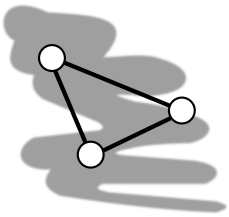

Databáze - návaznosti
Diskuze o databázích je užitečná nejen pro pochopení fungování automatizačních systémů, ale také fungování běžných informačních systémů a možnosti propojování a analýzy dat. Vhodné spojení dat z různých zdrojů představuje první krok v procesu dolování dat, kterým se budeme zabývat v druhé polovině skript.

2.2.2 Jazyk SQL

Jakým způsobem lze s databází manipulovat? Většina databází pracuje s jazykem SQL. Příkazy (dotazy) jazyka lze rozdělit podle toho, co dělají:

- Dotazy definující nebo měnící strukturu databáze (CREATE TABLE ..., ALTER TABLE ...)
- Dotazy výběrové (SELECT FROM ...)
- Dotazy modifikující data (INSERT INTO ..., UPDATE ... WHERE ..., DELETE ...)
- Dotazy pracující s tzv. programátorskými objekty jako jsou pohledy, uložené procedury a další (v těchto skriptech se tomuto typu dotazů nebudeme věnovat)

Definice struktury tabulek
Účelem této podkapitoly je dozvědět se něco o jazyku SQL, propojování dat a podobných záležitostech. jednotlivé typy příkazů budeme demonstrovat na tabulkách Tweet a HashtagTweet z obr. 2.2. Nejedená se sice o příklad související s automatizací, ale jednodušeji si jej prakticky představíte a principy zůstávají stejné.

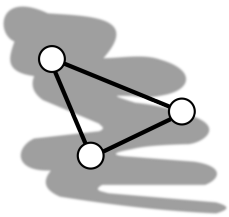

Databáze - základy
Pokud se v následujícím textu nebudete „chytat“, doporučuji projít první kapitolu skript *Bezpečnostní informatika 1 - Návody do cvičení* [85], kde je rozebrán úvod do databázové teorie, problematika normalizace báze dat a způsob odvození báze dat s demonstrací pro databáze MS Access a LibreOffice Base. Zatímco v BI definice tabulek probíhala naklikáním, v tomto případě je vytváříme přímo pomocí SQL dotazu.

Výpis 2.1: SQL: definice tabulek - příklad Twitter

```
1  CREATE TABLE Tweet (
2    idTweet INT NOT NULL AUTOINCREMENT,
3    user_handle VARCHAR(50) NOT NULL,
4    created_at DATETIME NOT NULL,
5    in_reply_to INT,
6    reply_count INT,
7    favorite_count INT,
8    PRIMARY KEY (idTweet)
9  );
10
11 CREATE TABLE HashtagTweet (
```

```
12   idTweet INT NOT NULL,
13   hashtag VARCHAR(50),
14   PRIMARY KEY (idTweet, hashtag)
15 );
```

Příkaz SQL pro vytvoření tulky začíná vždy klíčovými slovy CREATE TABLE jméno tabulky. Do kulatých závorek jsou pak vkládány datové definice jednotlivých sloupců ve formátu jméno sloupce, datový typ, případné další modifikátory.

Např. sloupec idTweet je celočíselného datového typu (INT), musí být vyplněn (NOT NULL) a vyplnění bude probíhat automaticky (AUTOINCREMENT).

V příkazu CREATE je možno také specifikovat primarní klíč, který jednoznačně bude identifikovat každý jeden řádek dané tabulky. V případě tabulky Tweet se jedná o sloupec idTweet, v případě tabulky HashtagTweet je pak použit složený primární klíč - z obou sloupců tabulky.

Datových typů databáze podporují celou řadu, my jsme použili INT pro celé číslo, VARCHAR(délka řetězce) pro textové řetězce o maximální zadané délce, maximální délka je specifikována v závorce, DATETIME - datum a čas. Populární jsou také datové typy DOUBLE pro desetinná čísla, TEXT pro dlouhý text (nad 255 znaků), BLOB pro ukládání binárních objektů v databázi

Databáze od různých výrobců se mohou používanými datovými typy drobně lišit, berte proto prosím výše uvedený přehled jako orientační.

Pro úplnost uvádím také obecnou strukturu CREATE SQL příkazu.

Výpis 2.2: SQL: struktura příkazu CREATE TABLE

```
1 CREATE TABLE Jmeno_tabulky (
2   jmenoSloupce datovyTyp dalsiModifikatory,
3   dalsiJmenoSloupce ...,
4   PRIMARY KEY (vsechny sloupce definujici klic oddelene carkami)
5 );
```

Již vytvořené je možno změnit pomocí SQL příkazu ALTER TABLE.

Výpis 2.3: SQL: struktura příkazu ALTER TABLE

```
1 ALTER TABLE Jmeno_tabulky
2   ADD jmenoSloupce datovyTyp modifikatory,
3   DROP COLUMN jmenoSloupce,
4   ALTER COLUMN jmenoSloupce datovyTyp;
```

Do tabulky i po vytvoření tak lze doplňovat nové sloupce (ADD), nebo je odebírat (DROP COLUMN). Každá databáze pak umožňuje také modifikovat definici již existujících sloupců. Různé databáze ale mohou využívat k tomuto účelu odlišná klíčová slova. ALTER COLUMN využívá např. MS Access nebo MS SQL Server, databáze MySQL ale používá klíčové slovo MODIFY COLUMN.

Datové typy odpovídají datovým typům popsaným v části věnované vytváření tabulek.

Výběrové dotazy

Výběry jsou realizovány pomocí příkazu SELECT. Zkusmě vybrat jeden záznam z tabulky Tweet - např. tweet s ID 25

Výpis 2.4: SQL: výběrový dotaz - příklad výběru konkrétního příspěvku

```
1 SELECT * FROM Tweet WHERE idTweet = 25;
```

Všechny Tweety uživatele @uzivatel:

Výpis 2.5: SQL: výběrový dotaz - příklad výběru příspěvků určitého uživatele

```
1 SELECT * FROM Tweet WHERE user_handle LIKE '@uzivatel';
```

Ve výše uvedených příkladech je postup stále stejný: SELECT sloupce FROM jménoTabulky WHERE podmínka. V předchozích příkladech jsme specifikovali, že chceme vybrat všechny sloupce pomocí zástupného znaku *. V případě, že bychom chtěli ale vybrat pouze některé ze sloupců, bylo by potřeba místo * napsat jejich seznam oddělený čárkami.

Výběr v obou předchozích příkladech byl omezen pomocí operátory porovnání. V případě idTweet byl použit operátor =, protože idTweet je celočíselného datového typu (INT). Podobným způsobem bychom pro čísla mohli použit operátory >, >=, <, <=.

V případě porovnání proti textu je ale využíván operátor LIKE, hledaný textový řetězec je ohraničen 'znakem apostrofu'. Pokud nehledáme přesnou shodu, lze použít znak %, např. LIKE 'ABC%' vyhledá všechny řetězce (v daném sloupci) začínající na ABC.

Podmínky pak lze řetězit kombinovat pomocí logických spojek AND a OR.

Výběry lze realizovat také napříč tabulkami. Řekněme, že bychom chtěli vybrat všechny tweety s haštagem *#vyber*. Řekněme, že nás ale budou zajímat pouze sloupce user handle a created at:

Výpis 2.6: SQL: výběrový dotaz - propojování tabulek vnitřním spojením (INNER JOIN)

```
1 SELECT
2   Tweet.user_handle,
3   Tweet.created_at
4 FROM Tweet
5 INNER JOIN HashtagTweet ON HashtagTweet.idTweet = Tweet.idTweet
6 WHERE hasthtag LIKE '#vyber';
```

Spojení tabulek je realizováno pomocí INNER JOIN - tedy vnitřního spojení. Tímto spojením se bude vybírat průnik obou tabulek. INNER JOIN ale není jedinou možností propojení. Výsledek různých spojení je v grafické podobě dostupný na obr. 2.3.

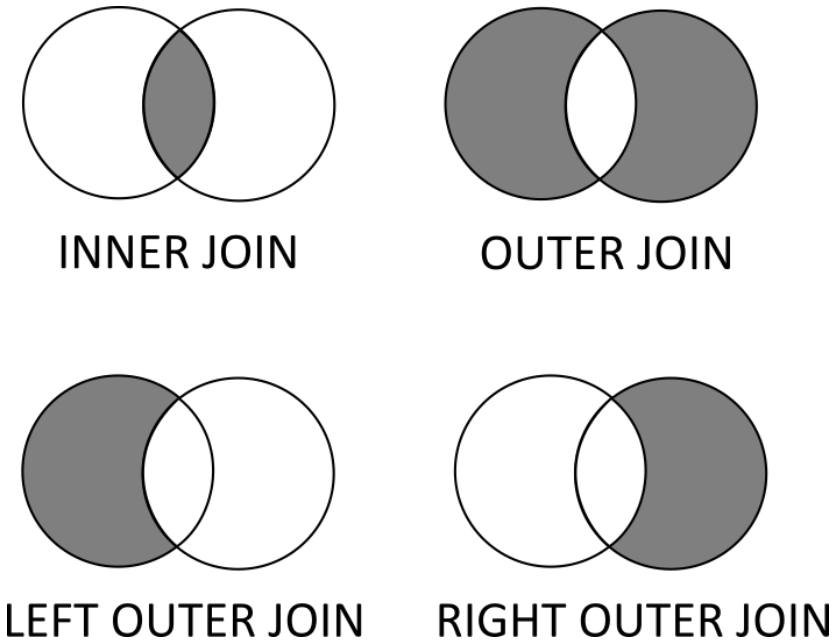

Obrázek 2.3: Výsledky spojení dvou tabulek

Kromě vnějších (OUTER) spojení, jsou používané také prosté levé (LEFT JOIN) a pravé (RIGHT JOIN). Tato spojení se liší od spojení z obr. 2.3 tím, že ve výběru je obsažen také průnik obou tabulek.

Tímto způsobem lze spojovat libovolné množství tabulek v databázi. Je ale potřeba mít na paměti, že se vzrůstajícím množství spojovaných tabulek rostou národy na spotřebovávané zdroje databázového serveru.

Aktualizace tabulek

Aktualizací tabulky rozumíme obvykle vložení nových řádků do tabulky (INSERT), aktualizaci řádků v tabulce (UPDATE), nebo jejich výmaz (DELETE).

Vložení nového řádku do tabulky Tweet by mohlo vypadat následovně:

Výpis 2.7: SQL: příklad vkládání údajů do tabulek (INSERT INTO)

```
INSERT INTO Tweet (user_handle, created_at)
VALUES
  ('@uzivatel', '2018-08-08 08:15:22'),
  ('@uzivatel', '2018-08-08 09:01:34');
```

Všimněte si, že není nutné vždy zadávat všechny sloupce tabulky, pouze ty, které jsou povinné. V tabulce Tweet jsou ale povinné 3 sloupce, tím třetím je idTweet. Tento sloupec je ale nadefinován jako automatické číslo, databáze jej proto vyplní sama.

Najednou lze do tabulky vložit také více řádků. Jednotlivé řádky jsou vkládány za klíčové slovo VALUES do kulatých závorek. Jednotlivé hodnoty sloupců jsou odděleny čárkami. Jednotlivé řádky jsou taktéž oddělovány čárkami.

Výše uvedený příklad bychom mohli zobecnit:

Výpis 2.8: SQL: struktura příkazu INSERT INTO

```
INSERT INTO jmenoTabulky (sloupec1, sloupec2, ...)
VALUES
  (hodnotyRadek1),
  ...,
  (hodnotyRadekN);
```

Aktualizace je možno provádět nad celou tabulkou nebo její částí specifikovanou klauzulí WHERE.

Výpis 2.9: SQL: příklad aktualizace zaznamu v databázi (UPDATE)

```
UPDATE Tweet SET created_at = '2018-08-08 05:00:00';

UPDATE
  Tweet
SET favorite_count = 0
WHERE user_handle LIKE '@uzivatel';
```

První příklad nastaví datum a čas vytvoření tweetu na 8. 8. 2018 5 hodin ráno. V druhém příkladu bude pro všechny tweety uživatele @uzivatel nastaven počet lajků na 0.

V případě, že je potřeba aktualizovat více než jeden sloupec, zadávají se všechny do klauzule SET a oddělují se čárkou.

Výmaz z tabulky se provádí pomocí příkazu DELETE. Pokud výmaz není omezen klauzulí WHERE, provede se výmaz obsahu celé tabulky (tabulka samotná zůstane, ale bude prázdná).

Výpis 2.10: SQL: příklad výmazu záznamů z databáze (DELETE)

```
DELETE FROM Tweet;

DELETE FROM Tweet WHERE user_handle LIKE '@uzivatel';
```

První příklad smaže obsah tabulky Tweet. Příklad druhý pak smaže pouze ty řádky tabulky Tweet, kde je autorem @uzivatel.

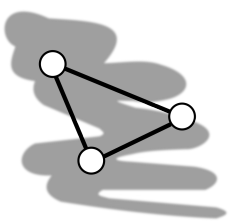

Jazyk SQL - další studium

V této podkapitole jsme se seznámili pouze se základy jazyka SQL. Na Internetu existuje celá řada výborně zpracovaných materiálů pro Vaše případné další studium. Velmi dobře je např. zpracovaný SQL Tutorial na w3schools.com [82]. Vhodným zdrojem informací je pak také manuál Vámi zvoleného databázového systému.

2.2.3 Transakce

Konečně se dostáváme k transakci - *co je tedy transakce*? **Transakce je posloupnost souvisejících databázových operací.**

Výše uvedená definice je velmi stručná, na druhou stranu v sobě obsahuje relativně velké množství prvků, které neznalé mohou zmást. Takže zkusme definici rozebrat. Začněme nejprve databázovou operací - tu můžeme zjednodušeně vnímat jako jeden (jakýkoliv) příkaz jazyka SQL z předchozí podkapitoly.

Posloupností pak rozumíme fakt, že příkazy jsou vykonávány postupně v jistém určeném pořadí - operace v jedné transakci tak nemohou probíhat paralelně. Na druhou stranu paralelně může databáze zpracovávat více (nezávislých) transakcí.

Souvisejícími operacemi pak máme na mysli to, že příkazy jazyka SQL, kterými manipulujeme s databází spolu mohou souviset, ale také nemusí - prováděné operace spolu nutně nemusí souviset. Technicky můžeme do jedné transakce vložit nezávislé příkazy, ale praktický smysl to nemá, protože se pouze prodlouží dobu vykonávání příkazů, které by se jinak vykonávaly paralelně.

Účelem transakce je tedy transformovat databázi z jednoho konzistentního stavu do druhého. Jako si to představit? Řekněme, že potřebujeme v databázi z obr. 2.2 změnit identifikátor uživatele (sloupec handle). Mohli bychom postupovat tak, že aktualizujeme pomocí příkazu UPDATE tabulku User a handle přenastavíme.

To ale nestačí - identifikátor uživatele je totiž použit také v tabulkách Following (sloupec handle) a Tweet (sloupec user_handle). Pokud nepřenastavíme také je, údaje v těchto tabulkách se „rozpojí“ a tím se naruší integrita databáze.

Správný postup je pak takový že musíme aktualizovat handle ve všech třech tabulkách. Přitom potřebujeme zajistit, aby aktualizace proběhla ve všech těchto tabulkách nebo v žádné. Co to znamená? Aktualizaci v tomto případě provedeme pomocí tří příkazů UPDATE. Jenomže, co když některý z těchto příkazů selže? Důvodů může být celá řada - mohli jsme udělat chybu v příkazu (např. překlep), nebo zrovna v okamžiku provádění příkazu byl problém v databázovém serveru. Pokud bychom přijali pouze částečnou aktualizaci databáze narušili bychom její konzistenci.

Proto potřebujeme, aby se tyto operace provedly celé - pokud se to nepovede, potřebujeme mít schopnost odvolat změny v databázi a vrátit ji do stavu jako předtím, než jsme začali s úpravami. Efektivní cestou, jak toto zajistit je zařadit takto související příkazy do jediné transakce.

Transakce - základní požadavky

Základní požadavky, které jsou kladeny na databázi z hlediska provádění transakcí se skrývají pod zkratkou ACID (atomicita - konzistence - izolovanost - nevratnost).

Atomicitou rozumíme, že transakce probíhá jako celek, je tedy nedělitelná. Prakticky to znamená, že transakce proběhne úspěšně celá, anebo neproběhne vůbec. Jinými slovy, v případě, že některá operace v rámci transakce selže, předchozí, úspěšně provedené operace v rámci transakce jsou revokovány (pomocí příkazu ROLLBACK) a databáze se dostane do stavu jako před započetím transakce.

V případě, že transakce proběhne úspěšně celá potvrdí se transakce pomocí příkazu COMMIT.

Konzistence zaručuje, že databázový systém je transakcemi transformován z jednoho konzistentního stavu do druhého, opět konzistentního, stavu. Tato vlastnost souvisí s úplným provedením transakce. Nekonzistence jsou do databáze vnášeny buď chybným návrhem databáze, tento problém však transakce neřeší, nebo provedením pouze částečných změn (jako třeba pouze polovina požadovaných operací). Protože transakce se provede celá nebo vůbec.

Transakce tedy efektivně brání problémům s konzistenci databáze.

Izolovanost – transakce je izolována od zbytku databáze. Ostatním operacím nebo transakcím nejsou dostupné výsledky operací prováděných v rámci transakce do doby úplného dokončení této transakce.

Nevratnost – pokud transakce byla úspěšně dokončena (příkazem COMMIT), není možné ji odvolat. Změny transakce je možné zvrátit pouze v průběhu transakce.

Pokud je potřeba po dokončení transakce odvolat změny, je nutné jít cestou mimo databázi - nejčastěji se používá obnova ze záloh.

Realtimové databáze k těmto principům přidávají ještě **časové omezení**. Z předchozí kapitoly již víme, že z hlediska automatizace mají největší význam aktuální informace, které popisují stav, ve kterém se nachází řízená technologie teď.

Pokud tedy má tedy transakce mít maximální přínos, musí být dokončena v jistém, omezeném časovém intervalu. Tento interval obvykle nastavují tvůrci aplikací, které s těmito systémy pracují. Možná Vás napadne otázka, co s transakcemi, které neskončí včas. Důvodů, proč transakce trvá déle než je žádoucí přitom může být celá řada od technických – proces zachycený transakcí včas neskončil (stále trvá) až po to, že došlo k přetížení serveru, který pak nestačí vyřizovat transakce.

Přínos transakce graficky si lze představit podobně jako na obr. 2.4.

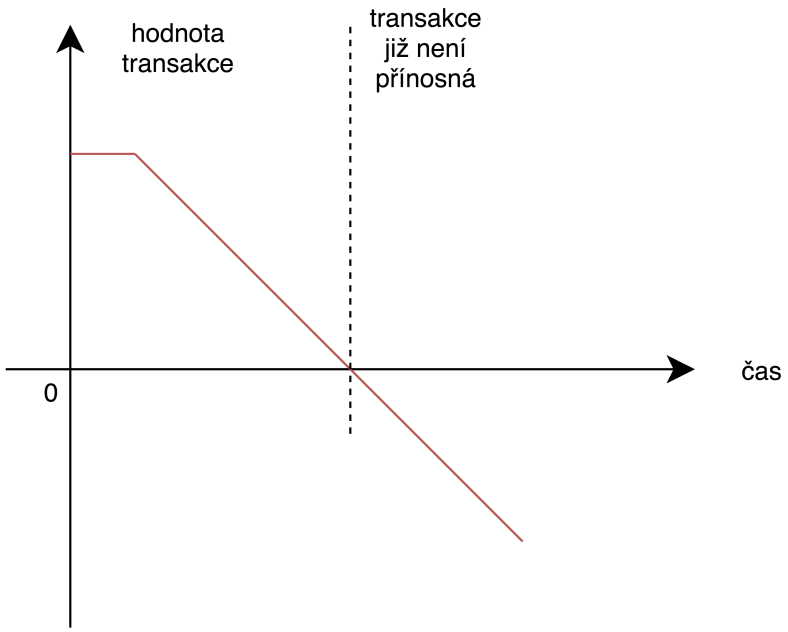

Obrázek 2.4: Změna hodnoty transakce v čase

Z tohoto pohledu je potřeba rozlišit přínos, jaký má dokončení této opožděné transakce:

1. opožděné dokončení transakce je přínosné – hodnota přínosu se ale obvykle nerovná přínosu ze včas dokončené transakce (např. aktuální hodnota senzoru výrobní linky vs. hodnota téhož senzoru z minulého dne). V takovém případě se databázový systém snaží transakci dokončit – obvykle ale opožděné transakci přiřazuje nižší prioritu tak, aby nebyla ohrožena schopnost databáze vkládat aktuální nově zadávaných (čerstvých) údajů.
2. V okamžiku, kdy transakce ztratí hodnotu úplně nebo její hodnota klesne pod určitou, předem stanovenou mez, může databázový systém její dokončení stornovat, tak aby si uvolnil systémové zdroje nutné pro vyřizování přínosných transakcí. Ne všechny typy transakcí ale lze stornovat.
3. Hodnota nedokončené transakce může dokonce poklesnout pod nulovou hodnotu – nedokončení transakce v takovém případě indukují další náklady. V takovém případě systém může buďto transakci stornovat (je-li to možné) nebo naopak navýšit prioritu výkonu transakce, tak aby transakce byla přednostně dokončena a nepřinášela další náklady.

Správné nastavení doby expirace jednotlivých transakcí je poměrně složitou záležitostí. Schopnost systému zpracovávat data je proto potřeba dlouhodobě sledovat a vyhodnocovat. Ke změně rychlosti práce s daty může docházet také v souvislosti se změnami v životě databázového serveru.

Dopad na výkon mohou mít také bezpečnostní aktualizace operačního systému. Např. záplaty na chyby v procesorech společnosti Intel známé pod jmény Spectre [45] a Meltdown [50] mohou způsobit pokles rychlosti určitých operací až o 15 %, zejména na starších typech procesorů.

Nastavení a údržba databázového systému je záležitostí, které se musí dlouhodobě věnovat IT specialista.

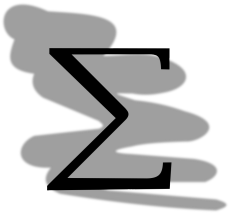

Shrnutí

V této kapitole jsme se seznámili se způsobem fungování relačních databází. Pro účely řízení se využivají databáze přizpůsobené co možná nejrychlejší odezvě - tyto označujeme jako *realtimové*. Tyto databáze jsou sice stále relační, využívají ale některé postupy pro zkrácení doby zpracování.

V úvahu takové databáze berou především hodnotu zpracovávaných dat. To je také největší rozdíl proti databázím používaných v běžných informačních systémech, kde hodnota dat je v čase stálá. Oproti tomu u realtimových databází hodnota zpracovávaných dat v čase klesá. Pro databázi tak může být výhodné rezignovat na nejstarší nezpracované transakce a uspořený strojový čas pak může být využit pro vyřízení transakcí aktuálních.

Kontrolní otázky

1. Čím se liší realtimová a relační databáze?
2. Jakými SQL příkazy lze aktualizovat data v tabulce?
3. Co rozumíme atomicitou transakce?
4. K čemu lze použít údaj o době zpracování transakce?
5. Jak se liší INNER JOIN spojení a LEFT JOIN?

Správné odpovědi

1. viz shrnutí.
2. INSERT, UPDATE, DELETE.
3. Transakce se provede celá nebo se neprovede vůbec (musí úspěšně proběhnout celá).
4. Staré nezpracované transakce, jejichž přínos zpracování je minimální, mohou být zahozeny aby se uvolnil výkon databázového systému pro zpracování transakcí nových.
5. INNER JOIN vybírá data tvořící průnik spojovaných tabulek, LEFT JOIN pak obsahuje všechna data z levé tabulky a data z pravé tabulky obsažená v průniku obou tabulek.

Kapitola 3

SCADA - příklad v Promotic

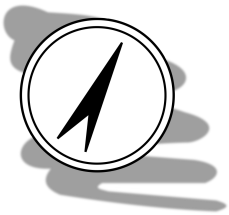

Náhled kapitoly
V této kapitole se seznámíme se systémem Promotic [55] Ostravské společnosti MicroSys. Jedná se o nástroj umožňující realizovat SCADA systém, popř. realizovat HMI.

Po přečtení této kapitoly budete
vědět

1. jakým způsobem jsou realizovány SCADA systémy
2. možnosti, jak vizualizovat různé typy údajů
3. jako funguje systém Promotic

Umět

1. vytvořit základní vizualizaci technologického procesu v systému Promotic

Čas pro studium
Odhad času potřebného pro prostudování této kapitoly je problematický, neboť tentokrát je očekáváno, že informace získané ve skriptech prakticky zužitkujete při přípravě semestrálního projektu. Proto je potřeba jednotlivé kroky prakticky zkoušet v Promoticu a experimentovat s prostředím ... různým lidem přitom taková práce trvá různě a některým pak výrazně déle než jiným.
K tomu Vám mohu pouze popřát, abyste u studia vytrvali ... látka není složitá, je pro Vás však nejspíše nová.

3.1 Promotic - instalace a projekt

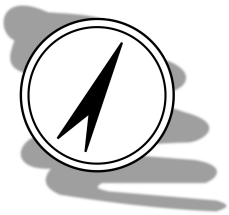

Průvodce
V této části se zaměříme na přípravu prostředí Promotic pro naši práci, vytvoříme projekt a podíváme se na jeho jednotlivé komponenty.

Instalace
Před použitím je nutno Promotic instalovat. Promotic je dostupný pouze pro operační systém MS Windows. Podporované verze operačního systému se liší podle verze Promotic. V době poslední aktualizace těchto skript (VIII 2020) jsou dostupné dvě základní verze systému:

- 9.0.x - nová verze systému, která vyšla ve stabilní verzi počátkem roku 2020, podporovány jsou operační systémy Windows 7 nebo novější

- 8.3.x - je starší verzí systému, která je v praxi stále ještě často používána. Je např. nainstalována na počítačových učebnách FBI. Tato verze podporuje operační systémy Windows XP nebo novější.

Na stránkách https://www.promotic.eu je možno stáhnout také starší verze prostředí Promotic. Důvodem pro dostupnost starších verzí je udržení zpětné kompatibility pro potřeby provozu v minulosti vyvinutých vizualizací technologických procesů. Nové verze jsou sice obvykle dopředně kompatibilní, pro složitější aplikace se ale mohou objevit nekompatibility, které provozovateli prostředí přejít na nejnovější stabilní verzi systému (a zůstane tak na starší, možná již nepodporované verzi systému).

Na domácích stránkách Promotic výše je možno stáhnout plnou verzi systému. Preferovat byste měli poslední stabilní verzi. V případě, že se Vám ji ale nedaří nainstalovat (což by se vzhledem k poměrně široké podpoře různých verzí operačního systému Windows nemělo stát), můžete vyzkoušet některou z předchozích verzí.

Promotic je dopředně kompatibilní - to znamená, že projekty vytvořené starší verzí Promotic lze otevřít v novější - bez ztráty funkčnosti, ale pozor opačně to již nejde. Tato kompatibilita je zajištěna tak, že systém Promotic detekuje verzi, ve které byl právě otevíraný projekt vytvořen a provede jeho převod do formátu nové verze. Před provedením převodu projekt zazálohuje, aby byla k dispozici také původní verze projektu pro případ, že by se automatický převod nepovedl.

Důvodem selhání může být např. použití komponenty dodané dalším výrobcem, která ale není kompatibilní s novou verzí prostředí. Pokud jsou ale používány čistě komponenty nabízené přímo prostředím Promotic, není potřeba se problémů s kompatibilitou obávat.

Na stránkách Promotic je ke stažení pro každou verzi dostupné samotné prostředí (označené např. Verze 8.3.26) a potom web klient. Web klient doplňuje do aplikací Promotic schopnost přístupu k výsledné aplikaci po sítí, pomocí webového prostředí. My ale tuto funkčnost nevyužijeme - takže pro práci nám bude dostačovat základní vývojové prostředí. K tomu je potřeba také dodat, že pro novou verzi 9.0.x již webový klient není k dispozici.

Při stahování dejte pozor, abyste stáhli poslední stabilní verzi. MicroSys někdy pro testování uvolňuje také vývojové (nestabilní) verze prostředí - zejména v období před oficiálním uvedením nové verze do oběhu. V době psaní těchto skript ale žádná vývojová verze nebyla na stránkách prostředí dostupná.

K instalaci jsou potřeba administrátorská práva k systému. Instalace samotná je ale přímočará, průvodce instalací je v češtině, takže by s instalací neměl nastat žádný problém. Podle stavu a verze operačního systému může být po dokončení vyžadován restart systému.

První projekt

V menu start instalátor přidal odkazy na:

- Demo aplikace PROMOTIC a
- Vývojové prostředí PROMOTIC

Demo aplikace slouží k demonstraci schopností prostředí Promotic. Může Vám tedy sloužit pro inspiraci, co je možné v Promoticu realizovat. Demo aplikace je také plně editovatelná - takže lze zkoumat, jak bylo funkčnosti dosaženo.

Vytváření a editace projektů je možná z *vývojového prostředí Promotic*.

Při spuštění vývojového prostředí se otevře základní menu umožňující:

- vytvořit *novou aplikaci*,
- spustit *demo aplikace* - toto demo je možno spustit také samostatně z menu start operačního systému,
- *otevřít* existující *aplikaci*,
- příklady v aplikaci obsahují sadu příkladů použití vybraných v Promoticu dostupných technologii (databáze, alarmy, reporty, trendy a další).
- *učebnice* - obsahuje podrobně vysvětlený postup realizace projektu kotelny (společně s projektem v této kapitole a menšími projekty realizovanými ve cvičení získáváte základní baterii příkladů, ze které můžete vyjí při návrhu vlastních projektů)
- *dokumentace* - obsahuje podrobnou dokumentaci ke všem komponentám dostupným pro vývoj.

Jelikož nemáme zatím žádný projekt vytvořen - vytvoříme si nový. **Pro nový projekt si vždy vytvořte samostatnou složku**. Každý projekt obsahuje soubor s příponou .pra. Tento soubor ob-

sahuje základní strukturu projektu, ale také obrazy aplikace pro editaci a ve zkompilované podobě a řadu dalších věcí.

Kromě .pra souboru může (ale nemusí) projekt obsahovat další zdroje, jako jsou např. externí obrázky použité ve vizualizaci, konfiguraci, log, dočasné soubory, apod. Některé z nich mohou být vyžadované pro běh námi vytvářené aplikace. Projekt v samostatné složce nám umožní jednoznačně identifikovat, které soubory jsou součástí projektu a případně je přenést, zabalit a odevzdat jako semestrální projekt apod.

My budeme vytvářet jednoduchou vizualizaci fungování systému UPS a proto si soubor také tak pojmenujeme (UPS.pra).

Vývoj samotný se liší podle verze systému. Verze 9.0.x z tohoto pohledu přinesla signifikatní změny. Při výkladu zohledníme tyto změny v samostatných podkapitolách věnovaných verzi 8.3 a 9.0. I když jsou mezi verzemi systému značné rozdíly, existuje zde také spousta společných věcí. Výklad bude proto realizován nejprve na verzi 8.3 a v podklapitole věnované verzi 9.0 budou podrobněji popsány změny a odlišnosti.

3.2 Promotic verze 8.3

Po specifikaci místa a názvu projektu se objeví dialogové okno *Nový objekt* umožňující nastavit základní vzhled budoucí aplikace, viz obr. 3.1.

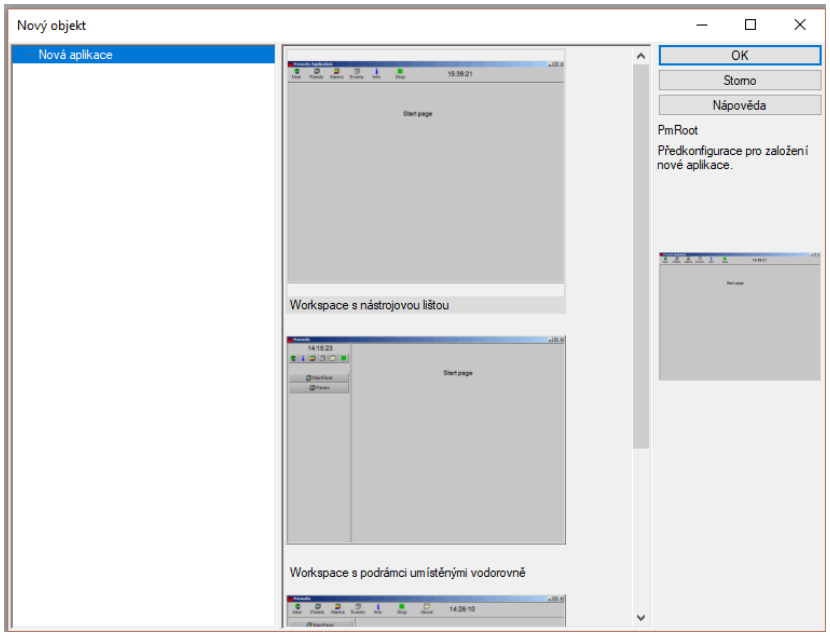

Obrázek 3.1: Základní rozložení aplikace Promotic - Nový objekt

Z hlediska funkčnosti jsou všechna rozložení nabízená v rámci dialogu na obr. 3.1 ekvivalentní - rozdíl je tedy pouze vizuální. Aplikaci vždy tvoří *workspace* (největší část okna aplikace s nápisem *start page*), zde se budou nacházet jednotlivé komponenty vizualizující něco - v našem případě činnost UPS.

Povinná je také *nástrojová lišta* - ta umožňuje základní manipulaci s vytvořenou aplikací, ukončit její běh, otevírat jednotlivé obrazy apod.

Některá rozložení navíc obsahují také tzv. *podrámce*, které mohou sloužit třeba pro zobrazení seznamu předpřipravených obrazů apod.

V našem projektu budeme používat pouze jeden obraz pro vizualizaci, proto podrámce potřebovat nebudeme. Já osobně preferuji první rozhraní s nástrojovou lištou pod titulkem okna aplikace. Je to způsob, který používá většina aplikací a proto jej použiji také.

Kliknutím vyberu a výběr potvrdím kliknutím na tlačítko OK.

V dalším kroku nastavujeme vlastnosti projektu. Některé z nich jsou důležité, jiné jsou důležité méně - všechny je možno v případě potřeby změnit také později přímo uvnitř vývojového prostředí.

Tady ale máme jednotlivé položky hezky pohromadě a můžeme tak provést nastavení jednou - a obvykle ho už pak nebudeme muset měnit. My nastavíme název aplikace na UPS, odklikneme volbu *Aplikace bude nabízena do webu* a změníme nastavení skriptovacího jazyka na *vbscript (zastaralé)*. Ostatní volby ponecháme, tak jak jsou - viz obr. 3.2.

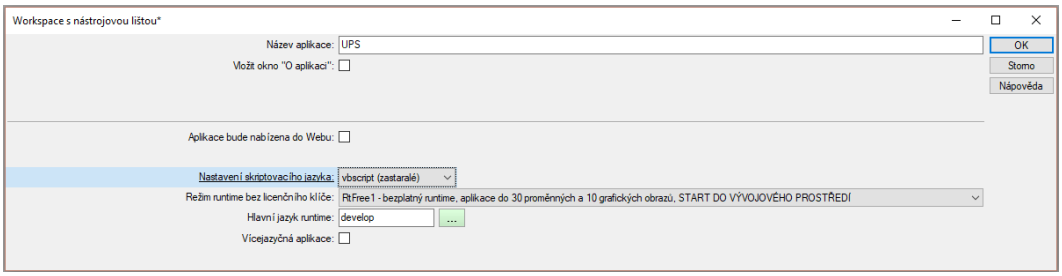

Obrázek 3.2: Promotic - nastavení workspace s nástrojovou lištou

Zastavme se u některých voleb. Promotic umožňuje realizovat interaktivní části pomocí jednoho z podporovaných skriptovacích jazyků. V současnosti je podporován Visual Basic Script a JavaScript. V obou případech se jedná o plnohodnotné programovací jazyky. Promotic tradičně využíval Visual Basic Script. Doplnění podpory JavaScriptu tak přišlo později.

Paradoxně - vývojové prostředí označuje Visual Basic jako zastaralé prostředí, avšak podpora JavaScriptu v současnosti není úplná. Pro naše účely tak ve verzi 8.3 systému JavaScript není možné použít, protože nepodporuje skripty časovače, které budeme potřebovat.

Programování?
Výše v textu se objevila podivná slova - programovací jazyky (dokonce **dva**!). To jakože znamená, že budeme programovat?
Technicky vzato - ano, přesně to to znamená. Prakticky, ale budeme využívat jen velice úzkou podmnožinu funkcionality poskytované Visual Basicem - takže to nebude tak hrozné :-).

Oba podporované programovací jazyky je možno extenzivně využívat také v dalších aplikacích (mimo Promotic). Visual Basic je využíván např. pro psaní maker v balíku MS Office, grafickém balíku CorelDRAW, Adobe Ilustrator (ten podporuje také AppleScript a JavaScript) a řada dalších. JavaScript je pak jazykem zajišťujícím interaktivitu webových stránek a je implementován také v řadě programů pro účely vytváření maker, viz třeba Adobe Illustrator.

Pozor si také dejte na režim runtime bez licenčního klíče. Promotic, který MicroSys poskytuje ke stažení je ve skutečnosti plnou verzí programu. Pokud není přítomen hardwarový klíč nebo nainstalován licenční server, bude Promotic spouštěn v režimu bez licenčního klíče a jeho funkčnost bude podléhat omezením velikostí projektu, který lze v prostředí vytvořit a provozovat.

RtFree1 je předvolen a umožňuje vytvořit projekt s maximálně 30-ti proměnnými a 10-ti grafickými obrazy. Při nastavení RtFree1 se projekt otevře v režimu pro vývoj, otevře se tedy ve vývojovém prostředí. Oproti tomu v režimu *RtFree2* se otevře do běhového prostředí - otevře se obraz a začne být vizualizována technologie.

Logicky je ale nejprve nutno aplikaci vyvinout a pak je možné ji spouštět, proto ponecháme režim RtFree1.

Po kliknutí na tlačítko OK se konečně vytvoří projekt a otevře se samotné vývojové prostředí. Po vytvoření projektu budete automaticky vyzváni k provedení kompilace obrazů - tu proveďte. Tímto způsobem se připraví nástrojová lišta a první prázdný obraz aplikace.

Co je to kompilace obrazů a proč je potřeba dělat si vysvětlíme později při výkladu editoru obrazů.

Vývojové prostředí vypadá podobně jako na obr. 3.3.

Vývojové prostředí má tři základní části:

- panel nástrojů,
- průzkumníka projektu a
- největší část obrazovky pak zabírají vlastnosti právě zvoleného objektu.

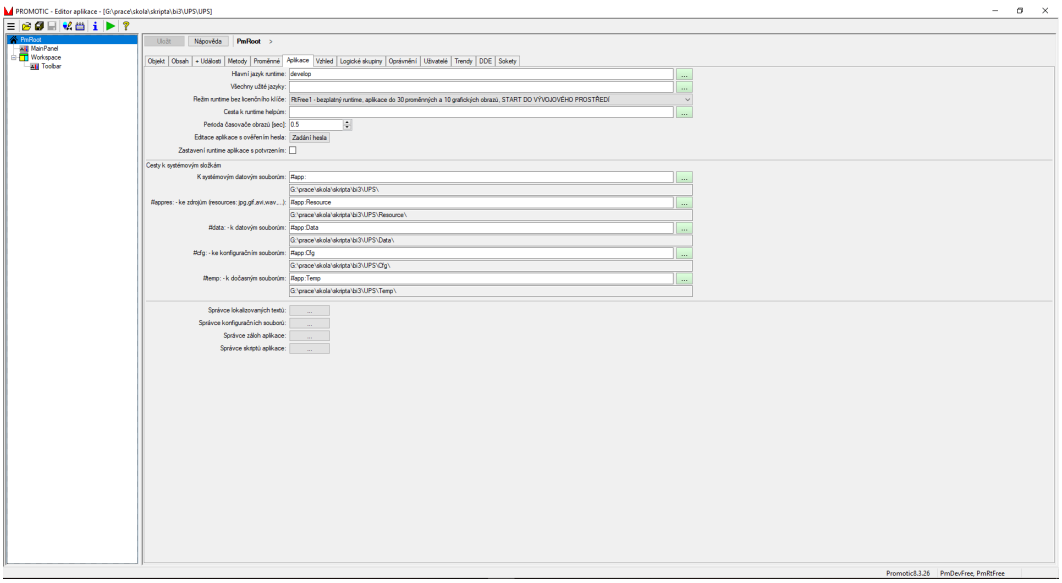

Obrázek 3.3: Promotic - vývojové prostředí

Vlastnosti objektu se mění v závislosti na tom, jaký objekt je vybrán. Na obr. 3.3 je vybrán základní objekt projektu (kořen projektu) - PmRoot. Všimněte si, že vlastností je tolik, že je bylo nutné rozdělit do jednotlivých listů vlastností. Otevřen pro náhled je pak vždy ten, kde Promotic očekává, že se budou provádět změny nejčastěji.

My z prostorových důvodů vysvětlíme pouze základní vlastnosti. Předtím, než začneme se ale ještě podíváme na strukturu projektu jako takovou. V projektu se vytvořil kořen (PmRoot), všechny další objekty projektu jsou pod ním. Projekt dále vytvořil obrazy Main Panel a Toolbat. Main panel je základní obrazovka aplikace, Toolbar pak obsahu panel nástrojů, který se bude přidávat do aplikace. Co kam patří je definováno ve Workspace.

Tyto tři objekty by měly být v každém projektu (byť různé verze Promoticu je organizují trochu odlišně). V žádném případě byste proto tyto objekty neměli z projektu mazat.

PmRoot

Jedná se o kořenovou složku projektu - zde je možno nastavit vlastnosti projektu jako celku. Nejdůležitější nastavení se nacházejí na záložce *Aplikace*. Zde je možno třeba provést změnu nastavení režimu runtime. Z dalších důležitých vlastností je *perioda časovače obrazů*. Jedná se o hodnotu v sekundách určující jak často se překreslí obraz na obrazovce. Předvolená hodnota 0.5 znamená, že obraz se překreslí 2x za sekundu.

Perioda časovače by měla být nastavena menší než je interval aktualizace dat ze senzorů, které mají být vizualizovány. Hodnota 0.5 obvykle pro běžnou práci dostačuje a není potřeba ji měnit.

Pozornost věnujte také sekci *cesty k systémovým složkám*. Tato skupina nastavení umožňuje specifikovat kam, se má Promotic dívat při hledání určitých dat, nebo zdrojů. Samostatně je možno nastavit:

- zdroje (Resource)
- datové soubory (Data)
- konfigurační soubory (Cfg) a
- dočasné soubory (Temp)

Výše uvedené složky se implicitně vytvářejí v hlavní složce projektu - proto také bylo tak důležité, abychom pro projekt vytvořili samostatnou složku. V případě práce s více projekty z jedné složky by totiž mohlo dojít ke smíchání dat z těchto systémových složek, což obvykle není žádoucí.

Této informace můžeme také využít v případě, že potřebujeme např. přidat do projektu nějaký obrázek, který není dostupný ve standardní knihovně obrázků poskytovaných Promoticem. Obrázek získáme např. z Internetu a uložíme jej do složky Resources našeho projektu.

PmPanel

Objekt typu *PmPanel*, česky uživatelská grafika umožňuje do projektu přidávat obrazy. Každý obraz

by měl mít specifikovaný titul, aby jej v případě potřeby bylo možné při běhu aplikace najít. To je zejména důležité, pokud aplikace obsahuje větší množství obrazů.

Pro obraz je možno nastavit také skriptovací engine - implicitní nastavení odpovídá jazyku zvolenému při vytváření projektu (viz obr. 3.2).

Hlavní část editace uživatelské grafiky je prováděna v samostatné vývojové aplikaci - *editoru obrazů*, který lze spustit kliknutím na tlačítko Editace grafického obsahu.

Problematice editace grafického obsahu se budeme věnovat podrobněji v samostatné podkapitole.

PmWorkspace

Pracovní plocha umožňuje zvolit základní rozložení aplikace. Nejdůležitější vlastnosti se nachází na záložkách Hlavní a Rámce.

V hlavní záložce je možno nastavit, zda tato pracovní ploch představuje hlavní okno aplikace, jaký má mít název a v jakém stavu se má nacházet při spuštění (implicitně v maximalizovaném).

Z hlediska funkce výsledné aplikace je ale důležitější záložka Rámce. V ní máme možnost zvolit jak budou jednotlivé obrazy vizuálně poskládány na obrazovce.

Kořen pracovní plochy tvoří MainFrame. V rámci něj je možno nastavit rozložení. Předvoleno je rozložení, které jsme zvolili na obr. 3.1 při vytváření projektu.

Pod MainFrame jsou pak pod zvoleného rozložení dva nebo tři další objekty, kam už lze mapovat určitou uživatelskou grafiku. Pro vertikální rozložení je nutno namapovat (viz obr. 3.4) pouze dva objekty a to toolbar (panel nástrojů, viz obr. 3.5) a main (viz obr. 3.6), což je hlavní obrazovka aplikace.

Hlavní obrazovka se automaticky načte při startu aplikace do běhového režimu. Případné další obrazy si bude muset uživatel buďto manuálně vyžádat nebo jejich zobrazení bude muset být vyvolané nějakým skriptem, který k tomuto účelu připravíme.

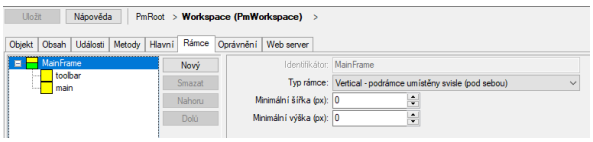

Obrázek 3.4: PmWorkspace - vlastnosti MainFrame

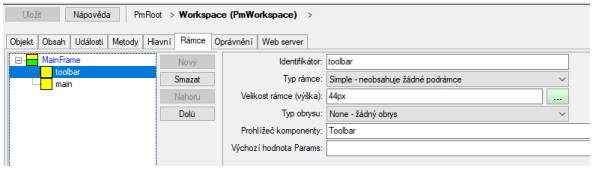

Obrázek 3.5: PmWorkspace - vlastnosti toolbar

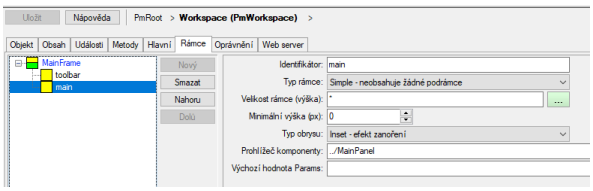

Obrázek 3.6: PmWorkspace - vlastnosti Main

Mapování uživatelské grafiky se provádí ve vlastnosti prohlížeč komponenty. Velikost rámce se určuje nastavením vlastnosti velikost. Všimněte si, že v našem projektu je na obr. 3.5 nastavena výška na 44px, ale u hlavního panelu na obr. 3.6 je výška specifikována pomocí znaku: *. Hvězdička je zástupným znakem, který v tomto kontextu znamená, že výška bude nastavena na zbytek výšky celé pracovní plochy.

Pokud u rámce nastavíme vlastnost typ rámce ze simple na horizontal nebo vertical. Je možné do něj pak vkládat další rámce a tak podle potřeby rozdělit pracovní plochu do takového množství segmentů, které potřebujeme pro řešení našeho problému.

Toto byly objekty, které máme v projektu nyní, jaké ale další objekty lze do projektu přidat a jak se takové přidávání vůbec realizuje?

Nový objekt do projektu můžeme přidat buďto z kontextového menu složky v průzkumníku projektu (v našem případě klikneme na objekt PmRoot, protože to je jediný objekt typu složka) a v kontextovém menu klineme na položku *Nový objekt ....* Vzhledem k tomu, že objektů budeme přidávat více, může být výhodné použití klávesové zkratky Ins (klávesa insert).

Objeví se paleta dostupných objektů, viz obr. 3.7.

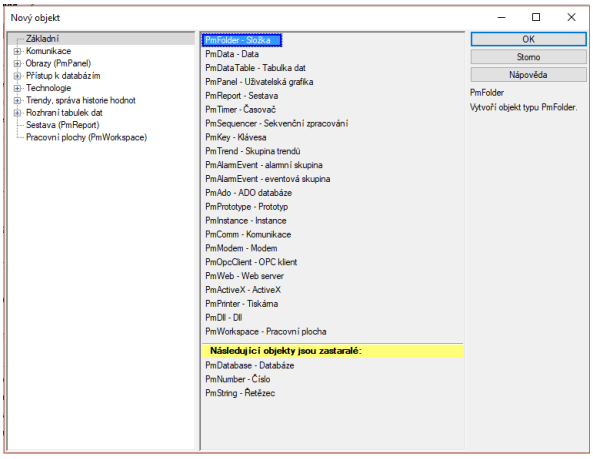

Obrázek 3.7: Promotic - nový objekt

Ve skriptech si představíme pouze malou podmnožinu těchto nástrojů - neprobereme ani všechny základní nástroje. Objekty typu PmWorkspace a PmPanel jsme už probrali (viz výše), jaké další objekty nám tedy nabízí Promotic?

PmFolder - složka

Složka slouží pro organizaci dalších objektů v projektu. Hodí se zejména v případě, že pracujeme s rozsáhlými projekty obsahující desítky nebo stovky objektů různého typu. Dobrou volbou může být použití systému složek pro rozčlenění projektu - buďto tématického nebo podle typu objektu.

Tématickým členěním projektu rozumíme postup v rámci kterého do složek vkládáme objekty různého typu týkající se určité části řešené technologie/problému.

Členění podle typu pak používá strukturu složek pro rozdělení objektů podle jejich typu.

Naše projekty budou poměrně malé, takže se bez použití složek obejdeme.

PmData, PmString, PmNumber

Tento objekt slouží pro management proměnných, se kterými bude Promotic pracovat. Proměnné obvykle odpovídají buďto měřeným veličinám nebo slouží pro interní potřeby aplikace.

Proměnné je možné vytvářet také jako samostatné objekty, konkrétně typu PmNumber pro čísla nebo PmString pro řetězce. Od verze 8.1 Promotic jsou ale tyto objekty označovány jako zastaralé a preferováno je použití objektu PmData.

U zastaralých objektů lze očekávat, že v budoucích verzích bude odstraněna jejich podpora. V současnosti ale není zcela jasné jak dlouho budou tyto typy objektů ještě podporovány.

Na obr. 3.8 jsou zobrazeny vlastnosti objektu PmNumber, na obr. 3.9 jsou pak zobrazeny vlastnosti objektu PmString.

Jak je z obrázků 3.8 a 3.9 patrné oba objekty využívají podobných vlastností. Každý objekt má vlastní jméno, které by mělo být v rámci dané složky unikátní (toto se týká všech typů objektů). Pro proměnné lze nastavit výchozí hodnotu, popis a specifikovat zda se jedná o proměnnou nebo konstantu.

Počáteční hodnota je poměrně důležitá - jedná se o hodnotu, na kterou se daná proměnná nastaví při spuštění aplikace. Tato hodnota pak následně může být měněna z technologie (načítána z externího datového zdroje) nebo může být měněna uvnitř samotné aplikace, např. nějakým skriptem.

Často pokud se aplikace chová odlišně než čekáte je problém právě v počátečním nastavení - tento problém je ale zároveň velmi jednoduchý na opravu, takže rozhodně nemůže škodit se na tuto vlastnost při hledání chyb podívat.

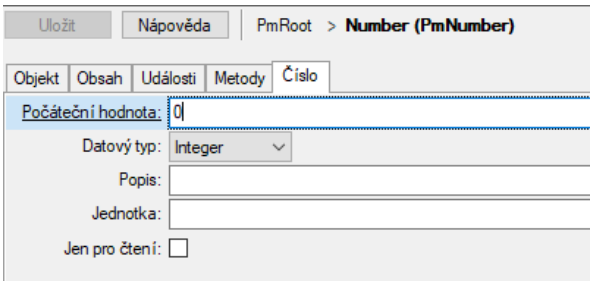

Obrázek 3.8: Promotic - PmNumber - objekt typu číslo

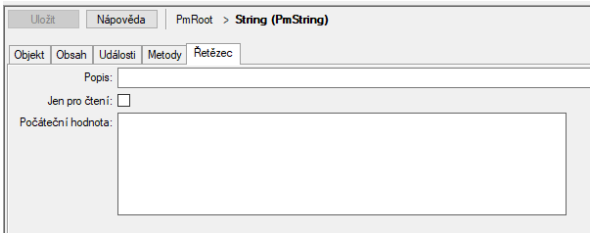

Obrázek 3.9: Promotic - PmString - objekt typu textový řetězec

Popis slouží pro vnitřní dokumentaci proměnné. Hodnota, kterou do této vlastnosti zadáte tedy bude sloužit Vám k lepší orientaci v tvořené aplikaci. Do popisu se obvykle vkládá účel proměnné, popř. další informace, které by později mohly být při manipulaci s aplikací užitečné.

Popis není povinný, pokud jej tedy u proměnné neuvedete, nebude to mít vliv na funkci Vámi vytvářené aplikace.

Proměnnou lze nastavit jako konstantu zaškrtnutím volby *jen pro čtení*. Po zaškrtnutí hodnota, která byla nastavena jako počáteční, již nemůže být změněna.

U čísel (PmNumber) je možno nastavit o jaký typ čísla se jedná:

- boolean (0/1)
- byte (0 - 255)
- integer - celočíselný datový typ (16-ti bitové, -32768 - 32768)
- long - celočíselný datový typ (32 bitový, -2 147 483 648 - 2 147 483 648)
- single - desetinné číslo, jednoduchá přesnost (32 bitové $-3.4 \cdot 10^{38} - 3.4 \cdot 10^{38}$)
- double - desetinné číslo, dvojitá přesnost (64 bitové, $-1,79 \cdot 10^{308} - 1.79 \cdot 10^{308}$)

U čísel je možno nastavit také jednotku. Podobně jako popis také jednotka není povinná. Tato vlastnost slouží pro předcházení problémům s interpretací jednotlivých veličin. Pokud u číselné proměnné tlak jednotku neuvedeme, můžeme předpokládat, že je vedena v Pascalech (Pa), ale co když zbytek aplikace předpokládá, že je vedena v kPa nebo dokonce v MPa?

Vyplnění jednotky samo o sobě tento problém zcela neodstraní, umožní ale aby v průběhu vytváření aplikace jste klikli na proměnnou a měli ten AHA moment ... veličina je v té a té jednotce (a nemusíte o tom přemýšlet).

Rozhraní objektu PmData vypadá odlišně, viz obr. 3.10.

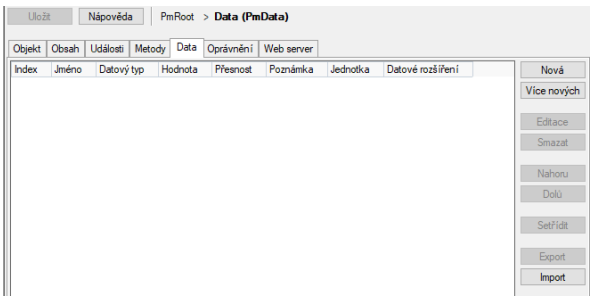

Obrázek 3.10: Promotic - PmData - sdružující proměnné různého typu

Nové proměnné do objektu PmData zadáváme kliknutím na tlačítko *Nová*. Rozhraní definice proměnné je univerzální. Kromě datových typů podporovaných v proměnných PmNumber a PmStrin podporuje tento objekt také datové typy Date (datum a čas), Object (objektový datový typ) a Variant (neurčený datový typ, datový typ se určuje až ze zadané hodnoty a způsobu použití proměnné).

Vzhledem k tomu, že k proměnným budeme potřebovat přistupovat, je velmi důležité specifikovat cestu k proměnné. Cestu naleznete ve vlastnostech daného objektu vedle tlačítek uložit a nápověda. Na obr. 3.10 je cesta PmRoot/Data (objekt PmData jsem pojmenoval Data).

V případě, že bych v objektu Data nadefinoval proměnnou napeti, byla by celá cesta k ní PmRoot/Data/napeti.

V případě, že proměnné jsou uvnitř složky (nebo složek) je název složky také součástí cesty.

Chybné mapování proměnných je další častou chybou, na kterou je potřeba si dát pozor.

PmTimer - časovač

Časovač slouží pro spouštění určitých operací (definovaných skriptem) ve specifikovaném časovém intervalu. V praxi se časovače používají pro pravidelnou aktualizaci stavů aplikace na základě hodnot připojených proměnných. K tomuto účelu časovač budeme využívat také.

Pro naše použití ale časovač bude plnit ještě jednu úlohu. Za normálních okolností jsou hodnoty proměnných odečítány z externího zdroje - technologie. My ale žádnou technologii připojenou nemáme - takže potřebujeme něco, co nám technologii bude simulovat. Tuto simulaci lze realizovat také pomocí časovače.

Formálně se činnosti, které časovač má vykonávat specifikují pomocí zvoleného programovacího jazyka, v současnosti pouze v jazyku Visual Basic Script (podpora JavaScript pravděpodobně bude doplněna v budoucích verzích Promotic).

Problematice oživení časovače budeme věnovat samostatnou podkapitolu.

3.2.1 UPS - specifikace podkladů pro tvorbu aplikace

UPS je zkratka pro Uninteruptible Power Source, tedy nepřerušitelný zdroj napájení. Tato zařízení obvykle obsahují baterii a logické obvody zajišťující vyhodnocování „kvality“ dodávek elektřiny v síti. V případě detekce problémů (nestability napětí, výpadku nebo naopak přepětí v síti) by přívod energie ze sítě měl být automaticky odpojen a elektřina by jednotlivým zařízením měla být dodávána z baterie.

Naším úkolem bude vytvořit aplikaci, která bude funkci UPS vizualizovat.

První otázku, kterou musíme vyřešit jsou **proměnné**, tedy - jaké proměnné budeme potřebovat pro vyřešení problému:

- *napětí* - aktuální napětí v elektrické síti [V]
- *baterie* - stav baterie [%]
- *dolní mez napětí* a *horní mez napětí* - limity toho, co budeme považovat za normální [V]

Kromě výše uvedených proměnných bychom zcela jistě mohli vymyslet celou řadu dalších proměnných, jejichž použití by nám třeba umožnilo signalizovat některé stavy - třeba že baterie je takřka vybitá, že baterie se právě nabíjí, že UPS právě dodává elektřinu z baterie apod.

Volba proměnných vždy závisí na tom, co má výsledná aplikace přesně dělat. Z předpokládaného účelu je pak možno odvodit datové typy, počáteční hodnoty a také chování jako podklad pro návrh funkce časovače.

V našem případě všechny čtyři výše uvedené proměnné budou čísla. O typu čísla ale rozhodne způsob, jakým navrhneme logiku simulátoru UPS - konkrétně s jakými kroky bude časovač pracovat. Pokud tyto kroky (změny za předem stanovený časový interval) budou celočíselné, pak mohou být také proměnné celočíselného datového typu.

Vzhledem k tomu, že pracujeme s napětím ve voltech a standardní napětí v elektrické síti je okolo 230 V a stav baterie bude v procentech, pak nám bude dostačovat typ Integer (nebude potřeba typ long).

Simulace

Pro účely simulace můžeme chtít, aby hodnota napětí v elektrické síti (s počátečním napětím 230 V) náhodně kolísala v každém časovém kroku o třeba 5 V.

Dolní a horní mez přípustného napětí jsou položky které můžeme nastavit třeba na 200 a 260 V, ale můžeme také chtít, aby případně tuto hodnotu mohl uživatel změnit sám v grafickém uživatelském rozhraní aplikace.

Dále předpokládejme, že v každém časovém kroku se bude baterie nabíjet nebo vyvíjet podle toho, zda hodnota aktuálního napětí v síti je v mezích přípustného napětí nebo ne. Řekněme, že změna bude ± 1 za časový krok.

Logickými omezeními by pak mělo být, že baterie se nemůže nabít více než na $> 100\%$ a vybít pod 0%. Podobně hodnota napětí v síti by nikdy neměla být menší než < 0.

Výše uvedená omezení nám determinují to, jak by se měl chovat časovač. My už ale každopádně máme dostatek informací k tomu, abychom mohli v Promotic začít prakticky realizovat náš projekt UPS.

První kroky návrhu aplikace

Podobný postup, jaký je uveden výše budete muset absolvovat pokaždé, kdy budete chtít něco implementovat a to nejen v systému Promotic.

Není dobrou strategií otevřít Promotic a začít v něm okamžitě něco tvořit. Šance, že výsledek Vaší práce bude za něco stát je v takovém případě minimální. Správný postup je, že si pořádně rozmyslíte celý projekt. Potřebujete zejména zodpovědět otázky:

1. Jaké hodnoty/proměnné potřebuji zpracovávat?
2. Jak proces nebo technologie ve skutečnosti funguje?
3. Jakou interakci od uživatele aplikace očekávám?

V první fázi si dělejte poznámky a náčrtky na papír. Zejména v začátcích Vás bude omezovat méně než samotný Promotic. Zodpovězení/rozmyšlení výše uvedených otázek Vám následně umožní, abyste se následně v implementační fázi soustředili pouze na to jak to implementovat (místo co, jak a proč implementovat).

Realizace Projektu

Základní rozhraní aplikace včetně hlavní obrazovky Promotic už máme vytvořeno. Potřebujeme vytvořit jeden objekt typu PmData a jeden PmTimer.

Objekt PmData pojmenujeme Data a uvnitř vytvoříme čtyři proměnné:

1. napeti - počáteční hodnota 230
2. baterie - počáteční hodnota 50
3. dmn (dolní mez napětí) - počáteční hodnota 200
4. hmn (horní mez napětí) - počáteční hodnota 260

PmTimer nazveme timer. Na záložce časovač by měl být časovat povolen po startu, s periodou 1 s. Výsledek by měl vypadat podobně jako obr. 3.11.

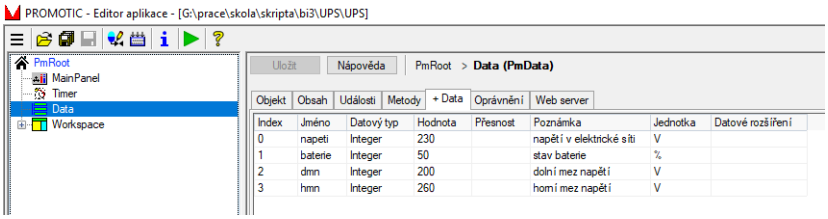

Obrázek 3.11: Promotic - objekty projektu UPS

... to nebylo tak hrozné, nebo ano?

3.2.2 Příprava obrazovek aplikace

Pro přípravu obrazovky potřebujeme spustit editor grafického obsahu. To je možné provést z objektu MainPanel kliknutím na tlačítko *Editace grafického obsahu*. Po kliknutí na toto tlačítko se editor spustí v novém okně. Editor obrazů a editor aplikace jsou nezávislé - můžete se tedy bez obav mezi oběma okny přepínat a podle potřeby je editovat (není potřeba a není ani žádoucí jedno okno zavřít).

Text *Start page* kliknutím označíme a stisknutím klávesy delete jej pak můžete vymazat.

Na obrazovce bude potřeba vytvořit nové objekty - to lze provést z kontextového menu plochy kliknutím na položku *Nový prvek* nebo stisknutím klávesy *N*.

Nové prvky se přidávají z *palety prvků*, viz obr. 3.12.

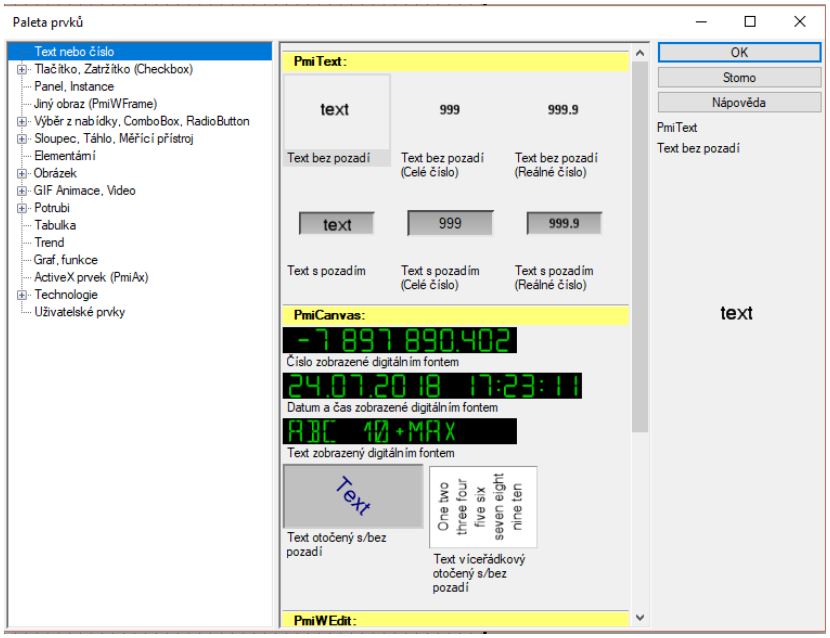

Obrázek 3.12: Editor grafického obsahu - paleta prvků

Jednotlivé prvky jsou seskupeny podle typů. Jelikož je dostupných prvků k dispozici opravdu velké množství nebudeme podrobně diskutovat všechny - zaměříme se pouze na ty, které bychom mohli chtít použít nejčastěji.

- text nebo číslo - dané prvky umožňují zobrazovat informaci v textové podobě
- tlačítka a zatržítka jsou v praxi často používaná, k jejich zprovoznení je ale potřeba programování, proto je v tomto textu používat nebudeme
- sloupec, táhlo, měřící přístroj - nabízené prvky umožňují vizualizovat v grafické podobě číselnou veličinu a případně (pomocí táhla) měnit její hodnotu.
- obrázek - obrázky ve vektorovém formátu (PmiCanvas) nebo ve formě bitmapy (PmiRastr), v obrázky - uživatelsky definované je přístupná grafika uložená ve složce Resources projektu
- GIF, animace, video - podobně jako obrázky, ale s animacemi
- potrubí
- graf, funkce - umožňuje vizualizovat vývoj sledované veličiny v čase

Pro zpracování vizualizace činnosti UPS vytvoříme dva měřící přístroje pro baterii a napětí v elektrické síti a dvě táhla pro dolní a horní mez napětí.

Měřící přístroje je možno nalézt v panelu nástrojů v sekci Sloupec, táhlo, měřící přístroj → Měřící přístroj. Použijeme kruhový měřící přístroj (hned ten první) pro napětí v síti a pro baterii pak měřící přístroj (viz obr. 3.16).

PmiCanvas je vektorový, proto je možné jej libovolně škálovat beze změny v kvalitě zobrazení. Zároveň ale manipulace s tímto typem je náročnější - tedy pokud chcete nastavit nebo změnit funkci prvku, která není nabízena v průvodci vytvoření prvku.

Zkusmě nadefinovat první přístroj pro měření napětí v síti. Dvojklikem vybereme měřící přístroj (alternativně kliknutím vybrat a kliknout na tlačítko OK). Spustí okno s nastaveními Kruhový měřící přístroj (viz obr. Y). Nastavení:

- měřená jednotka: V
- měřená hodnota: 230 - pozor, tady budeme připojovat proměnnou „napeti“
- rozsah od minima: 0
- rozsah do maxima: 300
- zobrazit technologické meze: zaškrtnuto

- technologické minimum: 200 - pozor, tady budeme připojovat také proměnnou „dmn“
- technologické maximum: 260 - pozor tady budeme připojovat také proměnnou „hmn“
- hlavní dílky stupnice: 15
- vedlejší dílky stupnice: 3

Připojení proměnných provedeme tak, že klikneme na oranžové tlačítko vedle dané hodnoty. Následně vybereme PP lvastnost PmObjektu a v pravé části obrazovky v položce Objekt klikneme na tlačítko ... Teď už stačí vybrat pouze PmRoot → Data → #vars → napeti (viz obr. 3.13) a volbu potvrdit OK, potom znovu OK až bude viditelné pouze okno vlastností Kruhového měřícího přístroje.

Analogicky připojíme také proměnné technologického minima a maxima. Které proměnné budeme připojovat do kterých vlastností je patrné v odrážkách výše. Vyplněné vlastnosti by měly vypadat podobně jako na obr. 3.14 (podle toho, jak jste přesně pojmenovali proměnné a kam jste je umístili).

Pokud jste s vyplněním spokojeni - klikněte na OK. Prostor pro vytvoření prvku označíte na pracovní ploše kliknutím a tažením. Velikost prvku a jeho umístění je možno kdykoliv změnit. (Manipulace s prvky je stejná jako u kteréhokoliv grafického editoru).

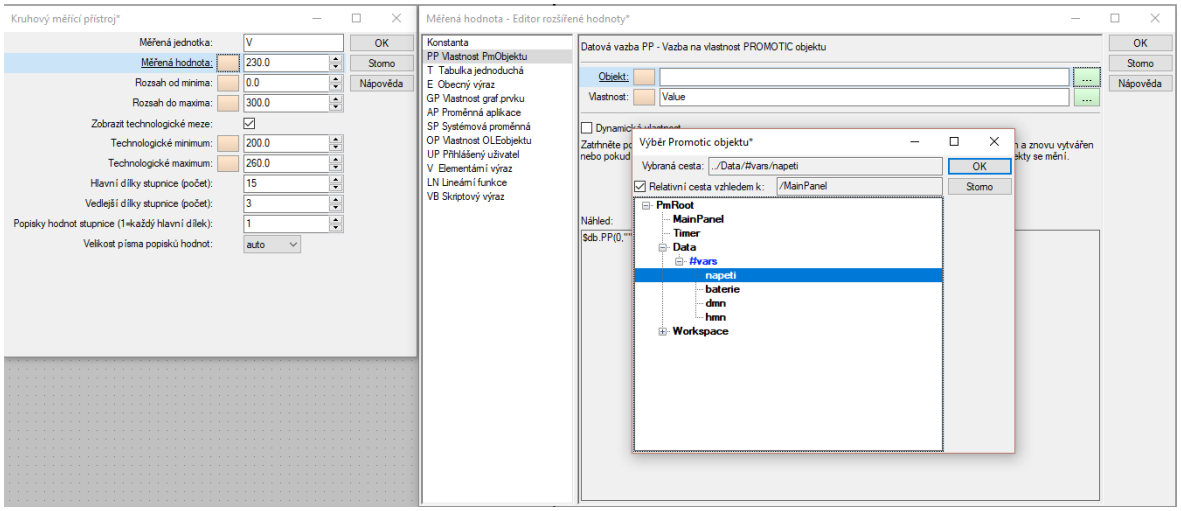

Obrázek 3.13: Kruhový měřící přístroj - připojení proměnné

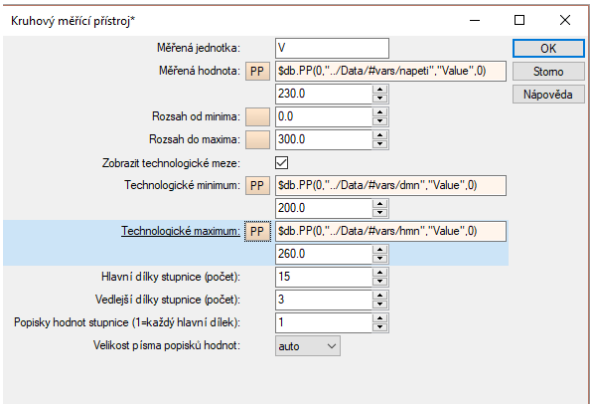

Obrázek 3.14: Kruhový měřící přístroj - nastavení vlastností

Dvojitým kliknutím na vytvořeném objektu se dostaneme do jeho vlastností. Nejdůležitější jsou záložky Proměnné, obsahující přípojené proměnné a Obsah - v obsahu je možné přenastavit vlastnosti z obr. 3.14. Obsah je ale v tomto případě dostupný pouze ve formátu XML a proto najít kde přesně se daná vlastnost nachází je poněkud náročnější.

Z hlediska rychlosti návrhu vizualizace je proto žádoucí, aby objekty byly vytvořeny správně na první pokus.

Z hlediska vizualizace napětí v síti by také bylo výhodné vidět aktuální hodnotu proměnné „napeti“ i v textovém formátu a hodil by se také popisek specifikující jaká veličina je vlastně měřena. Obojí lze jednoduše realizovat pomocí prvku *Text nebo číslo*, pro obojí zvolím text bez pozadí.

Text má pouze omezené množství vlastností, které má smysl vyplňovat. Vlastnost text v případě popisku nastavíme na nápis „Napětí v elektrické síti“ a umístíme jej nad vytvořený měřící přistroj. Případně lze změnit vlastnost Písmo a vybrat nějaké výraznější.

Pro vizualizaci hodnoty bude potřeba realizovat připojení na proměnnou „napeti“ a to konkrétně ve vlastnosti Text. Postupovat budeme stejným způsobem jako v případě nastavení měřícího přístroje. Původní vyplnění vlastnosti text můžeme ponechat, alespoň se nám bude s prvkem lépe manipulovat.

Prvek umístíme na měřící přístroj, podobně jako na obr. 3.15 (nad V).

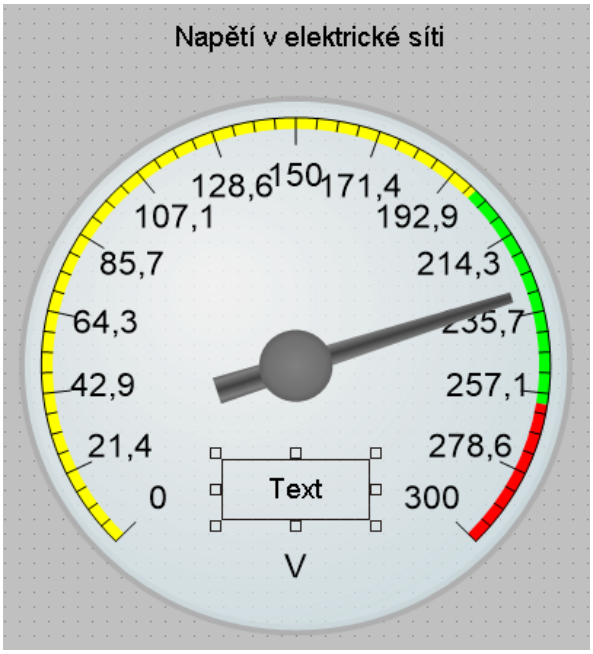

Obrázek 3.15: Kruhový měřící přístroj - doplnění textových popisků

Z hlediska umisťování objektů platí, že novější objekty jsou více ve předu - což je v tomto případě využito.

Vytvoření měřidla pro baterii je již jednodušší. Nastavit je zde potřeba pouze měřenou hodnotu - připojíme k ní proměnnou „baterie“. Z hlediska estetičnosti můžeme ještě přerozdělit hlavní a vedlejší dílky stupnice. Já jsem pro výsledek na obr. 3.16 zvolil 5 hlavních dílků a 2 vedlejší dílky stupnice.

Nad měřidlo umístíme popisek - Baterie [%].

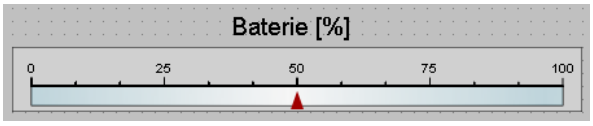

Obrázek 3.16: Vizualizace baterie

V obraze už zbývá pouze vytvoření dvou táhel pro realizaci dolní a horní meze napětí. Táhla jsou dostupná Sloupe., táhlo, měřící přístroj → Táhlo. Pro náš účel se hodí třeba táhlo se stupnicí, vodorovné.

Ani tady není potřeba nastavovat příliš velké množství vlastností. Nadpis nastavíme na Dolní mez napětí [V], do hodnoty připojíme proměnnou „dmn“, dolní mez dáme třeba 170 a horní 230.

Analogicky pak vytvoříme i táhlo pro horní mez napětí. Správně nastavení a propojení byste již měli být schopni realizovat sami. Celá vizualizace by měla vypadat podobně jako na obr. 3.17.

Aby byl obraz funkční, je potřeba provést tzv. kompilaci obrazu. Kompilaci je možno provést z menu Projekt → Překlad ..., nebo klávesovou zkratkou CTRL + P a nebo pomocí tlačítka na panelu nástrojů (hned vedle ikony diskety).

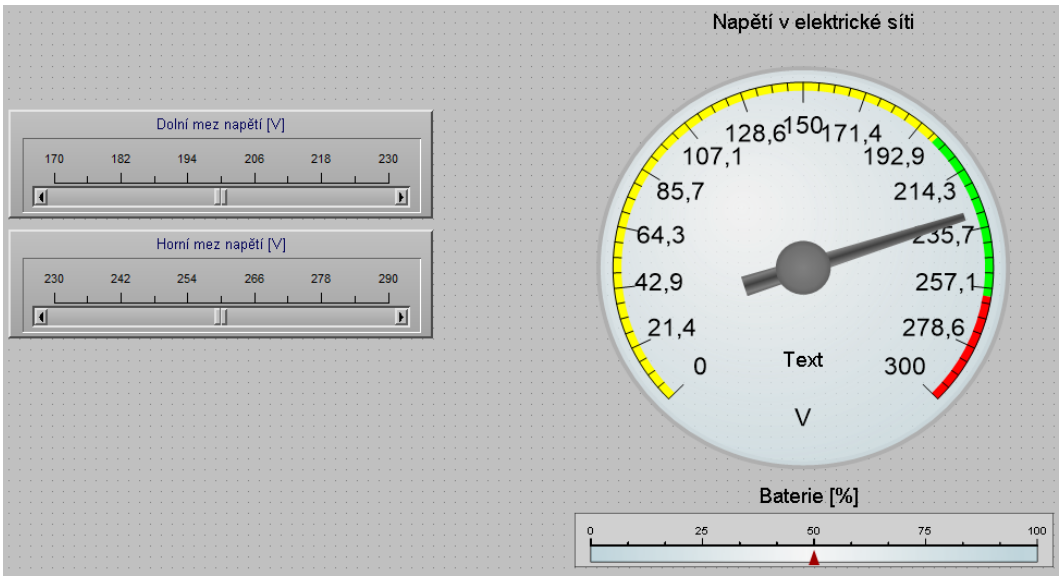

Obrázek 3.17: UPS - vizualizace, celek

Kompilovat je možné buďto pouze nekompilované nebo změněné obrazovky, nebo všechny obrazovky. V našem případě pracujeme pouze s jednou obrazovkou, takže časový rozdíl obou operací bude zanedbatelný. U větších projektů tomu tak ale být nemusí.

V běhovém prostředí budou dostupné pouze kompilované obrazy. Běhové prostředí přitom spouští poslední kompilovanou verzi obrazu, takže pokud to co vidíte v editoru obrazů a v běhovém prostředí je odlišné, je potřeba provést opětovnou kompilaci obrazu.

Po spuštění překladu se Vám na obrazovce objeví výsledné hlášení, v našem případě by překlad obrazu měl proběhnout v pořádku. V případě ale, že bychom někde udělali chybu, mohl by překlad selhat. Chybové hlášení by Vám pak mělo říci, kde přesně se chyba nachází.

Podle mých zkušeností s projekty se nejčastěji chybuje v propojování proměnných. Může se např. stát, že v základním rozhraní Promotic změníte názvy proměnných, ale změnu už třeba neprovedete v editoru obrazů - tím se naruší propojení mezi navrhovanou obrazovkou a systémem Promotic.

Nyní již můžeme editor obrazů zavřít. Aplikaci je možno spustit z hlavín aplikace Promotic kliknutím na tlačítko zeleného trojúhelníku v panelu nástrojů (tlačítko spustit aplikaci). Naše aplikace je plně funkční ... ale nic nedělá, protože ji chybí logika fungování technologie. Jednotlivé proměnné tak zůstávají statické.

Tento problém vyřešíme v následující podkapitole vytvořením jednoduchého skriptu v časovači.

3.2.3 Časovač - programování

Logiku fungování již máme vymyšlenou, viz předchozí podkapitoly.

Skript vytváříme na záložce Události časovače, konkrétně pak v události onTick, tedy česky po tiknutí časovače. Časovač pracuje tak, že spustí v určeném intervalu (na záložce časovač, vlastnost perioda) skript v události onTick.

Proměnné které se zde ale použijí nejsou tzv. perzistentní - to znamená, že jejich hodnoty mezi jednotlivými spuštěními nebudou zachované.

Z tohoto důvodu musíme provést mapování proměnných Visual Basic na Proměnné systému Promotic. Celý skript je přiložen níže:

Výpis 3.1: Oživení časovače Promotic (příklad) ve Visual Basic

```
1 dim napeti, baterie, dmn, hmn
2 dim n, zmena
3
4 set napeti = Pm("/Data/#vars/napeti")
5 set baterie = Pm("/Data/#vars/baterie")
```

```
6  set dmn = Pm("/Data/#vars/dmn")
7  set hmn = Pm("/Data/#vars/hmn")
8
9  'nahodne kolisani proudu v siti
10 n = rnd()
11 if n < 0.5 then zmena = -1 else zmena = 1
12
13 if napeti.Value + zmena < 0 then
14   napeti.Value = 0 'proud nesmi poklesnout pod 0
15 else
16   napeti.Value = napeti.Value + zmena
17 end if
18
19 if napeti.Value < dmn.Value or napeti.Value > hmn.Value then
20   'baterie pouze v intervalu 0; 100
21   if baterie.Value > 0 then baterie.Value = baterie.Value - 1
22 else
23   if baterie.Value < 100 then baterie.Value = baterie.Value + 1
24 end if
```

Zkusme projít zdrojový kód řádek po řádku. Na začátku jsou nejprve deklarované proměnné pomocí příkazu **dim**. Za příkazem dim vždy následuje jeden nebo více proměnných. V případě použití více proměnných, používáme oddělovat čárku.

Visual Basic přitom nebere v úvahu velikost písmen, proto zápisy dim proměnná nebo DIM PROMĚNNÁ nebo DiM ProMěNNá (jakákoliv jiná kombinace velikosti písmen) jsou funkčně ekvivalentní.

Proměnné jsou deklarovány na dvou samostatných řádcích spíše z důvodu snadnější čitelnosti kódu než čehokoliv jiného. V prvním řádku jsou deklarovány proměnné, do kterých budou mapovány proměnné Promotic, v řádku druhém jsou deklarovány pracovní proměnné, které vyžaduje ke své práci skript.

Mapování proměnných se děje pomocí příkazu **set**. Pomocí tohoto příkazu přiřadíme do proměnné odkaz na objekt, popřípadě vlastnost objektu. Řádek: set napeti = Pm("/Data/#vars/napeti") tak do proměnné napeti přiřadí proměnnou Promoticu nazvanou napeti z objektu Data.

Prosím při psaní vlastního kódu věnujte pozornost obsahu funkce **Pm** - pokud uděláte chybu v cestě k proměnné, nebude se jednat o syntaktickou chybu a samotné vývojové prostředí ji proto neodhalí (bude se tvářit, že je vše v pořádku). Po spuštění ale nebude aplikace pracovat správně.

Průvodním znakem této chyby je, že změny hodnot veličin měněných kódem se nezobrazují ve vizualizaci po spuštění.

Komentáře jsou označovány znakem apostrofu („'“). Vše, co následuje za znakem apostrofu je považováno za komentář a nebude vykonáno.

Funkce **rnd** vygeneruje náhodné desetinné číslo v intervalu 0 a 1. Ve skriptu je tato funkce použita pro simulaci náhodného kolísání proudu v elektrické síti. Jako hraniční je použita hodnota 0,5. Vyhodnocení je pak realizováno podmínkou.

Podmínku lze ve Visual Basicu realizovat příkazem **if**. Podmínky mohou být buďto jednořádkové nebo víceřádkové. Příkladem jednořádkové podmínky může být řádek 11. Formát podmínky je potom následující: Pokud podmínka pak příkaz ... vše na jednom řádku.

V některých příkladech, ale takový zjednodušený zápis není dostatečný. V takovém případě přichází na řadu víceřádková podmínka:

Výpis 3.2: VB: podmínky if .. then ... elseif .. else .. end if

```
1 if podminka then
2   ... prikazy ...
3 elseif jina_podminka then
4   'dodatecne podminky lze pomoci elseif pridavat
5   ... prikazy ...
6 else
7   ... prikazy ...
8 end if
```

Víceřádková podmínka je vždy zakončena end if.

Ve výpisech výše si všimněte také odlišného formátu použití proměnných - např. rozdílů v použití proměnné n a napeti. Zatímco proměnná n je používána tak, jak je, proměnná napeti je vždy používána v objektové notaci napeti.Value. To je dáno tím, že proměnnou napeti jsme nastavovali pomocí příkazu set a ve skutečnosti se proto jedná o objekt a objekty mají velké množství vlastností. Nás v tomto případě zajímá hodnota proměnné, proto voláme vlastnost objektu Value (hodnota).

K jednotlivým vlastnostem objektu je možno přistoupit pomocí tečky bezprostředně za objektovou proměnnou.

Náš kód je hotov. Před spuštěním celé aplikace je vhodné spustit test z kontextového menu. Test je schopen odhalit syntaktické chyby ve skriptu a označit místa, kde byly tyto chyby detekovány. Pokud byly zjištěny syntaktické chyby máte jistotu, že Váš skript nebude fungovat správně a proto je potřeba tyto chyby okamžitě opravit.

Pokud chyby detekovány nebyly bohužel nemáte jistotu, že Váš skript bude fungovat správně, protože může obsahovat také logické chyby, které automatizovaně detekovány nejsou.

Vhodným postupem pro začátečníka je zpracovávat kód po relativně malých částech, provádět pravidelně testování a spouště aplikaci tak, aby bylo možno vizuálně zkontrolovat, že připravená část skriptu funguje.

Kód skriptu by bylo možné např. realizovat nejprve takto:

Výpis 3.3: VB: napojení proměnných Promotic

```
1  dim napeti, baterie, dmn, hmn
2  dim n, zmena
3
4  set napeti = Pm("/Data/#vars/napeti")
5  set baterie = Pm("/Data/#vars/baterie")
6  set dmn = Pm("/Data/#vars/dmn")
7  set hmn = Pm("/Data/#vars/hmn")
8
9  napeti.Value = 300
10 baterie.Value = 33
11 dmn.Value = 230
12 hmn.Value = 230
```

Provedli jsme deklaraci proměnných a provedli jejich připojení na proměnné Promotic, následně jsme ale do takto spojených proměnných zadali odlišnou hodnotu. Pokud takovou aplikaci spustíme vizuálně uvidíme, zda se přenastavení hodnot proměnných provedlo nebo ne. Pokud ne, pak chyba musela nastat buď v přiřazení objektu set nebo v přiřazení hodnoty.

Protože ale zároveň uvidíte, která hodnota nebyla přiřazena omezíte možný problém pouze na dva řádky. Když získáme jistotou, že objekty se přiřazují správně, je možné řádky 9 - 12 odstranit a pokračovat v další práci.

Postupujte po malých krocích (rozdělujte problém na malé, jednoduché dílčí problémy).

Dbejte také na použití tzv. bílých znaků. Jedná se např. o tabulátory. Všimněte si, např. jak jsou naformátovány viceřádkové podmínky. Tabulátor umožňuje jednoznačně určit „tělo“ podmínky. Bílé znaky nejsou povinné, ale jejich použití zlepšuje výrazně čitelnost kódu, protože se v něm dá lépe orientovat. Dobře čitelný kód se pak lépe ladí.

3.3 Promotic verze 9.0

Promotic ve verzi 9.0 se poměrně zásadně proměnil. Po spuštění editoru naběhne jeho základní verze, viz obr. 3.18.

Otevření projektu nebo vytvoření projektu nového je pak realizováno na záložce **Aplikace**, kliknuttím na hlavní menu, viz obr. 3.19. Po výběru přidat lze přidávat existující projekty nebo vytvářet projekty nové. Pro zajištění zpětné kompatibility umožňuje Promotic 9.0 vytvářet jak projekty kompatibilní se starším prostředím Promotic 8.3, tak projekty spustitelné pouze v Promotic 9.0.

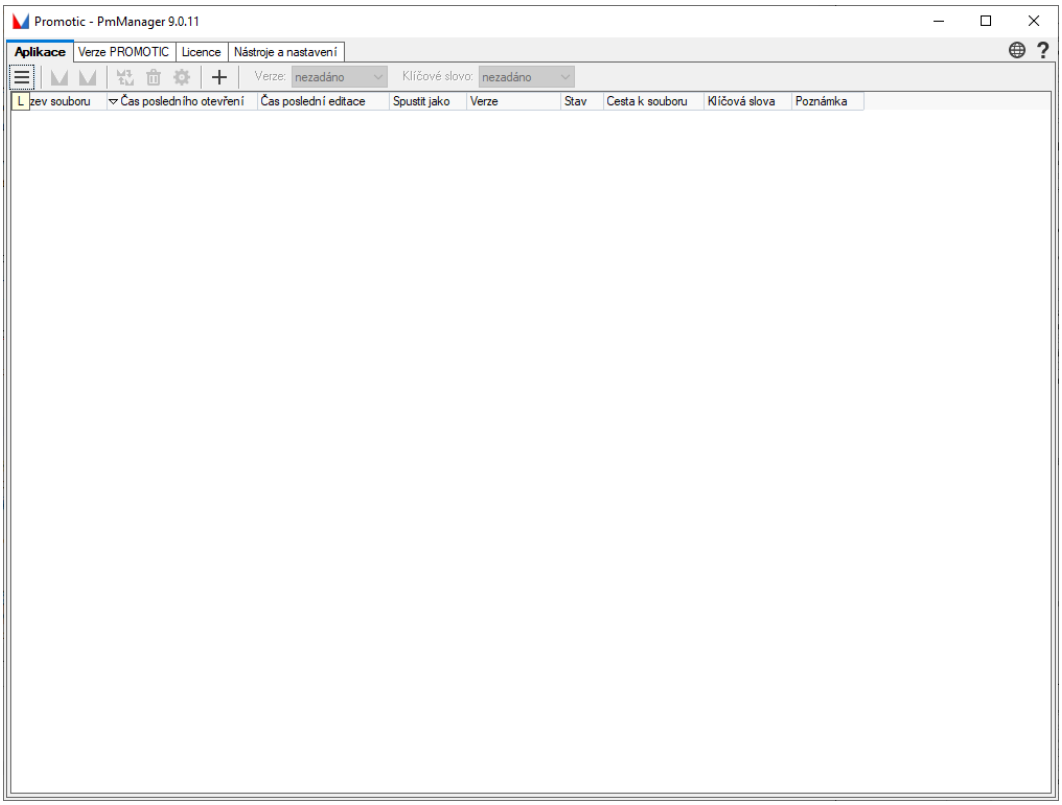

Obrázek 3.18: Promotic 9.0 - základní rozhraní

Z praktického pohledu, pokud vytváříme aplikaci novou měli bychom preferovat spíše poslední verzi. Přece jenom je zpětná kompatibilita určena pro dlouhodobou podporu již existujících řešení a systémů.

Projekty kompatibilní s verzi 9.0 je pak možno vytvářet v 32-, nebo 64-bitové verzi. Promotic 9.0 je přitom první verzí, která podporuje 64-bitové prostředí. Tato změna byla vynucena historickým vývojem, jelikož v současnosti jsme svědky masivního ústupu 32-bitových verzí operačních systémů a to včetně postupného upouštění od udržování podpory provozu 32-bitových aplikací. Promotic tak následuje tento trend.

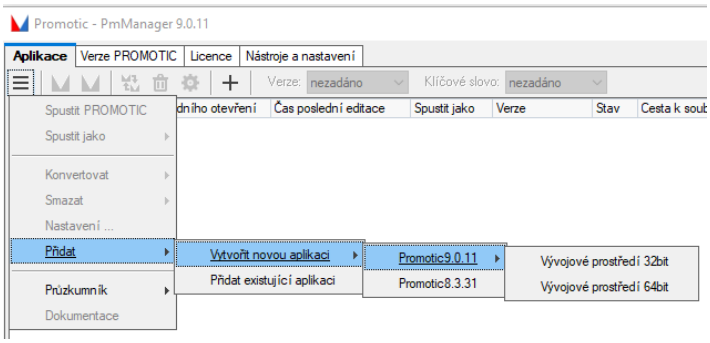

Obrázek 3.19: Založení projektu v Promotic 9.0

Kliknutím na vývojové prostředí 64- (popř. 32-) bitů spustíme průvodce vytvořením projektu. V prvním kroku volíme typ aplikace. Pro realizaci vlastního řešení v tomto kroku máme pouze jedinou volbu a to *základní aplikace*. Ostatní volby umožňují přístup k vestavěným demonstračním příkladům, které můžete chtít použít pro seznámením se s prostředím Promotic a jako případný zdroj inspirace. Na další krok přejdeme kliknutím na tlačítko *další*.

V dalším kroku volíme umístění projektu. Zde doporučuji předem si připravit prázdnou složku, ve které hodláte vyvíjet aplikaci, nebo si umístění alespoň rozmyslet. Novou složku Vám umožní vytvořit

přímo Promotic. Volbu umístění provedeme kliknutím na „...“ ve volbě *cesta k souboru aplikace*.

Název aplikace se zadává volným textem, jedná se o pojmenování. *Skriptovací jazyk aplikace* je ve verzi 9.0 již předvolen na JavaScript. Visual Basic je ale stále ještě nabízen. Pokud tedy preferujete spíše tento jazyk, nezapomeňte provést změnu. V této podkapitole budeme ale příklad oživovat pomocí JavaScript.

Poslední volbou, která nás v tomto kroku zajímá je *typ runtime licence*. Ta je předvolena na LicKey1 - podle licenčního klíče (povolit PmRt TestFree). Tato forma forma licencování nám umožňuje vyvíjet velikostí omezené aplikace, což je něco, co budeme potřebovat. Pro vývoj plnohodnotných aplikací bez omezení velikosti je požadován licenční serve, který je samozřejmě zpoplatněn.

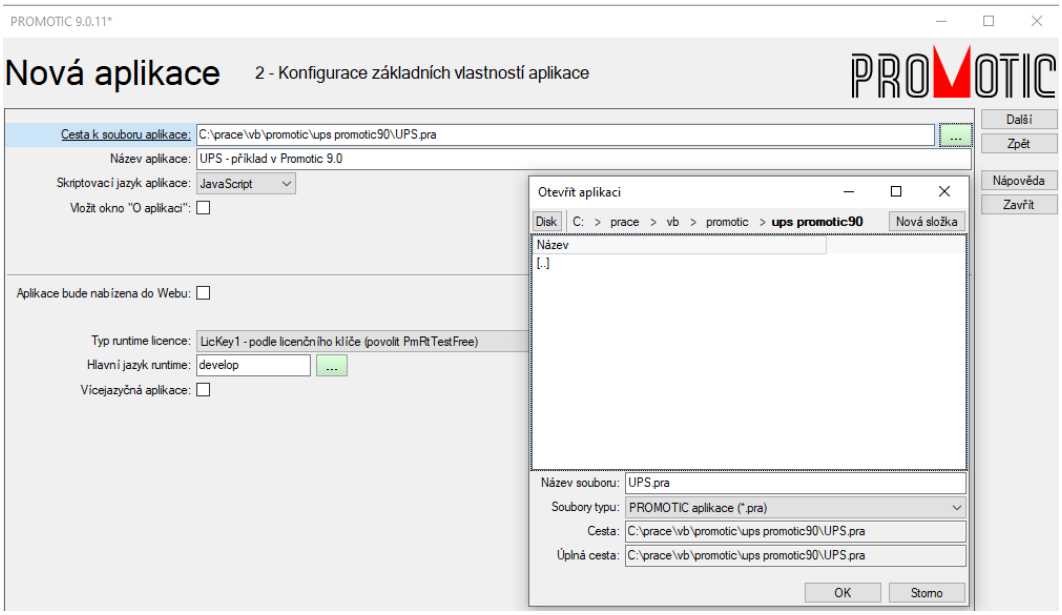

Obrázek 3.20: Průvodce zavedení projektu v Promotic 9.0 - krok 2

V třetím kroku volíme *rozložení aplikace*. K dispozici máme tři možnosti, které jsou vizuálně znázorněny na obr. 3.21. Volba rozložení neovlivňuje funkci vytvářeného projektu. Jedná se tak primárně a věc osobních preferencí. Podobně je v kroku 4 průvodce věcí osobních preferenci vzhled nástrojové lišty. Nástroje dostupné v této liště jsou ale totožné.

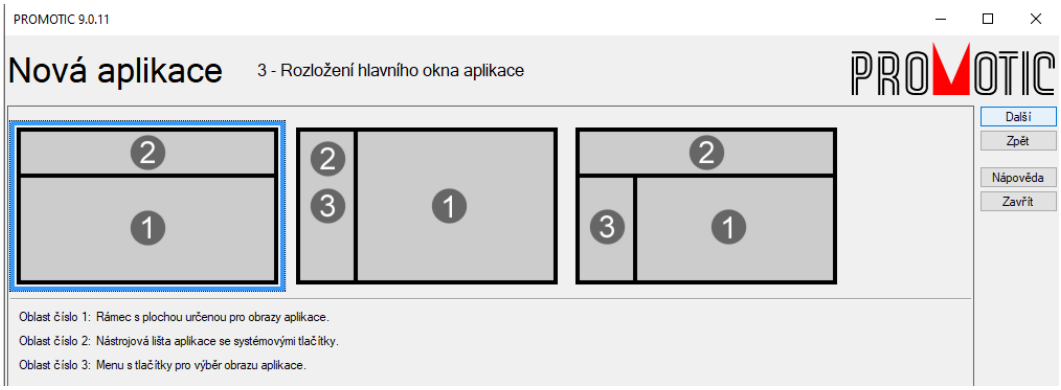

Obrázek 3.21: Průvodce zavedení projektu v Promotic 9.0 - rozložení aplikace

Volba vzhledu lišty nástrojů je posledním krokem průvodce. Po jeho dokončení se již otevře projekt v režimu editace, viz obr. 3.22. Tento editor už je velmi podobný editoru z verze 8.3, konečně můžete porovnat sami, viz obr. 3.3.

Zkusme replikovat postup vytvoření aplikace UPS z předchozí podkapitoly. Nabídka objektů i postup jejich definice zůstává stejný. Zůstává i možnost vybrat si způsob, jakým budeme definovat proměnné a to buď pomocí objektu *data* nebo zastaralým způsobem pomocí objektu *číslo*.

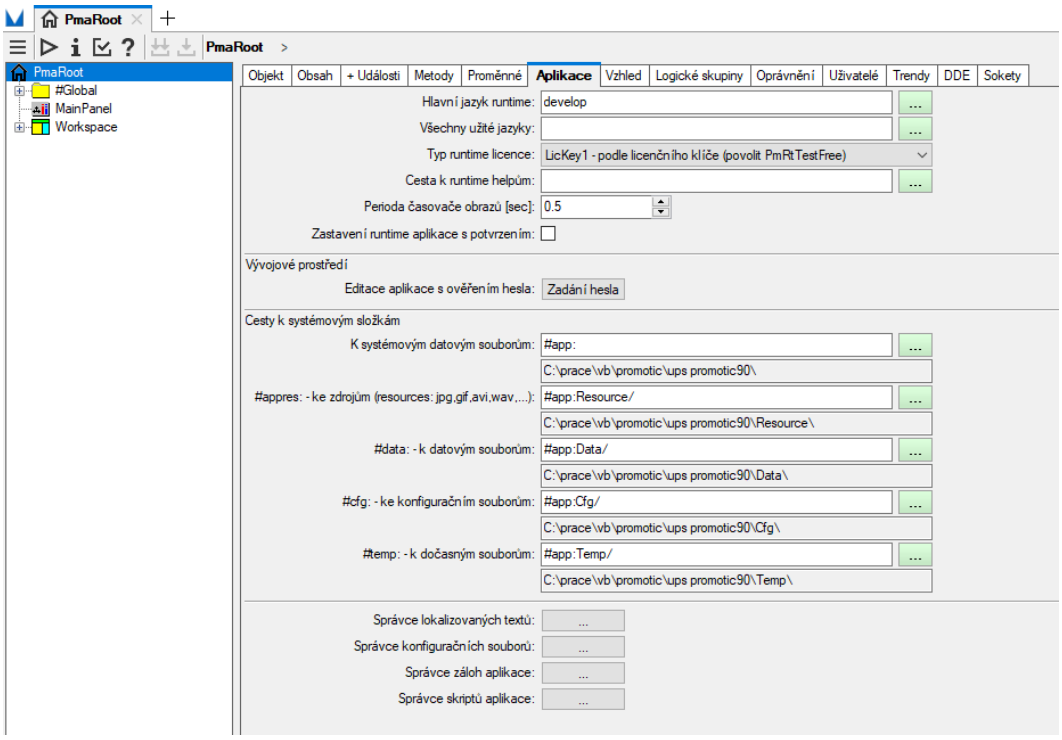

Obrázek 3.22: Editor Promotic 9.0

Jelikož demonstrujeme novou verzi, použijeme už moderní možnost poskytovanou objektem data. Rovnou si do projektu můžeme přidat další potřebné objekty a to *časovač* a *uživatelská grafika*.

V objektu data nastavíme naše proměnné. Budeme je přidávat postupně klikáním na tlačítko +. Všechny proměnné vytvoříme celočíselného datového typu (integer).

- *napeti* - počáteční hodnota 230,
- *baterie* - počáteční hodnota 50,
- *dmn* - dolní mez napětí, počátečního hodnota 200,
- *hmn* - horní mez napětí, počáteční hodnota, 260.

Editor obrazů ve verzi 9.0 již není samostatnou aplikací. Obraz tak můžeme editovat přímo kliknutím na záložku *grafika*. Samotný postup práce, ale zůstává stejný. Tedy definujeme jednotlivé objekty, které podle potřeby napojujeme na námi definované proměnné.

Pro náš projekt budeme potřebovat dvě táhla se stupnicí a s editací vodorovně (skupina nástrojů táhlo (PmiSlider)) a dva měřící přístroje.

Táhla napojíme na proměnné dolní a horní meze, měřící přístroje pak na proměnné baterie a napětí v síti.

Pamatujte, že maximum nastavení byste měli provést v dialogovém okně, které vám nabídne Promotic při vytvoření objektu. Toto dialogové okno totiž obsahuje ty nejpoužívanější nastavení, která je obvykle potřeba upravit. Přenastavení je možné samozřejmě provést také později, ale to budete muset jednotlivá nastavení hledat mezi ostatními.

Při nastavování postupujte podle návodu v předchozí podkapitole. Celkový výsledek by mohl vypadat např. jako na obr. 3.23.

Oproti verzi 8.3 má v souvislosti s uživatelskou grafikou nová verze Promotic jednu příjemnou vlastnost - nevyžaduje již kompilaci obrazů. Je to taková drobnost, ale potěší. Kompilace totiž byla krokem, na který zejména začátečníci často zapomínali a pak řešili, že změny, které v editoru provedli se neprojevují v aplikaci samotné po jejím spuštění. To v nové verzi odpadá.

Na druhou stranu, kompilace také fungovala jako určitá forma kontroly konzistence obrazu. Tímto způsobem bylo možné např. jednoduše odhalit, že bylo narušeno propojení mezi objektem obrazu a proměnnou Promotic. Tuto užitečnou kontrolu je ale možné jednoduše spustit manuálně z hlavního panelu nástrojů *Test konzistence aplikace* (ikona s fajfkou).

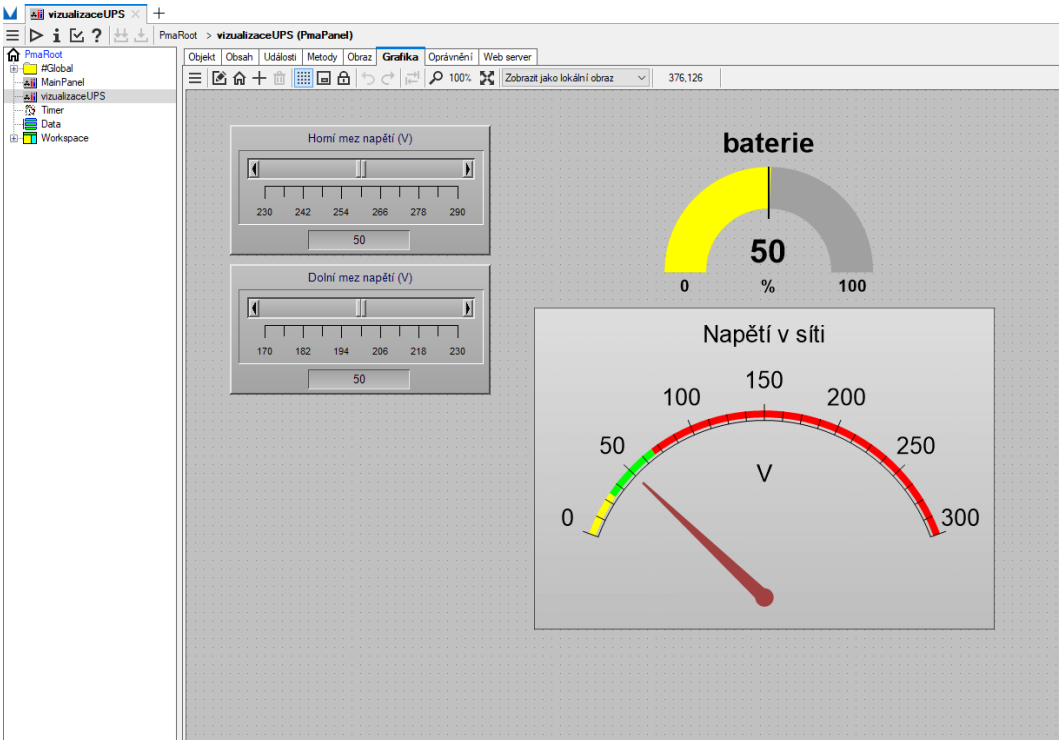

Obrázek 3.23: Příprava uživatelské grafiky v Promotic 9.0

Tento test by měl být spuštěn jako jeden z prvních kroků fáze ladění - kdy víme, že náš projekt obsahuje chyby, ale zároveň ještě nevím jaké. Chyby které lze automaticky detekovat jsou ty jednodušší z hlediska opravy, jelikož systém samotný nám řekne, kde je problém.

Zbývá oživit časovač přepsáním kódu z Visual Basic do JavaScript jazyka.

Výpis 3.4: JavaScript: oživení časovače projektu UPS v Promotic 9.0

```
1  var napeti = Pm("/Data/#vars/napeti");
2  var baterie = Pm("/Data/#vars/baterie");
3  var dmn = Pm("/Data/#vars/dmn");
4  var hmn = Pm("/Data/#vars/hmn");
5  var n = Math.random();
6
7  if(n > 0.5){
8    napeti.Value++;
9  }else{
10   if(napeti.Value > 0) napeti.Value--;
11 }
12
13 if(napeti.Value >= dmn.Value && napeti.Value <= hmn.Value){
14   if(baterie.Value < 100) baterie.Value++;
15 }else{
16   if(baterie.Value > 0) baterie.Value--;
17 }
```

Oproti VisualBasic je JavaScript trochu odlišný. Je citlivý na velikost písmenek proto pojmenování *napeti* a *Napeti* neodkazuje na stejnou proměnnou.

Proměnné samotné je potřeba deklarovat příkazem var (Visual Basic používal dim).

Jednotlivé příkazy v JavaScirpt jsou také zakončovány znakem středníku. VisualBasic proti tomu žádné formální zakončení řádku nevyžadoval. Podobně nevyžadoval ani vymezení třeba těla podmínky. JavaScirpt, ale toto vyžaduje, k tomuto vymezení používá složené závorky {}. Pouze poznámku - tyto znaky je možno pohodlně zadávat také na české klávesnici pomocí kombinace kláves pravý ALT + b („{“) a pravý ALT + n („}“).

Všimněte si také znamének ++ a −−, např. napeti.Value++. Jedná se o zkrácená zápis pro napeti.Value = napeti.Value + 1. −− pak analogicky znamená odečtení 1. ++ označujeme jako auto

inkrement, zatímco −− označujeme jako autodekrement.

Zjednodušeně přičítat nebo odečítat lze také jakékoliv jiné číslo, např. i = i + 10, můžeme zapsat zkráceně i += 10.

Konečně podmínku vždy ohraničujeme kulatými závorkami. Výrazy, které se mají vyhodnocovat mohou být spojeny logickými spojkami AND (zapsáno jako &&) a nebo OR (zapsáno jako ||).

Jak je vidno, JavaScript není extrémně filozoficky odlišný od Visual Basicu. Existují zde samozřejmě jinak pojmenovaná klíčová slova trošičku odlišná syntaxe, ale právě toto je něco, co bývá považováno za výhodu. Odlišnosti v programovacích jazycích mohou být naopak považovány za možnost jak si najít něco, co lépe vyhovuje způsobu myšlení osoby, která programuje. Např. použití pro ohraničení těla podmínky je pro řadu uživatelů preferovaná forma zápisu, protože tělo podmínky/funkce vizuálně odděluje od zbytku programu.

Naopak pro řadu lidí je takový zápis zbytečný a preferují jazyky (Visual Basic, Python), které takový typ zápisu nepoužívají.

Z hlediska našeho budoucího použití je jedno, který z těchto jazyků použijete, oba dva Vám umožní dostat se k cíli.

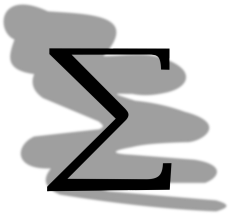

Místo shrnutí

Tato kapitola byla více praktická, doufám proto, že jste příklad úspěšně realizovali v Promoticu a pochopili základy fungování tohoto systému. Teď je vhodná doba se systémem dále experimentovat.

V kontrolních otázkách proto najdete některé náměty, které by Vás mohly motivovat

Kontrolní otázky

1. Implementujte světelnou signalizaci nabití baterie.
2. doplňte dynamicky měnící se text popisující stav baterie (např. vybitá, téměř vybitá, ...)
3. implementujte skrývání (a objevování se) prvků ve vizualizaci pro signalizaci některých stavů (experimentování s viditelností).
4. navrhnete vlastní řešení zvoleného problému, doplňte jej krátkým textovým komentářem a odevzdejte jej jako semestrální projekt.
5. podle toho jaký programovací jazyk jste zvolili pro oživení časovače - vytvořte variantu projektu využívající druhý programovací jazyk. Zkuste zjistit, který z jazyků Vám lépe vyhovuje. (a toho se pak držte :-)

Kapitola 4

Automatizace - otázky bezpečnosti

Náhled kapitoly
V minulých kapitolách jsme se do určité míry seznámili s funkcí jednotlivých zařízení odpovědných za automatizaci technologií. V této kapitole z těchto znalostí vyjdeme a zaměříme se na bezpečnost těchto zařízení a také možné dopady výpadků nebo ztráty kontroly nad nimi.

Po přečtení této kapitoly budete
vědět

1. jaké bezpečnostní problémy jsou typické pro v současnosti používané automatizační systémy
2. jaká řešení, z hlediska architektury sítě, lze zvolit pro minimalizaci rizik spojených s jejich použitím
3. jaké útoky byly prakticky realizovány a jaké měly následky

Čas pro studium
K prostudování této kapitoly budete potřebovat přibližně dvě hodiny.

V předchozích kapitolách jsme se seznámili s různými typy zařízení, které se používají pro automatizaci. Z hlediska bezpečnosti z toho můžeme vypíchnout především následující podstatné momenty:

- automatizace různých procesů v průmyslu (a nejen v něm) je natolik rozšířená, že lze říci že naše civilizace je na nich existenčně závislá - automatizováno je vše od výrobních procesů, systémů kritické infrastruktury až po ovládání kotle popř. klimatu v kancelářských budovách i rodinných domech
- dlouhodobé použití nasazovaných technologií (délka doby užití takových technologií) je obvykle delší než délka podpory ze strany výrobce
- změny v očekáváních o způsobu použití takových technologií pak nutně nemusí odpovídat výrobcem předpokládanému užití → *riziko*
- SCADA systém je obvykle provozován na standardním PC - je proto zranitelný běžnými útoky, stejně jako jiné běžně používané počítače připojené k síti
- typické je dálkové řízení
- některé informace získávané nebo zpracovávané v automatizační části sítě organizace je nutné sdílet i do běžné počítačové sítě organizace.
- ... pravděpodobně bychom dokázali vymyslet také další příklady.

Výše uvedený seznam představuje východiska, pro podrobné rozebrání problémů ale také způsobu ochrany. Z praktických důvodů je problematika ochrany rozdělena do dvou částí popsanými v

samostatných podkapitolách. V první části budou rozebrány některé *případy narušení bezpečnosti* takových systémů a rozebrány bezpečnostní implikace, které z nich lze vyvodit. V druhé podkapitole budou rozebrány *možnosti realizace izolace automatizační sítě*, jako základního nástroje pro získání jakési úrovně kontroly nad ní.

4.1 Případové studie bezpečnosti automatizace

Naši exkurzi pro známých případech narušení provozu, přerušení výroby, výpadku různého typu zahájíme v poměrně dávné době - v roce 2000. Tehdy se do čističky odpadních vod v Maroochy Shire, Queensland - Austrálie [72] naboural hacker a opakovaně vypustil miliony litrů nezpracovaných odpadních vod do přilehlých místních parků a také hotelu Hyatt Regency - čímž způsobil poměrně velké škody na majetku a především pak životním prostředí.

Motivem byla pomsta za odmítnutí zaměstnaní ze strany města. K provedení útoku využil hacker znalostí získaných v rámci svého původního zaměstnání, kde pracoval jako součást týmu pracujícího na instalaci a také údržbě výše uvedené čističky.

Útočník byl dopaden a následně odsouzen ke dvěma letům odnětí svobody.

2000 - čistička odpadních vod - implikace pro bezpečnost
Útočník byl v tomto případě tzv. *insider*. Disponoval tedy podrobnými znalostmi o způsobu fungování napadeného zařízení a vlastnil dokonce kopii software, který umožňoval dálkové připojení do tohoto zařízení a jeho ovládání.

Útoky insiderů jsou obzvláště nebezpečné, protože využívají standardních způsobů používaných pro běžné řízení technologií. Technicky je takový síťový provoz obtížněji detekovatelný než z vnějšku realizovaný pokus o průnik bez takových znalostí a nástrojů.

Problematická je také rychlost provedení útoku - v případě, že se útočníkovi podaří k řízené technologii připojit, může začít přímo ovládat část nebo dokonce celou technologii. Běžný útočník ale postupuje z vnějšku dovnitř. Nejprve musí řešit způsob připojení a následně způsob jakým se zmocní kontroly nad technologií - tato kontrola proto obvykle není úplná, zejména pokud útočníkem je jednotlivec s omezenými zdroji pro realizaci útoku.

Problémem z hlediska zabezpečení byl v tomto případě právě přístup - řízení by mělo být možné realizovat pouze z předem stanovených zabezpečených pracovních stanic. Obecně bychom mohli tento problém označit jako problém **bezpečnosti přípojných bodů**. Útočník by ideálně neměl mít vůbec možnost se připojit do automatizační sítě, natož v ní cokoliv dělat.

Jako podpůrný prostředek bylo možné použít metod asymetrického šifrování - konkrétně požadavek na použití ověřeného certifikátu k připojení, vztaženého k osobě operátora. Po odchodu pracovníka lze takový certifikát revokovat, pracovník by pak ztratil možnost se vzdáleně připojit, jelikož by nebyl schopen se do systému úspěšně autentizovat.

Tento způsob má ale také některá úskalí - před revokaci certifikátu je potřeba zajistit, aby se k systému mohl připojit alespoň jeden „oprávněný“ operátor - v opačném případě by mohlo dojít je ztrátě kontroly nad řízenou technologií.

Otázkou také zůstává, zda by takové opatření bylo v tomto případě účinné. Ze zdrojů totiž nevyplývá, zda v době realizace útoku byl útočník stále ještě zaměstnancem firmy realizující správu automatizace čističky a tedy zda měl (nebo neměl) z titulu své funkce v době útoku ještě možnost dálkového přístupu. Pokud ano, pak by použití asymetrické kryptografie samo o sobě tomuto útoku nezabránilo.

Zajímavým případem infekce červem **Slammer**[1] [74] v roce 2003. Tento červ napadal MS SQL server, kompromitované servery pak generovaly ohromné množství síťového provozu, které doslova zahltilo počítačovou síť, ve které se napadený server nacházel.

Ačkoliv většina databázových serverů spravovala data běžných informačních systémů byly zaznamenány i jisté dopady, které rámec běžného IT přesahují. Vyřazena byla např. činnost několika aerolinek [27], což vedlo k nutnosti zrušení řady letů. V tomto případě nebyla narušena bezpečnost leteckého provozu, lety ale nebylo možné odbavovat z důvodu nedostupnosti informací ze systému evidujícího letenky.

[1] známý též pod jmény W32.SQLExp.Worm, SQL Slammer Worm [ISS], DDOS.SQLP1434.A [Trend], W32/SQLSlammer [McAfee], Slammer [F-Secure], Sapphire [eEye], W32/SQLSlam-A [Sophos].

V atomové elektrárně Davis-Besse v Ohiu (USA) [66] způsobil Slammer výpadek bezpečnostního monitorovacího systému elektrárny. Je potřeba dodat, že elektrárna byla v to době odstavena z důvodu probíhající zásadní rekonstrukce a tak nedošlo k narušení jaderné bezpečnosti, byť i tak je tento incident hodnocen jako obzvláště závažný.

2003 - Slammer, diskuze následků a ochrana

V obou případech infekci způsobila nedbalost administrátorů MS SQL serveru postižených firem, kteří včas neaplikovali bezpečnostní záplaty, řešící zranitelnosti, které později Slammer zneužil ke kompromitaci serveru.

Tento případ také jasně demonstruje, že řídící systémy mohou být (a většinou také jsou) zranitelné vůči útokům, které jsou typické pro „běžné IT".

Ukazuje se, že člověk je tvor omylný a tak všechny jeho výtvory je obsahují také. V IT se to týká jak software tak hardware. Hlavním poučením, které si lze z případu Slammer vzít, je že se nevyplácí podcenit **management rizik**.

Organizace musí neustále vyhodnocovat v jakém stavu se nachází všechna aktiva, která využívají. Existuje řada služeb, které umožňují takové informace získat z jednoho místa pro různé systémy - viz např. Secunia [71] a řada dalších. Tyto informace je potřeba vyhodnotit a přijmout případně opatření k minimalizaci rizik z něj vyplývajících.

Ve většině případů mají tato opatření charakter buďto aplikace záplaty opravující zjištěnou zranitelnost nebo změnu konfigurace systémů která minimalizuje možnost jejího zneužití, zranitelnost samotná ale zůstává přítomna.

Jako příklad druhé možnosti nám mohou posloužit zranitelnosti Spectre [45] a Meltdown [50] čipů společnosti Intel. Intel vydal sice nové verze tzv. mikrokódu pro své čipy posledních dvou generací, podobně firmy odpovědné za vývoj jednotlivých operačních systémů vydaly pro své systémy záplaty. Tato opatření ale neřeší fyzický problém (konstrukční vadu) způsobující výše uvedené zranitelnosti. Zveřejněné opravy tak pouze znesnadňují jejich zneužití.

V případě jaderné elektrárny Davis-Besse hrál roli také další faktor - *působení třetí strany*. Této problematice se ale budeme věnovat o trochu později v souvislosti s červem Stuxnet.

Necílené infekce mallware jsou ve skutečnosti u automatizačních systémů poměrně běžné. V roce 2005 infekce virem Zotob si vynutila hodinovou odstávku v třinácti závodech společnosti Daimler-Chrysler [68]. Škody se v tomto případě odhadují poměrně obtížně, ale práci muselo přerušit okolo 50-ti tisíc zaměstnanců společnosti.

K infekci došlo byť automatizační síť byla za firewallem. Pravděpodobným vstupním bodem infekce bylo zapojení virem napadeného notebooku do automatizační sítě.

Ačkoliv následky takových útoků jsou citelné, pokud je útok cílený, bývají následky podstatně horší. Např. v květnu 2017 (12. - 19. května) byl zaznamenán útok ransomware WannaCry [77] na Britský National Health System (NHS). Podle šetření National Audit Office (NAO) [58] byla ransorwerem WannaCry v nějaké formě postiženo 81 zdravotních zařízení (z celkového počtu 236 zařízení zapojených do systému NHS). Přitom 37 zařízení bylo postiženo přímo, dalších 44 nepřímo tak, že preventivně odstavily část svých systémů z provozu, aby se vyhnuli infekci.

V důsledku útoku muselo být přeloženo okolo 6 900 konzultací, vyšetření nebo zákroků. Některé odhady pak hovoří o tom, že celkový dopad byl ve skutečnosti ještě větší, neboť tyto přeložené úkony by pravděpodobně vyvolaly další - doplňující vyšetření, konzultace specialistů apod.

Následky útoku přitom mohly být ještě podstatně větší, pokud by 19. května 2017 nebyl útok přerušen - útočník použil zabudovaný „kill switch" pro přerušení útoku.

Tento typ útoků je známý také z prostředí ČR. Např. v roce 2019 mu čelila Benešovská nemocnice, kde si virus vyžádal přerušení činností na dva týdny. Postiženy byly také další firmy, jako např. OKD, ale následky vzhledem k lépe řešenému modelu bezpečnosti nebyly takové a obnova činnosti po infekci tak byla velmi rychlá.

Infekce i v tomto případě využívala známých zranitelností operačního systému Windows. Situace v tomto případě byla komplikovaná tím, že řada přístrojů používaných ve zdravotnictví vyžaduje ke své práci specifickou verzi operačního systému, pro které již nemusí být nabízeny aktualizace. Bezpečnostní situace ve zdravotnictví je tak velmi podobná situaci např. v průmyslu.

Pro úplnost ještě můžeme zmínit také poslední vlnu opět ransomware WannaCry, která postihla počátkem srpna 2018 výrobní procesy v společnosti Taiwan Semiconductor Manufacturing Company (TSMC) [48] a způsobila jejich několikadenní výpadek. Škody v tomto případě jsou odhadovány na přibližně 170 mil. USD.

Odlišná příčina vyřadila řídící systém jaderné elektrárny Browns – Ferry (USA) [67]. Zde byl zaznamenán v roce 2006 souběžný výpadek dvou oběhových čerpadel (hlavního a záložního). Výpadek způsobil nestandardní síťový provoz v automatizační síti elektrárny. V tomto případě nestandardní provoz ale nebyl způsobem působením viru nebo aktivním útokem hackera, ale prostým provozem celého systému. Řídící systém oběhových čerpadel se nebyl schopen s touto situací vypořádat a tak reaktor elektrárny bylo nutné odstavit manuálně.

Problém byl následně vyřešen restartem řídícího systému, čímž byla opětovně získána plná kontrola nad systémem.

Přesná příčina nebyla nikdy pro tento případ odhalena - lze se ale dohadovat, že vlivem kombinace nepříznivých událostí se řídící systém dostal do stavu, se kterým se nebyl schopen vypořádat a který ale také zabránil dálkovému zásahu operátora.

Projevila se tak chyba v zařízení, která za normálních okolností zůstávala latentní. Jelikož obě oběhová čerpadla byla pořízena ve stejnou dobu od stejného výrobce, byla také náchylná ke stejným problémům. Nepříznivá kombinace faktorů která zapříčinila výpadek hlavního čerpadla způsobila taktéž výpadek jeho zálohy.

Řešení v tomto případě jsou poměrně problematická. Lez uvažovat o pořízení odlišných záloh, aby se zvýšila pravděpodobnost, že záložní systém nebude postižen stejným problémem jako hlavní systém. Realizace této možnosti je ale poměrně obtížná a bude mít negativní dopady na ekonomiku celého řešení a to jak z pohledu pořizovací ceny, tak z pohledu následné údržby takového řešení.

Co by mělo být bezpodmínečně zachováno je alternativní možnost řízení na místě včetně možnosti manuálního řízení. Přítomnost manuálního řízení umožní v případě výpadku dálkového řízení kontrolovat technologii, byť tato kontrola nebude ve stejné kvalitě jako třeba kontrola dálková.

Pro možnost manuálního řízení je potřeba uvažovat s jistou časovou prodlevou od vzniku situace, po dobu identifikace její příčina a okamžikem, kdy se odpovědný pracovník dostane na místo, aby mohl začít manuální řízení využívat. U rozsáhlých sítí pak může tato prodleva být i poměrně dlouhá (např. v hodinách). Sítě tohoto typu naštěstí jsou poměrně odolné proti náhodnému výpadku svých jednotlivých uzlů (ve smyslu vypadne náhodný uzel) a tak takové výpadky obvykle nevedou k rozsáhlejším výpadkům v síti jako celku.

Teoretické zdůvodnění toho, proč tomu tak je je možné nalézt např. v Lewis [49]. Bohužel v těchto skriptech není prostor k tomu, abychom se problematice sítí a šíření selhání v nich věnovali větší prostor.

Důležitý je také ještě jeden moment a to samotný charakter síťového provozu v automatizační síti. Právě nestandardní síťový provoz způsobil problém, ale co přesně je nestandardní provoz z hlediska zařízení, která jsou stará třeba 10 nebo více let?

Z tohoto důvodu jsou v automatizačních sítích pouze zřídka instalovány nástroje pro automatické mapování sítě, popř. systémy Intruder Detection System (IDS)/Intruder Prevention System (IPS), které jsou jinak běžně v podnicích využívány pro zlepšení bezpečnosti na síti.

2014 - Stuxnet - první kybernetická zbraň ... možná

Na závěr podkapitoly jsme si ponechali opravdovou lahůdku - červa Stuxnet, který působil mezi léty 2007 - 2010. Tento červ má několik prvenství:

1. jedná se o první zaznamenaný případ, kdy byl nějaký malware zacílen přímo na řídící systém
2. napadená síť nebyla připojena k Internetu
3. Stuxnet byl schopen fyzicky ničit části napadené technologie
4. Stuxnet byl pravděpodobně vytvořen (nebo jeho vznik byl podporován) nějakou vládou

Stuxnet [34] byl specifický svým zaměřením. Kompromitoval počítače s operačním systémem Windows. K tomu využíval 4 v době útoku neznámé zranitelnosti operačního systému. Při infekci byl ale červ obzvláště vybíravý - kontroloval lokaci ve které je spouštěn a také technologii, která je v automatizační síti přítomna.

Pozdější analýzou binárního kódu červa a přítomných omezení bylo zjištěno, že hlavním cílem červa byla pravděpodobně zařízení v Natanz v Iránu, které sloužilo k obohacování uranu. Hlavním cílem bylo přitom pravděpodobně napadané PLC automatů v síti ovládající centrifugy na obohacování uranu. Změnou rychlosti rotace centrifug bylo dosahováno velmi rychlého fyzického zničení těchto centrifug. Operátorům přitom kompromitovaná technologie hlásila, že vše je v pořádku.

Tímto způsobem bylo zničeno více než 2 000 centrifug a na to, že příčina hromadných selhání by mohla být externí se přišlo až v průběhu kontrolní mise Mezinárodní agentury pro atomovou energii.

Přestože zařízení Natanz bylo pravděpodobně hlavním cílem červa, byla přítomnost Stuxnetu zaznamenána také v dalších zařízeních na blízkém východě, ale také v jihovýchodní Asii.

Atypická struktura červa a také nástroje, které byly použity pro jeho přípravu a také cílení naznačují vysokou profesionalitu tvůrců červa. To asi hlavní důvody, proč se obecně předpokládá že jej vytvořil nebo jeho tvorbu sponzoroval nějaký stát nebo státy. Často se přitom spekuluje o USA a Izraeli.

Z pochopitelných důvodů, alespoň v nejbližší době zůstanou podobné úvahy na úrovni spekulací, protože oficiálního potvrzení se pravděpodobně nedočkáme.

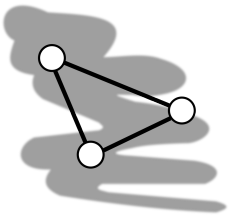

Stuxnet - další informace
O Stuxnetu je ale v současnosti k dispozici opravdu velké množství informací. Velmi poutavě popsal celou anabázi analýzy a také dopadů Stuxnetu popsal Kim Zetter ve své knize *Countdown to Zero Day: Stuxnet and the Launch of the World's First Digital Weapon* [83].

Na Stuxnet je také možné pohlížet z jiného pohledu - z pohledu platformy, na které byl postaven. Unikátnost návrhu je totiž také v silné modularitě kódu. Bezpečnostní výzkumníky proto napadlo, zda existují také jiní červi, kteří sdílejí podobné vlastnosti/moduly.

Stuxnet by pak mohl být považován za útočnou variantu červa, kterou by mohly doplňovat varianty zaměřené např. na špionáž. Ukázalo se, že takové varianty skutečně existují.

Červ DuQu [75] byl používán přibližně ve stejné době jako Stuxnet, byl ale zaměřen jiným způsobem. Analýzy antivirových společností prokázaly silné sdílení použitých modulů mezi oběma červy a také stejný (vysoce profesionální) styl, jakým byl napsán také Stuxnet.

Původní DuQu sloužil pro shromažďování informací o průmyslových řídících systémů. Většina zachycených vzorků byla z oblasti blízkého východu.

DuQu používal poměrně chytrý způsob infekce počítačů prostřednictvím zlovolně upravených běžných dokumentů (např. v PDF, nebo DOCX formátu) a zneužitím existujících zranitelností v jejich prohlížečích.

Jistou vazbu na Stuxnet mohou mít také červi Flame a Gauss. Flame (známý též pod názvem W32.Flamer) [76] otevíral zadní vrátka do systému, umožňující získat vzdálenému útočníkovi plnou kontrolu nad systémem, obsahoval také keyloger, schopnost zachytávat změny na obrazovce a také umožňoval využívat mikrofon a webovou kameru, pokud byly připojeny k počítači pro sledování dění v místnosti.

Malware Gauss [73] se pak zaměřuje primárně na sektor bankovnictví - opět se tedy jedná o špionážní software. Většina zaznamenaných infekcí pak pochází z blízkého východu, především pak Izraele, Sýrie, Libanonu a Palestiny.

Kaspersky se na základě svých analýz výše uvedených malwarů domnívá, že se jedná o jednu rodinu škodlivého kódu od stejných tvůrců. Svá tvrzení pak opírá o použití stejných nebo podobných modulů v červech. Takové závěry ale nejsou všeobecně sdíleny. Např. Symantec argumentuje, že sdílení modulů může naznačovat dočasnou spolupráci různých skupin na vývoji kódů, moduly, kterými se ale červi liší jsou napsány velmi odlišným způsobem. Symantec z toho vyvozuje, že Stuxnet a DuQu byl vyvinut jednou skupinou a Flame a Gauss druhou, nezávislou skupinou.

Kybernetická válka
Stuxnet je někdy označován jako první reálně vyvinutá a použitá kybernetická zbraň. V souvislosti s tím, se pak stále častěji hovoří o možnosti vedení tzv. *kybernetické války*, jako dalšího způsobu dosahování cílů v rámci konfrontace s nepřítelem.

Zatímco válka je jednoduše definovatelná (slovník Merriam-Webster [52]) jako *stav obvykle otevřeného a deklarovaného ozbrojeného nepřátelského konfliktu mezi státy, popř. národy.* V této definici jsou velmi důležitá slova otevřený a deklarovaný konflikt. Jde o to, že válka je skutečně v určitém smyslu pokračováním diplomacie jinými prostředky, jak prohlásil Carl von Clausewitz.

Jinými slovy všechny strany tohoto konfliktu mají vlastní, často otevřeně deklarované záměry, které se v rámci konfliktu snaží dosáhnout. Jednotlivé strany konfliktu proto ve skutečnosti řeší, zda budou v konfliktu pokračovat nebo druhé straně konfliktu dovolí dosáhnout jejích cílů.

Výše uvedené ale v případě vedení konfliktu na kybernetické úrovni není splněno. Současné zkušenosti tak spíše ukazují, že při nasazování takových prostředků je masivně využívána možnost tzv.

Stuxnet a obdobné kódy - aneb proč bych se to měl učit?
Po přečtení výše uvedených informací o různých škodlivých kódech Vás možná napadne: *proč bych se vůbec touto problematikou měl(-a) zabývat? Vždyť tohle je přece záležitost IT!* Svým způsobem má takový přístup pravdu. Je to ve skutečnosti záležitostí IT. Problémem ale je, že IT prorostlo takovým způsobem do všech běžných činností, že takřka vše co děláme je tak trochu záležitostí IT. Prakticky to znamená, že problematiku bezpečnosti nelze v současnosti od IT zcela oddělit!

To neznamená, že Vaše znalosti z IT by měly být nutně nějak hluboké. Berte prosím v úvahu, že IT specialisté mohou mít v oblasti (obecné) bezpečnosti podobnou úroveň znalostí, jako vy v IT. Aby bylo možné dosáhnout určité úrovně bezpečnosti je nutné se odborně „sejít někde uprostřed“ a intenzivně spolupracovat.

Pro realizaci takové spolupráce je ale nutné, aby si obě skupiny alespoň rámcově rozuměly.

věrohodného popření původu útoku, jelikož provedení analýz zachycených vzorů obvykle nepřináší samo o sobě věrohodné důkazy umožňující jednoznačně označit viníka. Alespoň ne na úrovni, kdy by z toho z hlediska mezinárodního práva vyplývaly jakékoliv reálné možnosti.

Z toho důvodu např. Thomas Rid [64] tvrdí, že kybernetická válka je ve skutečnosti protimluv. Argumentuje, že použití v současnosti známých nástrojů má tak spíše charakter špionáže popř. zpravodajských her.

Na druhou stranu samotná existence kódů jako Stuxnet vyvolává jisté otázky o budoucnosti bezpečnosti, zejména pak v oblasti kritické infrastruktury.

Jistá východiska z hlediska možnosti **dlouhodobého vyřazení systémů kritické infrastruktury** navrhuje Peterson [62]. Podle něj je v současnosti velmi jednoduché, alespoň po technické stránce, připravit škodlivý kód schopný kompromitovat a následně vyřadit určitý systém. Pro dlouhodobé působení takového útoku je ale zapotřebí aby kompromitovány nebyly jednotlivé systémy, ale systémy celého sektoru KI nebo alespoň jeho podstatné části.

K tomuto účelu by bylo nutné kompromitovat velké množství technicky odlišných systémů, což je opět technicky možné, ale finančně je to natolik náročné, že taková možnost je reálně dostupná pouze pro státy.

Přípravná fáze takového útoku by tak pravděpodobně musela probíhat minimálně měsíce, spíše však roky předem. Před spuštěním samotného útoku by tím ale vznikal prostor pro objevení již kompromitovaných systémů a jejich oprava. Také to znamená, že pokud stát uvažuje o reálné možnosti takto rozsáhlý útok realizovat musí zahájit snahy o kompromitaci takových systémů svého protivníka, byť reálně by útok - ve smyslu vyřazení KI nakonec nikdy nebyl realizován.

Nejblíže k plnému, dlouhodobému vyřazení části kritické infrastruktury měl útok na rozvodnou síť Ukrajiny z Vánoc 2015, který způsobil výpadek elektřiny pro přibližně 230 000 lidí na dobu přibližně 6-ti hodin. Některé pozdější studie kódu naznačují, že Ukrajina měla ve skutečnosti štěstí, protože škodlivý kód obsahoval část, která měla fyzicky poškodit rozvodný systém, při jeho manuální obnově činnosti. Vinou chyby v kódu viru se ale tato část nespustila.

Výše uvedené má také značné implikace z pohledu „ochrany KI“. Jednotlivé prvky KI jsou totiž obvykle v soukromém vlastnictví. Vlastník pak dle ekonomické teorie s infrastrukturami podniká za účelem maximalizace prospěchu svých vlastníků (stakeholderů). Tento prospěch se obvykle vyjadřuje finančně ve smyslu zisku, vyplacené dividendy, popř. ceny akcií.

Proti obránci ale může stát útočník, který podobnou motivaci nutně sdílet nemusí - pokud útok připravuje stát, pak motiv bude politický. Pro realizaci útoku přitom může stát uvolnit libovolné množství peněz, obránce je však limitován svými disponibilními prostředky.

K této problematice a možnostem organizace ochranných opatření je věnována kapitola 5.

4.2 Způsoby izolace automatizační sítě

Jedním ze základních mechanismů ochrany řídících systémů je jejich izolace. Tradičně byly takové systémy izolovány zcela - tedy řídící systém byl zapojen ve zcela samostatné síti bez jakýchkoliv spojení na další sítě včetně Internetu. Tento způsob je možno považovat za nejbezpečnější. V angličtině se pak označuje jako tzv. *air gap*. (Tedy že mezi sítěmi neexistuje fyzické spojení.)

Pro pokus o získání kontroly nad takovou sítí pak útočník musí získat fyzický přístup k síti - útok, tedy alespoň v určité fázi musí být proveden fyzicky a na místě.

Zkušenosti s červem Stuxnet ale ukazují, že prostá totální izolace sítě není sama o sobě dostatečná pro zajištění její ochrany. Pro kompromitaci sítě v Natanz byl pravděpodobně použit kompromitovaný notebook nebo médium (např. flash disk) kontraktora.

Alternativní scénář kompromitace takových izolovaných sítí vyžaduje fyzicky přistoupit k síti a buďto přímo realizovat útok, nebo do sítě doplnit další zařízení - modem, radiostanice apod., které umožní útočníkovi později do sítě dálkově přistoupit a realizovat zamýšlený útok.

Nevýhodou takového přístupu je fakt, že propojením sítí mohou být dosaženy některé jinak nedostupné synergické efekty, kdy informace z technologie mohou být dále využívány pro efektivnější řízení organizace. Taková síť je pak také jednodušeji vzdáleně spravovatelná. To jsou také důvody proč je úplná izolace takových sítí v současné době spíše minoritní záležitostí.

Ochrana pak musí být realizována dalšími vrstvami ochrany sloužícími především k filtraci síťového provozu.

Pro organizace s automatizační sítí oddělenou od zbývajících sítí a Internetu nutnost fyzického přístupu k získání/převzetí kontroly nad technologií znamená, že praktická ochrana musí být založena na zajištění ochrany *vnějšího perimetru organizace*. Vzhledem k tom, že fyzický přístup k zařízení představuje zároveň také černý scénář i pro systémy a sítě připojené k Internetu, nelze ochranu vnějšího perimetru podcenit ani v takovém případě.

Mezi opatření, kterými takovou ochranu lze realizovat můžeme zařadit např.:

- kontrola vstupu (do střeženého perimetru mohou vstupovat pouze osoby které jsou k tomu oprávněny),
- kontrola činnosti návštěv, kontraktorů apod. v průběhu jejich pobytu v areálu
- kontrola narušení perimetru - kamerové systémy, čidla pohybu, senzory monitorující otevření např. dveří, pochůzková činnost v areálu apod.
- management manipulace se zařízeními - kontrola toho jaká zařízení (ve smyslu např. notebooků) se v areálu používají
- management médií, zejména těch, která jsou vnášena/vynášena z areálu.

Výše uvedená opatření mají za cíl zvýšit náročnost provedení útoku, popř. prodloužit čas nutný pro jeho realizaci a tak zvýšit šanci, že dojde k jeho odhalení a následně přerušení. Cílem tedy není provedení útoku zcela zamezit - neboť úplné zabezpečení není technicky možné nikdy realizovat.

Z praktických důvodů často nelze ani realizovat úplnou izolaci řídícího systému. V následujících odstavcích se proto zaměříme na různé scénáře realizace *softwarově* řešené izolace řídící a běžných sítí. Pracovat budeme s následujícími scénáři:

1. ochrana na vnějším perimetru sítě obvykle na bázi firewallu
2. omezení společných částí sítí
    - dual home computer (vybrané stanice mají přístup do různých sítí)
    - dual home server (vybrané servery mají přístup do různých sítí)
3. oddělení sítí směřováním koumunikace (pomocí routeru)
4. oddělení sítí pomocí firewallu
5. vytvoření demilitarizované zóny a oddělení sítí dvojicí firewallů

Ochrana na vnějším perimetru sítě obvykle na bázi firewallu

Tuto formu ochrany bychom si mohli představit podobně jako na obr. 4.1.

Vnitřní síť organizace je v tomto případě oddělena od internetu firewallem. Firewall pracuje na bázi protokolu TCP/IP. Umožňuje nastavením pravidel specifikovat systémy (IP adresami, popř. jejich rozsahy) a služby (porty), jejichž komunikace bude firewallem propuštěna. Nepovolenou komunikaci pak firewall zastaví.

Na obr. 4.1 tak na Internetu mohou komunikovat všechna zařízení v běžné síti a také webový server, oproti tomu komunikaci automatizační (řídící) sítě je zabráněno.

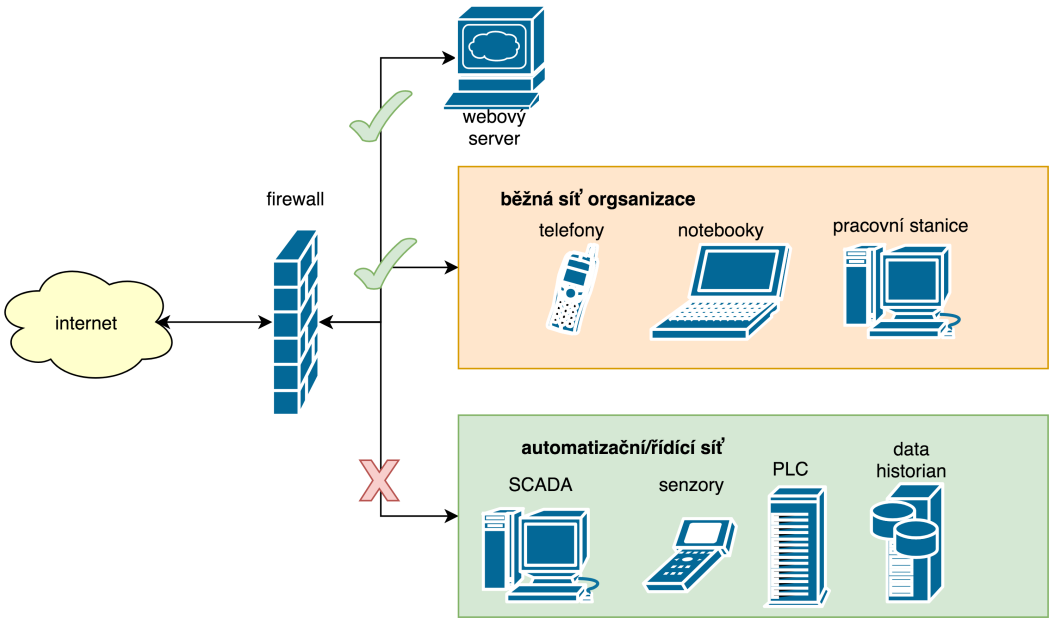

Obrázek 4.1: Bezpečnost řešená na vnějším perimetru sítě firewallem

Všimněte si, že výše uvedený scénář řeší pouze vnější hranici sítě. Komunikaci mezi běžnou počítačovou sítí a sítí automatizační tak nic nebrání. Útočníkovi tak může stačit kompromitovat jakékoliv zařízení v „otevřené“ části sítě a pak může pokračovat neomezeně v útoku do zbytku sítě i té, kde byla komunikace s vnějším světem na firewallu zakázána. V této fázi je útoku, je tak ochrana poskytovaná firewallem již překonána.

Úroveň ochrany, kterou toto řešení poskytuje, tak nelze přeceňovat. Z toho důvodu je tento scénář ochrany volen samostatně pouze zřídka a to zejména v případech kdy oddělení sítí nemá vzhledem k její velikosti smysl (např. mikro firmy nebo malé firmy).

Zároveň ale tento způsob ochrany poskytuje dobrý základ, který lze doplnit dalšími opatřeními vedoucími k lepší kontrole síťového provozu mezi jednotlivými částmi sítě. **Další scénáře proto předpokládají existenci tohoto řešení - tedy, že je nějakým způsobem řešena bezpečnost na vnějším perimetru sítě.**

Dual home computers

Tímto ne úplně dobře do češtiny přeložitelným označením rozumíme pracovní stanice, které jsou připojeny zároveň do řídící sítě a také běžné sítě. Připojení do každé ze sítí je přitom realizováno samostatnou fyzickou kabeláží. Tyto počítače tak musí být vybaveny dvěma síťovými kartami.

Schématicky si lze o způsobu realizace vytvořit představu z obr. 4.2.

K realizaci je používána běžná hvězdicová architektura sítě. Na obr. 4.2 je to naznačeno připojením počítačů do switchů v jednotlivých sítích.

Toto řešení není příliš praktické. Jeho takřka jedinou výhodou je, že formálně definuje rozhraní mezi běžnou počítačovou sítí a sítí automatizační. Toto rozhraní je tvořeno právě počítači, které jsou umístěny v obou těchto sítích. Z hlediska bezpečnosti je pak klíčové udržení kontroly právě nad těmito počítači.

S realizací tohoto scénáře oddělení sítí je však spojena také řada nevýhod. Toto řešení je poměrně rigidní - ve smyslu jeho změna není úplně snadná. Pokud mají být počítače umístěny ve dvou počítačových sítích, je nutné aby v budově byla vedena dvojí kabeláž. To ale také znamená, že vedené kabeláže nebudou univerzální a umístění těchto počítačů tak nebude v budoucnu možné měnit, aniž by byla taktéž přeložena kabeláž.

Podobná situace je s možností škálování řešení - např. přidávání dalších počítačů s touto konektivitou.

Z hlediska bezpečnosti není přínos tohoto řešení až tak výrazný. Je sice definováno rozhraní mezi sítěmi, ale stále se jedná o běžné počítače, které navíc jsou přímo přístupné z běžné počítačové sítě nebo dokonce Internetu (podle konfigurace firewallu na vnějším perimetru sítě). Tyto počítače tak mohou být samy přímo cílem útoku.

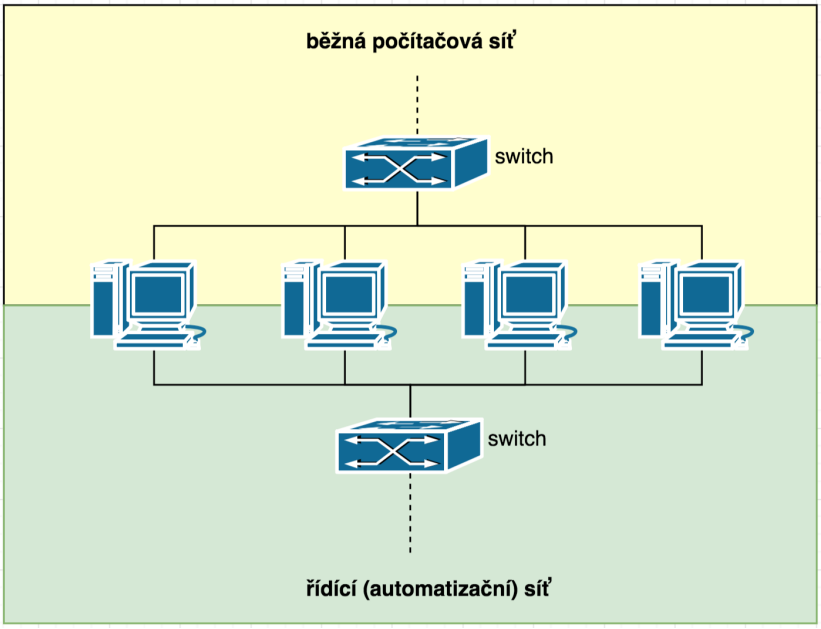

Obrázek 4.2: Dual home computers

Pokud pak dojde k jejich kompromitaci, otevírá se útočníkovi cesta do chráněné řídící/automatizační sítě organizace.

Dual home server

Alternativním řešením je neumisťovat do obou sítí jednotlivé počítače ale infrastrukturu, která má být v obou sítích používána. Z automatizační sítě jsou pro řízení organizace cenné informace o stavu technologií. Z předchozích kapitol již víme, že existuje místo, kam se takové údaje často ukládají - *data historian*.

Tento typ řešení by mohl být realizován podobně jako na obr. 4.3.

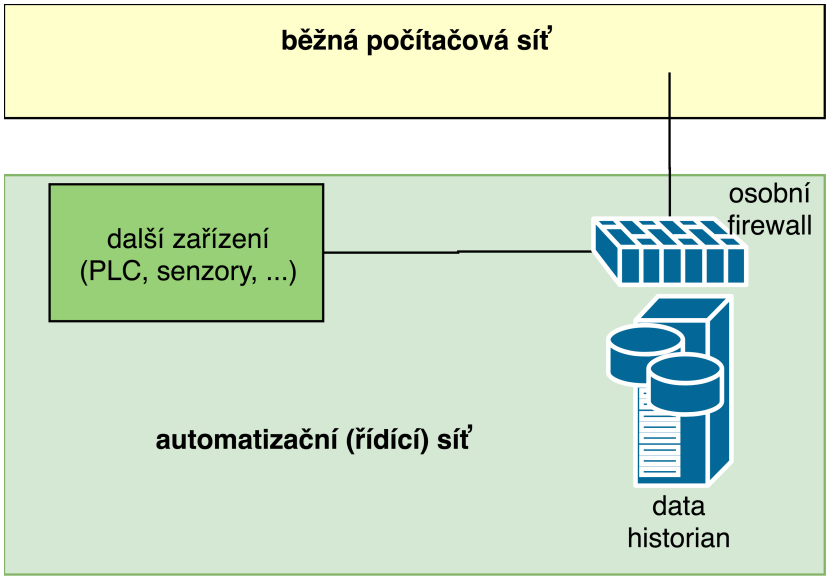

Obrázek 4.3: Dual home server

Toto řešení je ve srovnání s umisťováním jednotlivých počítačů do dvou sítí lépe škálovatelné. Databázový server bude nejspíše umístěn v servrovně, u které se dá očekávat, že její přesun nebude probíhat právě často. Dále se jedná pouze o jedno místo, jeho zasíťování není proto až tak problematické.

Umístění v serverovně s sebou obvykle nese také zvýšení úrovně fyzické bezpečnosti. Jelikož serverovna má obvykle zavedenu nějakou formu řízeného vstupu. Počet pracovníků s fyzickým přístupem k serveru je tak omezený a proto lépe kontrolovatelný.

Na obr. 4.3 je taktéž naznačena možnost použití osobního firewallu pro řízení síťového provozu serveru. V tomto scénáři se zatím nebere v úvahu možnost použití dedikovaného firewallu (tímto scénářem se budeme zabývat později).

Osobní firewall se od dedikovaného liší tím, že běží přímo na daném zařízení. Funkce firewallu je tak pouze doplňující vlastností systémové vrstvy zařízení. V současnosti většina operačních systémů má přímo v nějaké formě implementovaný osobní firewall, existují ale také samostatné softwarové balíky s pokročilejšími funkcemi, které lze doinstalovat.

Osobní firewall v sobě často obsahuje také některé další funkce zaměřené na zvýšení bezpečnosti použití zařízení. Může se jednat o moduly Host Intruder Prevention System (HIPS) sloužící pro identifikaci některých typů průniků do systému. V těchto řešeních jsou často implementovány také možnosti tzv. whitelistingu aplikací (specifikace aplikací, které mohou být spouštěny, popř. mohou komunikovat po síti), sandbox aplikací (omezení možnosti aplikací ovlivnit zbytek systému) a řada dalších.

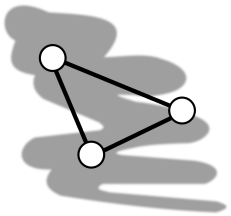

Osobní firewall pokusy

Některé z osobních firewallů jsou dostupné také bezplatně. Např. *Comodo Firewall* [28] je hodnocen poměrně příznivě a je dostupný bezplatně buď samostatně nebo v balíku s antivirovým programem.

Pokud jsou schopnosti osobního firewallu tak velké, dosahujeme výrazně vyšší úrovně bezpečnosti, ne? Ve skutečnosti tomu tak být nemusí. S použitím osobních firewallů na serverech se pojí řada problémů. Asi největším problémem je, že osobní firewally jsou určeny pro „osobní použití“ - tedy předpokládají, že u chráněného zařízení bude fyzicky sedět osoba, která v případě potřeby zasáhne do funkce firewallu.

Osobní firewally se totiž obvykle „učí“, jaký síťový provoz je možné považovat za bezpečný, které aplikace (a jejich verze) jsou bezpečné apod. V případě, že se firewall setká se situací, pro kterou nemá vytvořeno pravidlo za normálních okolností se uživateli objeví výzva na rozhodnutí, co má firewall v této situaci dělat - např. povolit dané aplikaci možnost komunikovat po síti. Na základě interakce s uživatelem jsou pro činnost firewallu doplňována pravidla - firewall se tedy postupně adaptuje na síťový provoz zařízení, na kterém je instalován.

U serveru ale za normálních okolností není fyzická obsluha přítomna - většina přístupů a to i administrátorských zásahů je realizována dálkové prostřednictvím na serveru provozovaných služeb. Navíc tato interakce je nárazová a je spojena obvykle s realizací údržby, servisních zásahů apod. Služby poskytované serverem jsou konzumovány klienty pomocí specializovaných aplikací nebo poskytovány přes webové rozhraní. Hlášení, které se zobrazí ve Windows tak pravděpodobně nikdo neuvidí - firewall tak ztrácí možnost se adaptovat.

I osobní firewall lze nakonfigurovat tak, aby se na nic neptal. Sada použitých pravidel je ale v takovém případě obvykle omezenější. Plnohodnotné použití všech (zejména těch pokročilejších funkcí jako je sandbox nebo HIPS) pak často není možné.

Další nevýhodou je to, že k filtraci síťového provozu dochází přímo na zařízení - zařízení tedy přijme packet a komponenta firewallu provede jeho vyhodnocení. Firewall ale může sám obsahovat zranitelnosti, které mohou umožnit útočníkovi tuto vrstvu ochrany (za určitých specifických podmínek) obejít nebo je ji možné dokonce zneužít k tomu, aby byl takový systém přehlcen požadavky a nebyl schopen vyřizovat oprávněné požadavky.

Útoky typu Denial of Services (DoS) jsou bohužel těmi nejčastějšími, kterým jsou sítě organizací vystaveny a tak předchozí scénář není nepravděpodobný. Omezení schopnosti data historianu udržet aktuální informace o stavu technologie jsou pak klíčovými z pohledu naší schopnosti udržet kontrolu nad řízeným procesem, jak již víme z předchozích kapitol.

Poslední poznámka - z hlediska funkce tohoto řešení je v zásadě jedno, zda dual home server je umístěn v řídící síti (jak je tomu na obr. 4.3) nebo zda je umístěn v běžné síti. Řešení (i proces zneužití) by fungovalo analogicky - pouze v obráceném gardu než je znázorněno na obrázku.

Oddělení sítí pomocí ... zařízení

V této části rozebereme zbývající scénáře oddělení sítí, konkrétně scénáře 3 - 5. Všechny tyto scénáře jsou založeny na použití dedikovaných zařízení umožňujících filtrovat provoz mezi jednotlivými sítěmi. Pro řešení oddělení lze použít v zásadě:

- router,
- switch s funkcí správy,
- **firewall** (dedikovaný).

Schématicky je situace znázorněna na obr. 4.4. Na obr. je použit generický název *zařízení*. Umístění zařízení ve všech výše uvedených případech bude stejné, řešení se však bude lišit svou funkcí podle typu zařízení, které se v řešení použije.

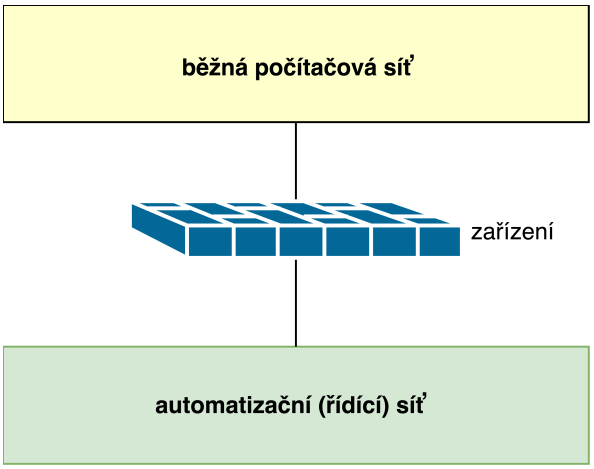

Obrázek 4.4: Oddělení sítí pomocí zařízení různých typů

Jednotlivá zařízení se zcela zásadně liší podle svých schopností - ty jsou definovány primárním účelem těchto zařízení.

Hlavní funkcí *routeru* je směřování síťového provozu a to primárně mezi jednotlivými sítěmi nebo segmenty sítě. Z tohoto pohledu se proto router nehodí pro řízení přístupu k jednotlivým zařízením. To samozřejmě neznamená, že router není schopen při směřování provozu jít až na úroveň jednotlivých zařízení, pouze že pro takovou činnost není optimalizován a pokud se používá tímto způsobem je potřeba architekturu sítě přizpůsobit. Takové řešení pak obvykle není nijak elegantní, špatně se udržuje a ještě hůře škáluje.

Podobná situace je se zařízeními typu *switch* - ty se starají primárně o funkci tzv. přepínání (switching) síťové komunikace. Zjednodušeně řešeno přeposílá síťovou komunikaci do cílových portů. V případě tzv. „spravovatelných“ switchů, s jejichž použitím v tomto scénáři počítáme, lze zasáhnout do konfigurace zařízení a ovlivnit způsob, jakým se toto přeposílání děje. V našem případě tedy specifikujeme, která zařízení spolu mohou komunikovat.

K tomu je však potřeba dodat, že switch pracuje na linkové vrstvě síťové architektury a proto nemá schopnost rozlišovat např. mezi jednotlivými službami. Povoluje se, popř. zakazuje tak komunikace identifikací IP adresy zařízení.

Ani router, ani switch tedy nejsou určeny primárně k filtraci síťového provozu - tento typ použití je tak pouze sekundární a lze jej použít tam, kde se nevyplatí (z různých důvodů) použití firewallu. Firewall oproti tomu je přímo určen k filtraci síťového provozu a proto práce s ním je v tomto směru podstatně jednodušší.

Filtraci je možné provést na úrovni jednotlivých zařízení (identifikovaných IP adresou) nebo rozsahu IP adres. Ovlivnit lze také síťové služby, které mohou v síti komunikovat (prostřednictvím specifikace síťových portů). Firewall je tak ze všech řešení, která jsem zmiňovali v této podkapitole prvním, které umožňuje zajistit kvalitně izolaci řídící sítě.

Podstatná otázka, kterou je potřeba dořešit je kam přesně umístit „sdílená zařízení“. Obr. 4.4 naznačuje dvě možnosti - buďto do sítě automatizační nebo běžné. V obou případech by řešení bylo podobné. Na firewallu by bylo nutné nastavit pravidla pro komunikaci s druhou sítí, zařízení by bylo

přístupné pak z vybraných (na firewallu povolených) zařízeních druhé sítě a všech zařízeních sítě, ve které je sdílené zařízení umístěno.

Zvažme ale řešení představené na obr. 4.5. V rámci tohoto řešení vyčleňujeme sdílená zařízení do *důvěryhodné zóny* a na firewallu řešíme komunikaci s oběma sítěmi. Tímto způsobem lze získat mnohem lepší kontrolu nad síťovým provozem adresovaným těmto zařízením a řídit jej.

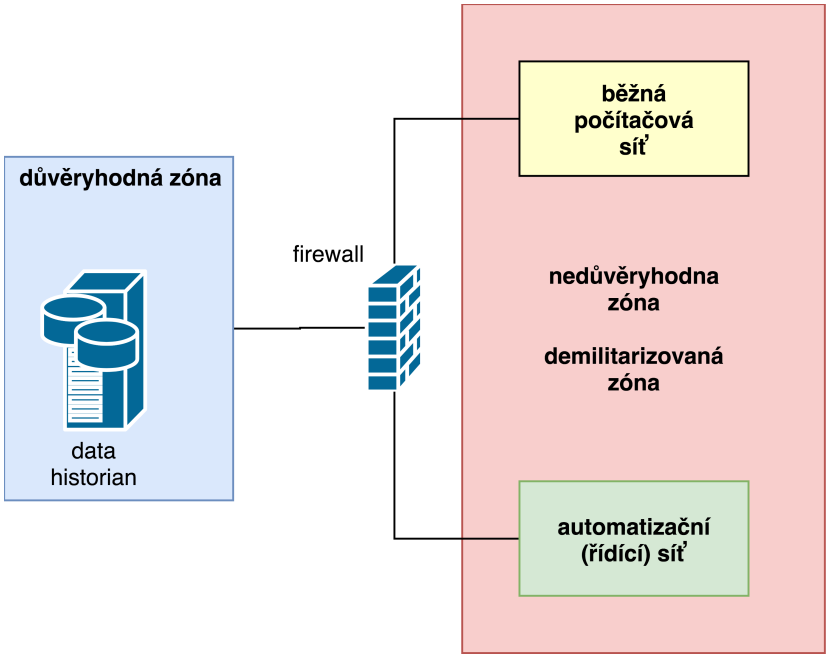

Obrázek 4.5: Důvěryhodná vs demilitarizovaná zóna

Řešení z obr. 4.5 předpokládá, že žádné ze sítí není možné bez výhrady věřit a z toho důvodu je žádoucí klíčová zařízení vyčlenit do důvěryhodné zóny a přesně stanovit nastavením pravidel firewallu, která zařízení s použitím kterých služeb mohou s nimi komunikovat. Zbývající zařízení uvnitř sítě jsou tedy považovány za nedůvěryhodná (potenciálně kompromitovaná). Někdy je zóna nedůvěryhodných zařízení označována jako demilitarizovaná zóna (DMZ).

Úvahy o DMZ nám umožňují jednak technicky oddělit obzvláště kritická zařízení od zbytku sítě, jednak mění způsob, kterým uvažujeme o zařízeních na síti. Ideově pracujeme s možností, že může dojít ke kompromitaci zařízení na síti a řešíme způsob, jak minimalizovat škodlivé následky takového průniku.

Zero trust network

Koncept DMZ položil základy odlišnému přístupu k bezpečnosti. Tradiční architektura bezpečnosti pracuje s perimetrem sítě. Vše, co je mimo tento perimetr je považováno za nebezpečené (nedůvěryhodné), vše co je uvnitř je pak považováno za důvěryhodné. Dlouhodobé zkušenosti ale ukazují, že tento přístup nezaručuje ve skutečnosti žádnou reálnou bezpečnost.

V posledních letech se proto prosazuje koncept zero trust network (popř. architecture), která je založena na tom, že zařízením na síti implicitně nevěříme - *zero trust = nulová důvěra*. Filozoficky proto se zařízeními pracujeme, jako by už z pohledu bezpečnosti byla kompromitována. Bezpečnostní opatření jsou pak navrhována tak, aby ani kompromitace takových zařízení nevedla k ohrožení důvěryhodnosti a dostupnosti informací, které jsou na síti zpracovávány.

Přesný popis principů tohoto přístupu ale svým rozsahem přesahuje možnosti tohoto textu. Podrobnosti o tomto přístupu můžete nalézt např. v knize Gilman a Barth [36].

U realizace oddělení sítí a zón jediným firewallem je potřeba mít na paměti, že toto řešení je

náchylné k selhání člověka při tvorbě pravidel. V ideálním případě by v situaci popsané na obr. 4.5 měla smysl komunikace pouze data historian ⟷ vybraná zařízení nebo data historian ⟷ vybraná zařízení v automatizační síti. Naopak smysl nemá přímá komunikace mezi běžnou a autentizační sítí.

Zkušenosti bohužel ukazují, že chybu je často poměrně jednoduché udělat, avšak její zpětné odhalení a odstranění je obtížně. Z tohoto důvodu můžeme uvažovat o alternativním řešení realizace důvěryhodné zóny realizované ne jedním ale dvěma firewally, viz obr. 4.6.

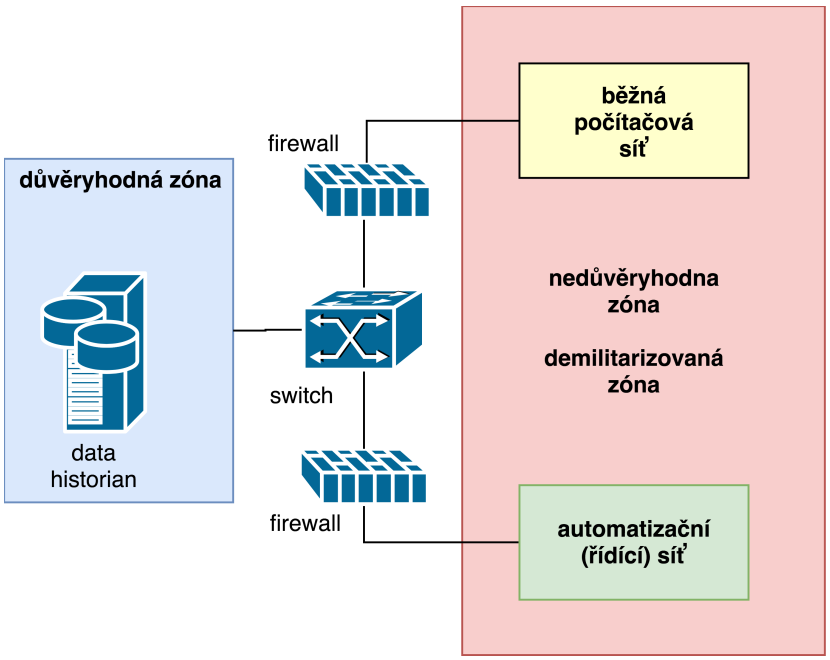

Obrázek 4.6: Důvěryhodná vs demilitarizovaná zóna - řešení s použitím dvojice firewallů

V řešení představeném na obr. 4.6 je pro každou síť použit samostatný firewall. Pravidla komunikace mezi sítěmi zůstávají stejná ve smyslu kdo s kým může komunikovat. Hledání chybných pravidel je ale v tomto případě podstatně snazší. Při řešením jedním firewallem existovala pravidla pracující s oběma sítěmi. V případě použití dvou firewallů ale taková pravidla existovat nemohou. Lze tak jednoduše (třeba i automatizovaně) testovat pravidla na přítomnost takových chyb.

Použitím dvou firewallů na druhou stranu přinášíme do systému určitý nový stupeň komplexity - místo jednoho firewallu musíme zpravovat dva, musíme to zaplatit ... získáme však řešení které je ale také poměrně odolné vůči selhání člověka při konfiguraci těchto zařízení. Aby síťová komunikace prošla mezi běžnou a automatizační sítí nestačí totiž udělat chybu při konfiguraci jednoho firewallu, ale obou firewallů - taková chyba je však mnohem méně pravděpodobná.

Tímto způsobem nebudou odhaleny všechny chyby v konfiguraci firewallů - lze ale takto detekovat chyby, které jsou z pohledu bezpečnosti nejzávažnější a jejich porušení poskytuje útočníkovi přímý vektor k napadení druhé sítě.

Nedá se říci, že by některé z výše uvedených řešení (snad s výjimkou použití firewallu na vnějším perimetru sítě) bylo skutečně univerzálně použitelné. Spíše platí, že čím rozsáhlejší, popř. cennější systém je potřeba chránit, tím sofistikovanější řešení se pro ochranu používají.

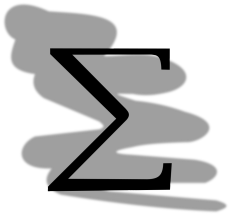

Shrnutí

Zajištění bezpečnosti automatizační sítě je poměrně složitá otázka. Zkušenosti z minulosti ukázaly, že ke kompromitaci těchto sítí může docházet náhodně vinou malware, který je primárně zaměřen na běžné počítače a sítě nebo projevem chyby v nastavení nebo v systému zařízení, byly však zaznamenány také příklady, kdy ke kompromitaci takové sítě došlo úmyslně s velkými finančními dopady na provozovatele napadeného systému.

Z hlediska ochrany je potřeba řešit zejména problematiku perimetru (okraje) organizace, resp. její počítačové sítě a to často včetně řešení fyzické bezpečnosti síťových uzlů zneužitelných pro neautorizované připojení k síti. Mezi řešené problémy patří zejména kontrola vstupu, management zařízení a médií vnášených a vynášených z areálu, kontrola pohybu a působení zaměstnanců třetích stran apod.

Velké části problémů lze také předcházet vhodným návrhem a realizací počítačové sítě. V popředí zájmu by především mělo být oddělení síťového provozu sítě určení pro řízení technologií. Způsobů jak takové oddělení realizovat je celá řada, avšak použití DMZ je považováno jako jedno z nejbezpečnějších.

Způsob oddělení je obvykle odvozen z velikosti/ceny a očekáváních stran bezpečnosti, které jsou na celý systém kladeny.

Kontrolní otázky

1. Co je Stuxnet?
2. Co je DMZ a jak přispívá k bezpečnosti?
3. Co rozumíme managementem médií?
4. Jaký je rozdíl mezi osobní a dedikovaným firewallem?
5. Co je dual home computer?

Správné odpovědi

1. Stuxnet je škodlivý kód napadající automatizační systémy společnosti Siemens (první takto navržený červ, fyzické zničení centrifug, ...)
2. Demilitarizovaná zóna - nedůvěryhodná zóna. V této zóně je provozována většina IT. Umožňuje nám lépe uvažovat o možných scénářích kompromitace sítě a minimalizace jejich následků na kritická zařízení umístěná v důvěryhodné zóně.
3. Rozumíme jím soubor opatření zaměřených na pečlivou kontrolu všech médií vstupujících a odnášených z areálu s cílem zamezit vnesení škodlivého kódu a vynesení citlivých informací.
4. Dedikovaný firewall umožňuje filtrovat síťový provoz na bázi protokolu TCP/IP, osobní k této funkcionalitě může obsahovat další komponenty jako např. HIPS, sandbox a další, ke své plnohodnotné funkci však potřebuje často interakci uživatele.
5. Jedná se o počítač s fyzicky realizovaným samostatným spojením do běžné a automatizační sítě - možno realizovat pro počítače které mají zpracovávat data udržována na těchto sítích.

Kapitola 5

Ochrana ICS

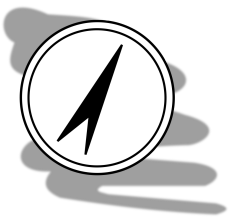

Náhled kapitoly
V této kapitole se zaměříme na podporu ochrany Industrial Control System (ICS) ze strany státu. Konkrétně se budeme zabývat v současnosti platnou legislativou, zejména pak zákonem o *Kybernetické bezpečnosti* a také funkcí různých typů CSIRT týmů.

Po přečtení této kapitoly budete vědět

1. jaká je funkce Computer Emergency Response Team (CERT) a Computer Security Incident Response Team (CSIRT)
2. co je to stav kybernetického nebezpečí
3. jaké jsou mezinárodní souvislosti řešení kybernetické bezpečnosti

Čas pro studium
Pro prostudování této kapitoly budete potřebovat přibližně dvě hodiny.

V minulé kapitole jsem zejména s některými zaznamenanými incidenty v oblasti kritické infrastruktury pracovali s možností, že za realizací alespoň některých z těchto útoků mohou být buď přímo státy nebo mohou být státy sponzorované. Vzhledem k tomu, že infrastruktura samotná je většinou v soukromých rukou, vzniká nepoměr v dostupných zdrojích z hlediska možnosti financovat útok na infrastruktury na straně jedné a na druhé straně pak možnosti obrany proti takovým útokům.

Z praktických důvodů nemohou ponechat státy systémy kritické infrastruktury zcela, alespoň z hlediska ochrany, na libovůli vlastníka, popř. provozovatele. Různé státy ale podpůrné ochranné aktivity organizují různě. V následujících podkapitolách se proto zaměříme na některá používaná řešení, jejich možnosti, výhody a nevýhody.

5.1 Typy CERT a CSIRT

CERT je označení týmů určených k reakci na počítačové hrozby. První CERT tým vznikl v roce 1988 na univerzitě Carnegie Mellon pod názvem CERT-CC (CERT Coordination Center). Jeho zaměření bylo poskytováni pomoci při problémech s IT.

IT v roce 1988 bylo ale velmi odlišné od IT, se kterým pracujeme dnes. Většina počítačů bylo lokálních často bez připojení do sítě, Internet neexistoval, malware existoval, ale nebyl tak rozšířen jako dnes, zařízení jako chytré telefony ovládané pomocí dotykového rozhraní byly futuristickou vizí která se objevovala ve sci-fi filmech a seriálech (např. Star Trek: Nová generace a další).

Hlavní aktivitou tohoto týmů tak byla obecná podpora uživatelům. Podobný přístup a také označení takových týmů bylo později přejímáno také jinými organizacemi. Řada z nich se ale rozhodla nepoužít pro tým označení CERT, ale CSIRT.

CSIRT - česky Tým pro reakce na počítačové bezpečnostní incidenty. Takové označení je podstatně specifičtější než CERT - indikuje zaměření týmu nikoliv na problémy běžné podpory uživatelů IT, ale na řešení problémů spojených s bezpečností.

K této transformaci došlo zejména v souvislosti s masifikací použití prostředků IT (dnes jsou počítače běžnou každodenní součástí života většiny obyvatelstva a to jak v rovině pracovní, tak v rovině osobní) a také změnám povahy hrozeb.

Rozvoj Internetu jako univerzální, celosvětové platformy pro sdílení informací sice na jedné straně otevřelo firmám i jednotlivcům netušené možnosti, na straně druhé obdobné možnosti přinesla také lidem, kteří by takové možnosti chtěli zneužít pro vlastní prospěch - hackerům samotářům, nebo zločineckým syndikátům.

Dobře je situace viditelná na příkladu malware. Ještě v 90. letech bylo hlavní motivací tvůrců buď vlastní pobavení nebo demonstrace vlastní technologické nadřazenosti. S postupem času se ale situace změnila a proto dnes je hlavním cílem tvůrců vlastní prospěch ať už formou finanční (např. ransomware), nepřímé finanční (kompromitace počítačů za účelem realizace útoků DoS, rozesílání spamu za úplatu), zcizení osobních nebo firemních informací, které je možno zpeněžit na černém trhu.

Většina společností soudí, že specializovaný tým (CSIRT) by se tak měl zaměřovat především na oblast bezpečnosti - kde jsou vyžadovány specifické znalosti, popř. nástroje, které je výhodné soustředit na jedno místo - do týmu CSIRT. Běžná podpora uživatelů by pak měla být doménou oddělení IT.

Bezpečnostní incident vs mimořádná události

Všimněte si používané terminologie. V souvislosti s bezpečností IT používáme pojem *bezpečnostní incident*, nikoliv pojem *mimořádná událost*, se kterým jste se dosud v průběhu studia setkávali. Rozdíl je poměrně důležitý - mimořádnou událost definuje zákon o integrovaném záchranném systému [5] jako *škodlivé působení sil a jevů vyvolaných činností člověka, přírodními vlivy, a také havárie, které ohrožují život, zdraví, majetek nebo životní prostředí a vyžadují provedení záchranných a likvidačních prací.*

Bezpečnostní incident je ze své povahy jiný - jedná se o jakékoliv z hlediska organizace významné narušení činnosti v její IT infrastruktuře. Může se tak jednat o kompromitaci počítačů malware, únik citlivých informací, masivní útok na infrastrukturu organizace apod. V žádném z výše uvedených scénářů však není vyžadováno provádění záchranných a likvidačních prací ze strany jednotlivých složek IZS.

Za určitých okolností může ale bezpečnostní incident přerůst do mimořádné události - např. ve formě dálkového útoku na technologii vedoucí k uvolnění nebezpečné látky do prostoru ...

Z hlediska fungování lze takové týmy organizovat různě. Např. výše uvedený CERT-CC je typickým představitelem podnikových CERT/CSIRT týmů. Tyto týmy působí v organizaci a řeší problémy dané organizace. To však není jediná úroveň, na které mohou tyto týmy pracovat.

Řada států realizuje tzv. národní a vládní CERT týmy. V případě české republiky plní funkci národního CERT týmu tým CSIRT.CZ [29], funkci vládního CERT týmu plní pak GovCERT.CZ [61].

Tým CSIRT.CZ byl zřízen v roce 2010 na základě memoranda mezi Ministerstvem vnitra ČR a sdružení CZ.NIC, jako provozovatelem týmu. V roce 2011 pak byla podepsána smlouva mezi CZ.NIC a Národním bezpečnostním úřadem, který se stal gestorem problematiky kybernetické bezpečnosti.

Funkce národního CERT týmu se soutěží. Poslední soutěž proběhla v roce 2015. Smlouva na provoz národního CERT týmu byla uzavřena na dobu neurčitou.

Pro úplnost v rámci národního týmu v současnosti působí 8 zaměstnanců.

Poznámka:

Všimněte si používání pojmů CERT a CSIRT. Ve výše uvedeném textu se může zdát, že jsou zaměňovány a v praxi se tomu tak skutečně děje. Např. v obecné rovině se často hovoří o vrcholových CSIRT týmech, popř. národních a vládních CSIRT týmech.

Při probírání této problematiky v podmínkách ČR je však v souvislosti s provozem národního a vládního týmu potřeba respektovat dikci zákona o kybernetické bezpečnosti [4], který explicitně hovoří o národním CERT týmu a vládním CERT týmu.

Hlavní cíle CSIRT.CZ jsou následující [29]:

- Udržování zahraničních vztahů - se světovou komunitou CERT/CSIRT týmů a organizacemi, které tuto komunitu podporují.
- Spolupráce se subjekty v rámci ČR - ISP, poskytovateli obsahu, bankami, bezpečnostními složkami, akademickým sektorem, úřady státní správy a dalšími institucemi.
- Poskytování služeb v oblasti bezpečnosti
  - Řešení a koordinace řešení bezpečnostních incidentů
  - Osvětová a školící činnost
  - Proaktivní služby v oblasti bezpečnosti

K těmto činnostem je tým vybaven poměrně dobře také díky svému provozovateli - sdružení CZ.NIC, které je správcem domény CZ. CZ.NIC tedy provozuje registr domén, registrovaných pod doménou CZ a zabezpečuje provoz domény nejvyšší úrovně .CZ. Má tedy k dispozici potřebné informace o sítích (doménách) provozovaných v ČR stejně jako mechanismy kontaktu jejich správců.

Právě zprostředkování kontaktů provozovatelů sítí je jedním z nejúčinnějších nástrojů jak řešit např. útoky. Např. pokud na síť organizace je veden útok z jiné sítě, je možné často síť, ze které byl útok veden identifikovat. Mezi provozovateli jednotlivých sítí ale obvykle není realizován přímý kontakt, který by umožnil problémy řešit operativně.

Národní CERT tak slouží jako ověřený/důvěryhodný kontaktní bod, který potřebné informace může zprostředkovat.

Vzhledem k tomu, že útoky nemusí přicházet pouze ze sítí provozovaných v ČR, je nutná také mezinárodní spolupráce. Důvěryhodnost je v tomto případě zaručena členstvím (akreditací) v mezinárodních uskupeních zaměřených právě na provoz CERT/CSIRT týmů.

Konkrétně se jedná o sdružení Trusted Introducer (TI) [38] a FIRST [35]. TI bylo zřízeno v roce 2000 evropskou komunitou CERT a CSIRT týmů [38]: *za účelem řešení společných potřeb a budování infrastruktury, která by poskytovala důležitou podporu všem bezpečnostním týmům, zaměřeným na řešení a řízení bezpečnostních incidentů.*

Jednotlivé týmy se do TI akreditují. Po akreditaci pak mají k dispozici některé služby především pak [38]:

- seznam týmů s potřebnými dodatečnými informacemi (např. kontaktními)
- zabezpečný mailing list
- možnost účastnit se porad, konferencí, školení organizovaných TI
- a některé další.

Forum of Incident Response and Security Teams (FIRST) sdružuje důvěryhodné CERT a CSIRT týmy spolupracující na řešení bezpečnostních incidentů a propagující programy jejich prevence. Z hlavních činností [35]:

- členové vyvíjejí a sdílejí technické informace, nástroje, metodologie, procesy a nejlepší postupy
- podporuje vývoj kvalitních produktů v oblasti bezpečnosti, politik a služeb
- vyvíjí a zveřejňuje nejlepší postupy v oblasti počítačové bezpečnosti
- podporuje vznik a rozvoj týmů reakce na incidenty a členství organizací ze všech koutů světa
- členové používají své kombinované znalosti, schopnosti a zkušenosti k podpoře bezpečnějšího globálního elektronického prostředí

Zvláštní postavení v této oblasti má také European Union Agency for Network and Information Security (ENISA) [32], česky Evropská agentura pro bezpečnost sítí a informací. Jedná se o agenturu Evropské unie zřízeného na základě Nařízení Evropského parlamentu a Rady (ES) č. 460/2004 o zřízení Evropské agentury pro bezpečnost sítí a informací. V současnosti je provoz této agentury regulován Nařízením Evropského parlamentu a Rady (ES) č. 526/2013 o Agentuře Evropské unie pro bezpečnost sítí a informací (ENISA) a o zrušení nařízení (ES) č. 460/2004.

Nařízení [33] definuje úkoly ENISy následovně:

1. podporuje rozvoj politiky a práva Unie (poradenství, analýzy a přípravné práce v oblasti bezpečnosti sítí a informací)

2. podporuje rozvoj schopností (podporuje dobrovolnou spolupráci mezi státy, zdokonalování prevence, odhalování a analýzy problémů a incidentů v oblasti bezpečnosti sítí a informací a schopnost na ně reagovat)
3. zajišťuje fungování skupiny pro reakci na počítačové hrozby (CERT) ... na úrovni Evropské unie.
4. zajišťuje fungování skupiny pro reakci na počítačové hrozby (CERT), organizuje cvičení
5. podporuje rozvíjení mechanismu včasného varování Unie
6. podporuje vývoj a výzkum a normalizaci evropských a mezinárodních norem pro řízení rizik a pro bezpečnost elektronických produktů, sítí a služeb
7. výměna know-how a poskytování poradenství s orgány, institucemi a jinými subjekty Unie, včetně těch, které se zabývají počítačovou kriminalitou a ochranou soukromí a osobních údajů, s cílem řešit otázky společného zájmu

Z hlediska fungování je zajímavé, že existence agentury není neomezená - její fungování je v pravidelných intervalech přehodnocováno, což může vést k poměrně razantním změnám nebo dokonce zrušení agentury. Tento proces byl změněn až v roce 2019, kdy ENISA získala permanentní pozici v oblasti kybernetické bezpečnosti Nařízením Evropského parlamentu a rady 2019/881 [19].

Nařízení mění postavení ENISY jako vrcholového CERT týmu pracujícího na úrovní EU jako celku. Nově pak má specifikovány některé další úlohy (nad rámec úloh specifikovaných ve výše uvedeném seznamu), především směrem k:

- rozvíjení a aktualizaci strategií pro bezpečnost sítí a IS na úrovni EU a členských států, pokud o to požádají,
- podněcování spolupráce mezi veřejným a soukromým sektorem a v rámci soukromého sektoru, zejména za účelem podpory ochrany kritických infrastruktur,
- agregaci a analýze dobrovolně sdílených vnitrostátních zpráv od týmů CSIRT a interinstitucionálních týmů pro reakci na počítačové hrozby pro orgány, instituce a jiné subjekty EU.
- V případě rozsáhlých přeshraničních incidentů a krizí v oblasti kybernetické bezpečnosti by agentura ENISA měla přispět k reakci na úrovni.
- a řada dalších.

Nejdůležitějším novým úkolem, který není specifikován v seznamu výše je vytvoření a udržování *certifikačního rámce kyberbezpečnosti EU*. Tyto certifikace by měly osvědčit, že produkty a služby certifikované podle takových schémat splňují specifikované požadavky na kybernetickou bezpečnost.

V současnosti je totiž tato problematika řešena pomocí mezinárodní dohody SOG-IS, jejíž poslední verze je z roku 2010 [11]. Tato dohoda si kladla za cíl poskytnout vysokou úroveň důvěry ve spolehlivost a také konzistence hodnocení certifikací probíhajících podle standardů InformationTechnology Security Evaluation Criteria (ITSEC) a Common Criteria (CC). Nevýhodou tohoto standardu bylo, že byl schválen pouze 14-ti členských států EU a Norska. Přitom např. Česká republika není signatářem této dohody (pro zajímavost ale Slovensko signatářem je).

Sjednotit přístup k certifikaci by měl certifikační schéma European Cybersecurity Certification Scheme (EUCC). Toto schéma již nepracuje s rychle zastarávajícím standardem ITSEC, místo toho se exkluzivně věnuje CC (odtud také název). Schéma je již koncipován jako standard, nikoliv jako mezinárodní dohoda, což by mělo zjednodušit certifikaci a možnost nasazování produktů takovou certifikaci vyžadující v rámci jednotného trhu EU. Zvolená forma schématu pak umožňuje pokrýt celý trh najednou, což v minulosti nebylo možné.

EUCC bylo vydáno v polovině roku 2020 k veřejným konzultacím, kdy k textu schématu se mohou vyjádřit jak představitelé členských států, tak představitelé různých profesních uskupení, výrobců hardware, akademické sféry, bezpečnostních expertů nebo jinak zainteresovaných jednotlivců nebo skupin občanů. Připomínky bylo možné zasílat do konce července 2020. V současnosti (září 2020) pak stále probíhá zpracování přijatých připomínek.

Zatím pak není jasné, zda toto kolo veřejných konzultací bude poslední a tak je obtížné odhadovat kdy bude vydáno finální schéma. Realisticky lze očekávat, že se tak stane někdy v roce 2021.

GovCERT.CZ má za sebou poměrně krátkou, avšak pestrou minulost. Původně GovCERT.CZ provozoval Národní bezpečnostní úřad (NBÚ) v rámci Národní centrum kybernetické bezpečnosti (NCKB) (od roku 2011). V roce 2017, ale došlo k transformaci NCKB do formy samostatného správního úřadu Národní úřad pro kybernetickou a informační bezpečnost (NÚKIB).

Původní NCKB vznikl na základě usnesení vlády č. 781 o ustavení Národního bezpečnostního úřadu gestorem problematiky kybernetické bezpečnosti (říjen 2011). V té době však neexistoval právní ráme,

který by centru dával pravomoci. Tyto byly doplněny až v roce 2014, kdy vešel v platnost zákon o kybernetické bezpečnosti, který už formálně definoval postavení vládního CERT týmu a svěřoval mu některé pravomoci.

K hlavní náplni práce NÚKIB patří [59]:

- provozovat Vládní CERT České republiky (GovCERT.CZ)
- spolupráce s ostatními národními a mezinárodními CERT a CSIRT týmy
- příprava bezpečnostních standardů pro informační systémy Kritické informační infrastruktury (KII) a Veřejných informačních systémů (VIS)
- osvěta a podpora vzdělávání v oblasti kybernetické bezpečnosti
- výzkum a vývoj v oblasti kybernetické bezpečnosti
- ochrana utajovaných informací v oblasti informačních komunikačních systémů
- kryptografická ochrana

Úkoly NÚKIB jsou tedy poměrně rozsáhlé, jaké úlohy však plní GovCERT.CZ? Odpověď lze nalézt na webových stránkách organizace [60]:

- koordinační činnost a pomoc při řešení incidentů
- zprostředkování kontaktů
- informační hub pro zveřejňování informací, analýz, článků apod. týkajících se aktuálních hrozeb
- sdílení dat o potenciálně infikovaných strojích v ČR
- nasazování honeypotů
- penetrační testování (v současnosti primárně zaměřeno na bezpečnost webových stránek)
- vzdělávací a výzkumná činnost
- forenzní laboratoř a SCADA laboratoř

Jak je vidno z přehledu výše jsou některé zajišťované činnosti totožné z činnostmi které provádí národní CERT tým - jedná se zejména o koordinační činnosti, prostředkování kontaktů a zveřejňování bezpečnostně orientovaných informací především na webových stránkách instituce.

Vládní CERT tým, resp. NÚKIB jako takový disponuje ale mnohem většími zdroji, proto má kapacity v případě potřeby poskytnout také aktivní pomoc. Tato pomoc však je primárně určena především povinným osobám podle zákona o kybernetické bezpečnosti.

Zajímavé schopnosti představují informace zachycené z C&C (Command and Control) serverů různých botnetů, které obsahují seznamy kompromitovaných zařízení na síti, které do daného botnetu byly přiřazeny. Na základě takto získaných IP adres lze identifikovat sítě, ve kterých se taková zařízení nachází a kontaktovat jejich provozovatele.

Provozovatelé by se jinak k takovým informacím sami nedostali.

Dalším zdroj informací představují tzv. *honeypoty*. Jedná se o většinou servery, které jsou nakonfigurovány jako běžné servery (např. databázové, ale i jiné), které však neobsahují reálná data. Jedná se pouze o uměle vytvořený cíl pro případné útočníky. Vzhledem k tomu, že v tomto případě není důvod, aby se k serveru někdo reálně připojoval, budou všechna připojení spojena s různými útoky. Tak lze jednoduše identifikovat problémový síťový provoz a studovat mechaniku provedeného útoku.

Informace tohoto typu jsou cenné pro návrh a testování ochranných opatření.

Velmi důležitý je provoz forenzních laboratoří a laboratoře SCADA. Forenzní laboratoře umožňují analyzovat kompromitovaná zařízení v kontrolovaných podmínkách. Takto získaná zjištění jsou pak použitelná i v případném vyšetřování Policie ČR apod.

SCADA laboratoře jsou v podmínkách ČR nové. Jejich význam ale nesporný, umožňují totiž v kontrolovaných podmínkách testovat vlastnosti kontrolních systémů, což je nesmírně důležité např. pro ochranu kritické infrastruktury. Obdobné laboratoře budují dnes prakticky všechny rozvinuté státy.

Prostřednictvím ENISA je pak uvažováno o vytvoření obdobné laboratoře na úrovni EU jako celku.

5.2 Legislativa kybernetické bezpečnosti

Zákon o kybernetické bezpečnosti (181/2014 Sb. [4]) vešel v platnost 1. 1. 2015. Během svého relativně krátkého života však již byl jednou poměrně významně novelizován (v roce 2017) v souvislosti se vstupem do platnosti Směrnice EU 2016/1148 o opatřeních k zajištění vysoké společné úrovně bezpečnosti sítí a informačních systémů v Unii [14] (tzv. Směrnice NIS).

Primárním účelem směrnice NIS bylo sjednotit úroveň bezpečnosti sítí v EU, která byla dosud realizována různými státy na velmi odlišné úrovni. Většina opatření vyžadovaných směrnicí NIS byla již obsažena v původním zákonu o kybernetické bezpečnosti. Novela proto pouze rozšířila okruh povinných osob a také řešila některé další věci, které ale nebyly směrnicí vyžadovány, např. vnik správního úřadu NÚKIB.

Předtím než začneme rozebírat samotný zákon podívejme se na celkové legislativní řešení kybernetické bezpečnosti. Její základ tvoří *zákon o kybernetické bezpečnosti*. Kromě něj existuje i řada dalších prováděcí vyhlášek, popř. dalších sovisejících vyhlášek a nařízení vlády:

- Vyhláška č. 82/2018 Sb. o bezpečnostních opatřeních, kybernetických bezpečnostních incidentech, reaktivních opatřeních, náležitostech podání v oblasti kybernetické bezpečnosti a likvidaci dat (vyhláška o kybernetické bezpečnosti) [18]
- Vyhláška č. 317/2014 Sb. o významných informačních systémech a jejich určujících kritériích [13]
- Vyhláška č. 437/2017 Sb., o kritériích pro určení provozovatele základní služby [15]

Zákon o kybernetické bezpečnosti

Zákon 181/2014 Sb. o kybernetické bezpečnosti řeší řadu problémů, které postupně budeme rozebírat. Zde je potřeba upozornit také návaznost na další prováděcí předpisy k zákonu, které probíranou problematiku dále rozvádějí. Některé z těchto předpisů jsou stručně popsány také v těchto skriptech.

Prvním problémem jsou tzv. *významné informační systémy*. ty jsou definovány zákonem (§2 písm. d): informační systém spravovaný orgánem veřejné moci, který není kritickou informační infrastrukturou a u kterého narušení bezpečnosti informací může omezit nebo výrazně ohrozit výkon působnosti orgánu veřejné moci.

Pro pochopení toho, co přesně výše uvedené znamená je potřeba definovat další pojem a to *Kritická informační infrastruktura (KII)*. Ta je definována následovně (§2, písm g): prvek nebo systém prvků kritické infrastruktury v odvětví komunikační a informační systémy v oblasti kybernetické bezpečnosti.

KII je tedy řešena jako kritická infrastruktura, včetně určování dle Nařízení vlády 432/2010 Sb., významný informační systém se ale určuje podle vyhlášky 317/2014 Sb.

Laicky je možno si to zdůvodnit tak, že kritická infrastruktura je realizována nějakým fyzickým prvkem, oproti tomu informační systém je software. Software sice běží na nějakém hardware, ale lze jej v případě potřeby relativně jednoduše přesouvat. Řídící systémy, SCADA, síťovou infrastrukturu, které řadíme do KII, ale takto přesouvat nelze.

Zákon stanovuje okruh osob, kterým ukládá povinnosti v oblasti kybernetické bezpečnosti:

a) poskytovatel služby elektronických komunikací a subjekt zajišťující síť elektronických komunikací, pokud není orgánem nebo osobou podle písmene b),
b) orgán nebo osoba zajišťující významnou síť, pokud nejsou správcem nebo provozovatelem komunikačního systému podle písmene d),
c) správce a provozovatel informačního systému kritické informační infrastruktury,
d) správce a provozovatel komunikačního systému kritické informační infrastruktury,
e) správce a provozovatel významného informačního systému,
f) správce a provozovatel informačního systému základní služby, pokud nejsou správcem nebo provozovatelem podle písmene c) nebo d),
g) provozovatel základní služby, pokud není správcem nebo provozovatelem podle písmene f), a
h) poskytovatel digitální služby.

S některými pojmy jsme se již seznámili (významný informační systém a KII), zaměřme se proto na pojmy zbývající.

Službami elektronických komunikací definuje zákon o elektronických komunikacích [8] (§2 písm. n) jako služby obvykle poskytovaná za úplatu, která spočívá zcela nebo převážně v přenosu signálů po sítích elektronických komunikací, včetně telekomunikačních služeb a přenosových služeb v sítích používaných pro rozhlasové a televizní vysílání a v sítích kabelové televize, s výjimkou služeb, které nabízejí obsah prostřednictvím sítí a služeb elektronických komunikací nebo vykonávají redakční dohled nad obsahem přenášeným sítěmi a poskytovaným službami elektronických komunikací; nezahrnuje služby informační společnosti, které nespočívají zcela nebo převážně v přenosu signálů po sítích elektronických komunikací.

Taková definice pokrývá celou škálu provozovatelů různých sítí - od televizních a rozhlasových sítí, až po sítě např. operátorů mobilních sítí.

Pojmem *významná síť* se rozumí sítě zajišťující přímé zahraniční propojení do veřejných komunikačních sítí nebo zajišťující přímé připojení ke kritické informační infrastruktuře. Do této skupiny

tak spadají tzv. páteřní sítě, ale také samostatné sítě zajišťující řízení kritické infrastruktury. Takové sítě jsou typické např. pro odvětví energetiky budující rozsáhlé sítě produktovodů (zemní plyn, ropa) apod.

Základní službou se rozumí služba závislá na sítích elektronických komunikací, popř. informačních systémech a jejíž narušení by mohlo mít významné dopady na zabezpečení společenských nebo ekonomických činností v některém z odvětví:

1. energetika,
2. doprava,
3. bankovnictví,
4. infrastruktura finančních trhů,
5. zdravotnictví,
6. vodní hospodářství,
7. digitální infrastruktura,
8. chemický průmysl,

Výše uvedený seznam by Vám neměl být neznámý - jedná se více méně o přehled odvětví kritické infrastruktury. Kritéria pro určení provozovatelů základních služeb jsou specifikována ve vyhlášce 437/2017 Sb.

Konečně digitální službu se rozumí vybraná skupina služba informační společnosti [7] zaměřená na provoz on-line tržišť, internetových vyhledávačů a tzv. cloud computingu (ať už ve smyslu výpočetních zdrojů v cloudu nebo úložného prostoru).

Právě oblast digitálních služeb do zákona byla přidána teprve na základě požadavků směrnice NIS. Vycházelo se přitom z toho, že „v cloudu“ je v současnosti provozováno velké množství systémů provozovaných osobami uvedenými v seznamu povinných osob (a) - e), provozovatelé cloudové infrastruktury však dlouho regulováni nebyli.

Nová pravidla proto specifikují některé náležitosti, na které při využívání takových služeb musí povinné osoby musí brát zřetel. Jedná se např. o Service Level Assurance (SLA) - dohodě o úrovni poskytovaných služeb, podmínek bezpečnosti provozu apod.

Povinné osoby musí pro bezpečný provoz regulovaných systémů realizovat tzv. *bezpečnostní opatření*. Tato opatření jsou buďto organizační nebo technická.

Do *organizačních opatření* řadíme systém řízení bezpečnosti, rizik, bezpečnostní politiky, řízení lidských zdrojů apod. Jedná se tedy opatření, která je nutno implementovat ve způsobu fungování organizace. Ze své povahy je ale realizace plných účinků těchto opatření dlouhodobější záležitostí. Zavedení plnohodnotného nového systému řízení bezpečnosti může trvat měsíce a pokud organizace pracuje s obzvláště rozsáhlých nebo složitými systémy může trvat i let několik.

Technickými opatřeními jsou opatření vedoucí ke zvýšení bezpečnosti v organizaci. I charakter těchto opatření může být velmi různorodý od úpravy způsobu jakým funguje ostraha objektů organizace až po zavádění sofistikovaných nástrojů pro detekci bezpečnostních incidentů apod.

Podrobnosti o struktuře bezpečnostní dokumentace stanovuje vyhláška 82/2018 Sb. o kybernetické bezpečnosti [18]. Postup podle tohoto předpisu je povinný pro osoby c) - f) z okruhu osob.

Osoby b) - f) mají taktéž povinnost ze zákona detekovat kybernetické bezpečnostní události. Pojem *kybernetická bezpečnostní událost* je pro vás nový. Zákon totiž rozlišuje mezi těmito událostí a kybernetickými bezpečnostními incidenty.

Kybernetickou bezpečnostní událostí je dle zákona událost, která může způsobit narušení bezpečnosti informací v informačních systémech nebo narušení bezpečnosti služeb anebo bezpečnosti a integrity sítí elektronických komunikací.

Oproti tomu *kybernetickým bezpečnostním incidentem* je dle zákona narušení bezpečnosti informací v informačních systémech nebo narušení bezpečnosti služeb anebo bezpečnosti a integrity sítí elektronických komunikací v důsledku kybernetické bezpečnostní události.

Jaký je tedy rozdíl mezi událostí a incidentem. Událostí může být např. pokud neutorizovaně přistoupit k citlivým datům významného informačního systému. Incidentem v tomto kontextu může být v případě úspěchu takového přístupu získání citlivých dat z takového systému.

Prakticky vzato většina útoků na systémy organizací není úspěšná. Zákon, ale pro specifikované okruhy osob ukládá povinnost detekce událostí. Není přípustné tedy u takových systémů pouze reagovat na incidenty.

Pokud už k bezpečnostnímu incidentu dojde mají osoby b) - f) povinnost hlášení takových incidentů, liší se ale komu má být incident hlášen.

V případě dopadů na základní služby musí být hlášen incident přímo NÚKIB. Podobně incidenty týkající se KII nebo významných systémů (osoby c) - f) incidenty hlásí NÚKIB. Provozovatelé významných sítí (b) a digitálních služeb (h) hlásí incidenty národnímu CERT týmu.

Úřad je také oprávněn ukládat opatření okruhu osob za určitých podmínek. Opatření jsou rozlišována na:

- varování
- reaktivní opatření
- ochranná opatření

Varování může úřad vydávat bez omezení. Reaktivní a ochranná opatření se ale v plném rozsahu vztahují pouze na provozovatele významných systémů a systémů KII (osoby c) - f). Osobám a), b) pak může Úřad ukládat opatření pouze v případě že je vyhlášen stav kybernetického nebezpečí nebo některých nouzových stavů.

Úřad naopak nemůže ukládat opatření provozovatelům digitálních služeb.

Vraťme se ke *stavu kybernetického nebezpečí*. Rozumí se jím stav, ve kterém je ve velkém rozsahu ohrožena bezpečnost informací v informačních systémech nebo bezpečnost služeb elektronických komunikací anebo bezpečnost a integrita sítí elektronických komunikací, a tím by mohlo dojít k porušení nebo došlo k ohrožení zájmu České republiky ve smyslu zákona upravujícího ochranu utajovaných informací [9].

Základním zájmem dle zákona o ochraně utajovaných informací a o bezpečnostní způsobilosti je zachování ústavnosti, svrchovanosti a územní celistvosti, zajištění vnitřního pořádku a bezpečnosti, mezinárodních závazků a obrany, ochrana ekonomiky a ochrana života nebo zdraví fyzických osob.

Stav kybernetického nebezpečí
Z dalších předmětů by Vám měly být známy ostatní *nouzové stavy*, jako jsou?

Pro úplnost stav kybernetického nebezpečí vyhlašuje ředitel NÚKIB vyvěšením na úřední desce Úřadu. Informace o vyhlášení se také zveřejňuje v celoplošném rozhlasovém a televizním vysílání. Stav se vyhlašuje na dobu nezbytně nutnou, nejdéle však na sedm dní. Tuto dobu lze ale prodlužovat a to i opakovaně. Celková doba trvání stavu kybernetického nebezpečí však nesmí být delší než 30 dní.

V průběhu vyhlášeného stavu pak Úřad informuje vládu o přijatých krocích k řešení příčiny/aktuálním stavu hrozby, která vedla k vyhlášení stavu kybernetického nebezpečí.

Vyhláška o kybernetické bezpečnosti
Vyhláška 82/2018 Sb. upravuje především:

- obsah a strukturu bezpečnostní dokumentace,
- obsah a rozsah bezpečnostních opatření,
- typy, kategorie a hodnocení významnosti kybernetických bezpečnostních incidentů,
- náležitosti a způsob hlášení kybernetického bezpečnostního incidentu,
- náležitosti oznámení o provedení reaktivního opatření a jeho výsledku,
- vzor oznámení kontaktních údajů a jeho formu a
- způsob likvidace dat, provozních údajů, informací a jejich kopií.

Vyhláška je prováděcím předpisem zákona o kybernetické bezpečnosti. Zákon (tak jak je obvyklé), ale specifikuje pouze že má být vedena bezpečnostní dokumentace, avšak nikoliv v jakém rozsahu nebo struktuře. Právě tyto otázky pak řeší vyhláška.

Předepsána jsou také organizační struktury, které by s ohledem na řízení kybernetické bezpečnosti povinné osoby měly být realizovány - např. role managera, architekta, autora kybernetické bezpečnosti a existence výboru pro řízení kybernetické bezpečnosti.

Svou organizací filozoficky vyhláška vychází z doporučení kodexu norem ISO 27000 zaměřených na řešení tzv. Information Security Management System (ISMS).

Vyhláška o významných informačních systémech a jejich určujících kritériích
Vyhláška 317/2014 Sb. řeší kritéria, podle kterých se určující kritéria významné informační systémy.

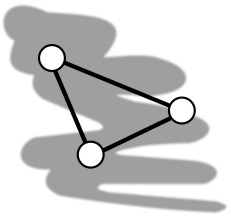

ISO 27000
Kodex norem ISO 27000 obsahuje v současnosti několik desítek norem, základ ale tvoří tři řešící:

- ISO 27001 [1] - systém ISMS
- ISO 27002 [2] - nejlepších praktik z oblasti bezpečnosti informací
- ISO 27005 [6] - rizika

V tomto předmětu není prostor se touto problematikou zabývat ve větší míře, proto v případném studiu můžete pokračovat buďto samostatně nebo v rámci předmětu *Bezpečnosti informačních systémů*.

Takové systémy musí jejich provozovatel ze zákona lépe chránit. Určující kritéria se člení na *dopadová* a oblastní kritéria.

Svou dikcí, Vám možná výše uvedený odstavec něco připomene - třeba průřezová a odvětvová kritéria pro určování prvků kritické infrastruktury dle nařízení vlády 432/2010 [12].

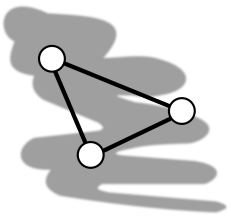

Kritická infrastruktura
S problematikou kritické infrastruktury se můžete seznámit blíže v předmětu *Ochrana kritické infrastruktury*. Při studiu nezapomeňte, že kritická infrastruktura má svůj informatický rozměr.

Dopadová kritéria hodnotí dopady úplné nebo částečné nefunkčnosti systému způsobené narušením bezpečnosti. Hodnotí se přitom dopady na provozovatele, případně poskytování služby nebo informací orgány veřejné moci nebo další dopady mimo samotný systém. Spektrum takovým dopadů je poměrně různorodé - může se jednat o narušení prvku kritické infrastruktury, počítat lze také se ztrátami na životech, zdraví, majetku nebo obecně veřejných zájmů.

Oblastní určující kritéria se rozlišují podle provozovatele systému a to orgány veřejné moci a pak také orgány veřejné moci - kraje v přenesené působnosti. Jedná se především o schopnost vést správní řízení, vykovávat státní dozor, hospodařit, spravovat osobní údaje a další.

Úplný přehled oblastních kritérií je specifikován v příloze 2 vyhlášky.

Vyhláška obsahuje také seznam již určených významných informačních systémů a to konkrétně v příloze 1 vyhlášky. Seznam v současnosti (IX. 2018) obsahuje 153 významných informačních systémů. Ve vyhlášce je evidováno pořadové číslo systému, jeho provozovatel a název.

Významné informační systémyvs informační systémy veřejné správy
Prosím neplést tyto pojmy. Informační Systém Veřejné Správy (ISVS) jsou souborem informačních systémů, které slouží pro výkon veřejné správy. Jejich pořizování a provoz se řídí zákonem 365/2000 Sb. o ISVS [3] a jeho prováděcími vyhláškami. V ČR je v současnosti provozováno dle Informačního systému o informačních systémech veřejné správy 6 633 [57] takových systémů, přičemž nejvíce je jich provozovány městy a obcemi v samostatné působnosti (1 818), přenesené působnosti (1 384) a ostatní (520).
Problematice ISVS byl věnován prostor v předmětu *Bezpečnostní informatika*[a].

[a] od roku 2018, do roku 2018 byla problematika ISVS probírána na FBI v rámci předmětu *Bezpečnostní informatika 2*.

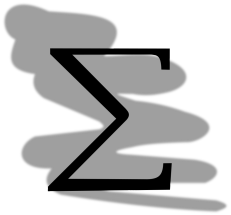

Shrnutí kapitoly

Základní právní úpravou problematiky kybernetické bezpečnosti představuje zákon o kybernetické bezpečnosti. Tento zákon definuje právní postavení, pravomoci a povinnosti národního a vládního CERT týmu. Národní tým CERT.CZ je primárně určen pro zprostředkování kontaktů mezi provozovateli sítí pro řešení zaznamenaných narušení kybernetické bezpečnosti.
Vládní tým GovCERT.CZ provozuje NÚKIB. Ten je určen primárně provozovatelům významných sítí a systémů a také systémů KII.
Provozovatelům výše uvedených systémů vznikají dle zákona některé povinnosti, především pak vést bezpečnostní dokumentaci, monitorovat kybernetické bezpečnostní události a hlásit bezpečnostní incidenty.
V případě, že hrozí vážné narušení provozu významných sítí a systémů, popř. systémů KII, kde rozsah narušení by mohl ohrozit základní zájmy ČR, může ředitel NÚKIB vyhlásit stav kybernetického nebezpečí. Behem trvání tohoto stavu se Úřadu rozšiřuje okruh osob, kterým může ukládat úřad opatření. Za normálních okolností přitom úřad může ukládat taková opatření pouze provozovatelům významných systémů a KII.

Kontrolní otázky

1. Definujte významný informační systém.
2. Jaký je rozdíl mezi národním a vládním CERT týmem?
3. Co je poskytovatel digitální služby, uveďte příklad.
4. Jaký je rozdíl mezi událostí a incidentem (kybernetická bezpečnost).
5. Podle čeho se klasifikují významné informační systémy?

Správné odpovědi

1. IS provozovaný org. veřejné moci, u kterého by narušení bezpečnosti ohrozilo výkon působnosti tohoto org.
2. Národní je provozovaný soukromou org. a je určen primárně ke koordinaci mezi provozovateli běžných sítí, vládní CERT proti tomu primárně řeší kybernetickou bezp. ve spolupráci s provozovateli významných IS a KII a je provozován správním úřadem (NÚKIB).
3. Rozumí se jím provozovatelé on-line tržišť, internetových vyhledávačů a cloudových služeb. Př.: Google, Microsoft, Amazon ...
4. Událost je obecnější, incident už představuje reálné narušení kybernetické bezpečnosti.
5. Podle dopadových (měří se dopad funkci veřejné správy, popř. systému KII) a oblastních (taxativně stanoveny vyhláškou) kritérií.

Kapitola 6

Data mining

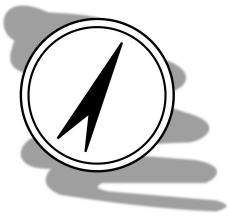

Náhled kapitoly
V této kapitole se přesuneme od problematiky systémů řízení k problematice data miningu. Tato kapitola slouží jako úvod do problematiky. Proto si v ní řekneme co to vůbec data mining je, ale také jaké problémy a pomocí jakých metod řeší. Další kapitoly se pak zaměří na jednotlivé nástroje a metody, které pro dolování informací můžeme použít. Tato kapitola tak poslouží jako teoretické východisko pro další výklad jednotlivých metod.

Po přečtení této kapitoly budete
vědět

- co je to data mining
- jaké metody lze pro dolování informací použít
- a co od nich můžeme očekávat

znát

- obecný postup řešení data miningových projektů

Čas pro studium
Pro prostudování této kapitoly budete potřebovat přibližně dvě hodiny.

Data mining je pojem, který souhrnně označuje postupy schopné identifikovat v datech zajímavé souvislosti nebo skryté informace. Pro data mining je typické zpracování velkých objemů dat, které jsou pouze obtížně zpracovatelné pomocí běžných tabulkových procesorů, jako je např. MS Excel. Bavíme se tak o rozsahu dat od desítek tisíců řádek výše, s desítkami, stovkami nebo více sloupci s tím, že horní limit pro data mining není určen.

Pro dolování dat je také typické, že data samotná se nachází ve fragmentované podobě, umístěna ve velkém množství datových zdrojů. Jedním ze základních problémů, které data mining řeší je tak integrace dat z těchto různorodých zdrojů tak, aby proces dolování mohl vůbec započít.

V české literatuře se někdy používá doslovný překlad dolování dat. Objevují se také jiné názvy jako dobývání dat, v angličtině se pak někdy používá také Knowledge Discovery in Databases (KDD). *Data mining* je ale jednoznačně nejpoužívanější název a to i v češtině.

Původně se data mining používal především v pojišťovnách, statistických úřadech, bankách, investičních fondech a výzkumu. Motivací byla na jedné straně existence ohromných objemů dat a na straně druhé relativní dostupnost finančních zdrojů nutných pro investici do nástrojů, které by data mining realizovaly.

Představiteli takových nástrojů jsou např. SAS [70] od stejnojmenné společnosti a SPSS [42] od společnosti IBM. Obě tyto společnosti stály u zrodu data miningu a dokonce vyvinuly vlastní doporučované postupy realizace data miningu.

S postupem doby a rozvojem výpočetní techniky, se ale začaly objevovat také alternativní, cenově dostupné nástroje, které data mining zpřístupnili také malým a středním firmám nebo dokonce jednotlivcům. V současnosti nejpoužívanější analytický nástroj celosvětově je R [17], který je open source. To znamená, že je dostupný bezplatně a to i ke komerčnímu použití.

Otevřená podstata R přispěla k rozšíření v akademickém prostředí, které pak přispívá v vývoji jak prostředí samotného, tak rozšiřujících knihoven poskytující nové funkce a postupy, které pokrývající prakticky všechny oblasti matematiky, statistiky, strojového učení apod. Dostupnost širokého spektra funkcí pak vedla k rychlé adopci R pro realizaci cenově dostupných analýz dat v organizacích různého zaměření i velikosti.

Na rozdíl od nástrojů SAS nebo SPSS nedisponuje R jednotným grafickým rozhraním, které by umožňovalo parametry datových analýz „naklikat“. Proto je s použitím R spojena nutnost zvládnout vestavěný programovací jazyk a také způsobu, jakým jsou implementovány jednotlivé toolkity.

Pro řešení problémů dataminingu v R je pak nutné zvládnutí zvolené knihovny implementující analytické metody, které jsme vybrali pro řešení problému.

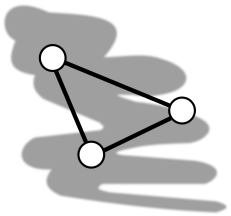

R zapojení do výuky

Dostupnost knihoven různého druhu, včetně těch, které jsou zaměřeny na řešení různých problémů včetně implementace různých metod použitelných pro data mining, byla jedním z faktorů, které přispěly v volbě tohoto nástroje pro výuku. V následující kapitole se seznámíme se základy použití R. V dalších kapitolách se zaměříme na jednotlivé metody (a knihovny, které je implementují), praktické ukázky pak budou demonstrovány právě v R.

6.1 Postup data miningu

Bez ohledu na zvolený analytický nástroj je základní postup data miningu stejný. Můžeme se na něj dívat technicky nebo manažersky. Při *technickém* pohledu vnímáme data mining jako na posloupnost na sebe navazujících činností realizovaných v analytickém nástroji. Oproti tomu při *manažerském* pohledu je pro nás primární spíše problém, který se pomocí data miningu snažíme řešit. Data mining je tak vnímán jako projekt, který řešíme sestavením řešitelského týmu, přidělením zdrojů apod.

Tyto přístupy si vzájemně neodporují - prostě se na problematiku data miningu dívají z odlišného úhlu pohledu. Graficky jsou přístupy znázorněny na obr. 6.1 a 6.2.

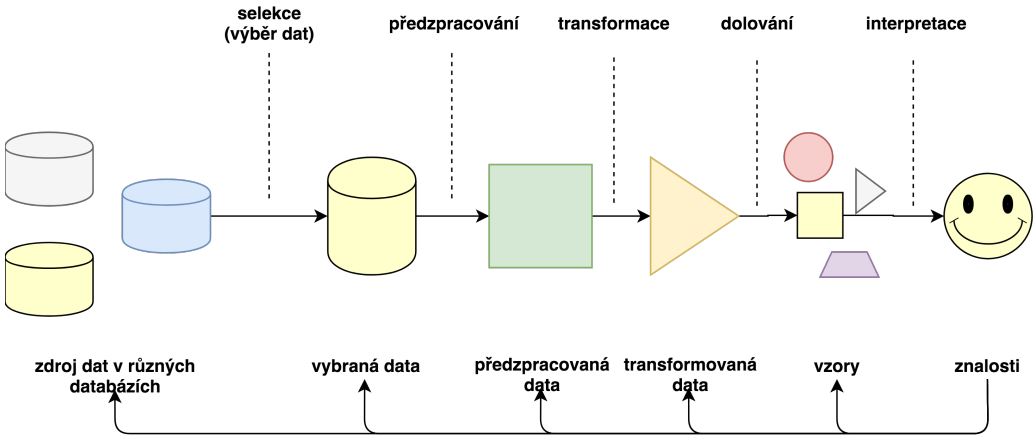

Obrázek 6.1: Technický pohled na postup data miningu (adaptováno z [23])

Data použitelná v data miningu se obvykle nacházejí v různých informačních systémech, které organizace používá pro vedení svých agend. Data mohou být také získána z měřící techniky, ale také externích zdrojů. Před jejich použitím pro účely data miningu je ale potřeba rozhodnout, která data jsou pro řešení zvoleného problému vůbec relevantní.

Vybíráme tak relevantní data (*selekce*) pro další zpracování. V tomto okamžiku data zůstávají ještě ve svých původních umístěních. Jejich fyzický výběr a příprava pro data mining se děje až v kroku *předzpracování dat*, v rámci kterého jsou data extrahována ze svého původního umístění a integrována v úložišti zvoleného data miningového nástroje.

Proces předzpracování je často časově velmi náročný, často náročnější než samotná aplikace data miningových metod pro získání znalostí. Operace selekce a předzpracování je přitom v rámci data miningového projektu často nutné opakovat, protože zejména na začátku projektu není vždy zcela jasné, jaká data jsou pro dosažení cíle vlastně potřeba.

Konečně z data miningu vyplývá, že hledáme znalosti které jsou **skryté** v datech. Jak vyplývá ze zpětnovazebních vazeb na obr. 6.1 je možné se v rámci data miningu vrátit zpět a opakovat jeden nebo více kroků např. se změnou vstupních parametrů apod.

V kroku *transformace* připravujeme data na jejich zpracování pomocí zvolených data miningových metod. Tento krok je nutné provést, jelikož různé metody očekávají odlišné vstupy. V rámci transformace řešíme často následující problémy, ale nejen je:

- chybějící data,
- standardizace dat do jednotného (požadovaného formátu),
- diskretizace dat (převod spojitých dat do intervalů),
- apod.

Z výše uvedeného vyplývá, že pro správné provedení transformace dat je již nutné mít vybrané metody, které chceme pro samotné dolování dat použít. Po provedení transformace již bez problémů můžeme na připravená data tyto metody použít a získat *vzory*.

Vzory jsou tedy přímým výstupem zvolených metod. Tedy nestačí aplikovat metodu, napsat výsledek a prohlásit náš úkol za vyřešený - výsledky je nutné interpretovat. Jinými slovy je potřeba zjistit, co přesně takové výsledky znamenají. Jsou užitečné? Jaká je chyba v řešení, ke kterému jsme došli? Je možno kvalitu řešení zlepšit, např. doplněním dalších vstupních dat nebo volbou jiné metody, popř změnou parametrů metody stávající? Podobných otázek pak lze vymyslet celou řadu.

Odpovědi na tyto otázky nám pak spolu s výsledky metod tvoří znalosti, které jsou aplikovatelné pro řešení problémů.

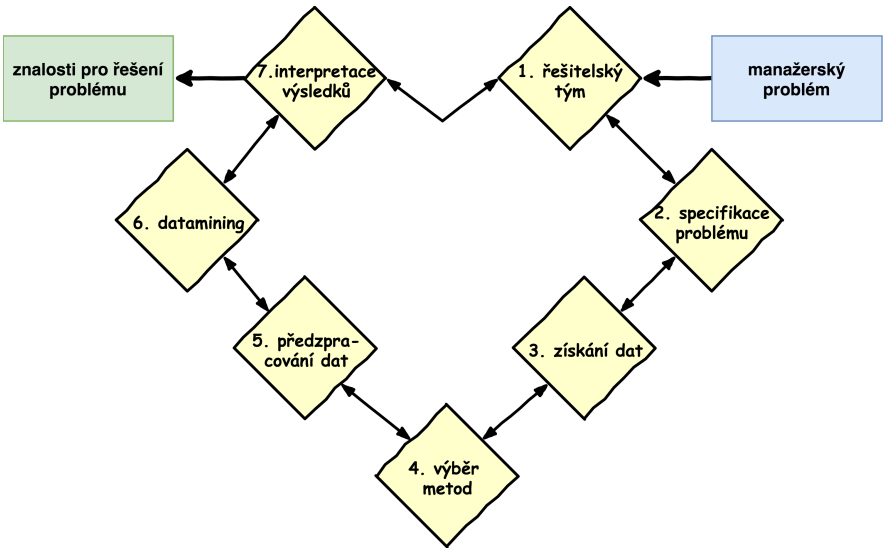

Obrázek 6.2: Manažerský pohled na postup data miningu (adaptováno z [23])

Manažerský pohled je trošičku jiný - nesoustředí se totiž na technickou stránku, ale spíše na organizaci celého řešení. Z pohledu managementu je na začátku problém, který je potřeba vyřešit. S problémem je spojeno určité zadání specifikující, v čem problém spočívá a také jaké jsou očekávány výstupy - např. z pohledu přesnosti, rychlosti, popř. jiných nároků, které na budoucí řešení máme.

Určí se leader projektu - může to být sám manager, ale mnohem častěji se jedná buďto o odborníka v doméně problému (odborník na problém) nebo odborníka na data mining. V rámci data miningu jsou často zpracovávány údaje, které jsou oborově velmi různorodé. K jejich správnému pochopení a

zpracování je tak často potřeba sestavovat celé řešitelské týmy s interdisciplinárním oborovým zázemím.

Tým rozpracovává zadání tak aby získal podrobnou *specifikaci* jak problému samotného tak metrik, kterými má být poměřováno jeho řešení. Specifikace se často dělá ve spolupráci s managementem - v některých případech jsou v tomto kroku objeveny nejasnosti, které je potřeba již na začátku data miningového projektu odstranit.

Specifikace problému může také ukázat, že tým není odborně složen správně - mohou např. chybět některé klíčové odbornosti. Na druhou stranu se může ukázat, že některé odbornosti naopak nebudou potřeba.

Pro dobře definovaný problém se získávají data z různých zdrojů, o kterých se řešitelský tým domnívá, že by se v nich mohlo skrývat řešení. Následně jsou *vybírány metody*, které splňují požadavky zadání z hlediska očekávaných výstupů a také naděje na úspěch.

Řadu metod např. lze vyloučit předem z důvodu nedostupnosti dat, nebo přílišné složitosti přípravy dat.

Pro zvolené metody se dat *předzpracují*. Na takto připravená data již lze aplikovat zvolené metody. Výsledky je pak potřeba podrobit *interpretaci*, abychom zjistili, zda odpovídají našim představám o řešení nebo ne. V případě že ne lze některé kroky celého procesu opakovat, nebo opakovat proces celý ovšem s tím, že suma znalostí o problému je již větší - včetně znalosti o tom, proč naše případné předchozí pokusy selhaly.

Tedy klíčovým prvkem data miningu je *problém*. Jaké typy problémů vlastně lze řešit. V data miningu jsou obvykle rozlišovány tři typy úloh [23]:

- klasifikace a predikce,
- deskripce,
- hledání nugetů.

Klasifikace je pravděpodobně nejčastěji řešenou úlohou data miningu. Protřednictvím klasifikace se snažíme zatřídit hodnocený případ do některé z existujících kategorií. Např. vyhodnocením symptomů nemocného můžeme určit diagnózu (zaklasifikovat nemocného) a navrhnout vhodnou léčbu. Klasifikací je ale také například identifikace dopravních značek kamerovým systémem projíždějícího samořiditelného auta.

Predikci pak můžeme chápat jako klasifikaci zaměřenou na budoucnost. Abychom zůstali v mantinelech předchozích příkladů může příkladem predikce být odhad reakce pacienta na léčbu (bude se uzdravovat? bude to trvat dlouho?).

Z algoritmického hlediska ale obvykle mezi klasifikací a predikcí rozdíl není, proto dále v textu budeme pro zjednodušení používat pojem klasifikace pro klasifikaci i predikci.

Z algoritmů, které bychom pro řešení klasifikačních problémů mohli použít lze zmínit např.:

- statistika (např. regresní modely)
- pravidlově orientované metody jako rozhodovací stromy nebo pravidla
- metody strojového učení jako např. neuronové sítě
- apod.

Pro řešení klasifikačních problémů je typické, že máme k dispozici vstupy, na základě kterých se snažíme odvodit výstup. Deskripce a hledání nugetů, ale podobným způsobem nefungují.

Deskripce řeší problém popisu analyzovaných dat. Deskripce nám pomáhá data pochopit a to v souvislostech. Řeší se tím problém kdy data mohou být pochopena v kontextu svých původních informačních systémů. Výběr a spojování dat do nových datových sad vyžaduje podrobnější průzkum. Právě toto řeší deskripce.

Vzhledem k tomu, že na základě výše uvedený popis deskripce jste si nejspíše neudělali úplně jasnou představu o tom, co deskripce vlastně je, zkusme se podívat na nějaké nástroje a postupy, na kterých bychom si to mohli ukázat:

- vizualizace dat pomocí grafů (např. vzájemný vztah veličin),
- analýzy distribuce veličin,
- shluková analýza,
- apod.

Konečně *dolování nugetů* se zaměřuje na identifikaci nových zajímavých, možná překvapivých informací v datech. Tam kde se tedy deskripce zaměřovala na získávání informací popisujících používaný

datový soubor jako celek, dolování nugetů se zaměřuje spíše na minoritní část dat, která z nějakého důvodu vybočuje.

Umožňuje proto nacházet např. limity určitých postupů, např. ve smyslu hranice za kterou už neplatí model požívaný pro většinu dat. Informace tohoto typu jsou často vedlejším produktem analýz řešících třeba klasifikační problémy nebo deskripci dat.

Předem se přitom dá pouze těžko odhadnout, zda takové nugety budou v datech nalezeny a jaké bude jejich podstata.

Problematikou hledání nugetů se v tomto textu nebudeme příliš zabývat. Z metod, které by k tomuto účelu bylo možné použít lze zmínit např. asociativní pravidla.

Graficky si lze představit tyto tří typy úloh jako na obr. 6.3. Uvažujme na chvíli o těchto problémech jako o stěně, kterou máme postavit. Prostor, který má stěna pokrýt označíme jako koncept. Jednotlivé stavební prvky stěny nám budou sloužit pro pokrytí tohoto konceptu. Koncept je reprezentován na obr. žlutou barvou.

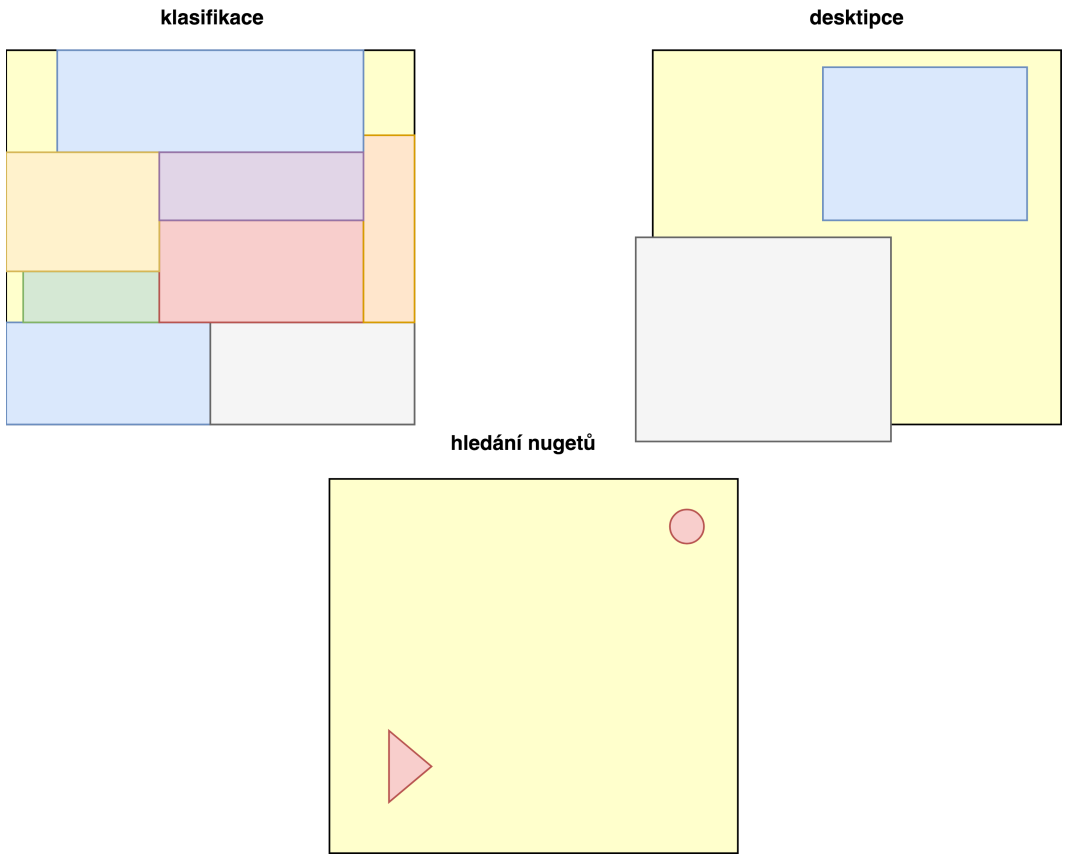

Obrázek 6.3: Úlohy data miningu - pokrytí konceptu (adaptováno z [23])

V případě klasifikace je požadováno, aby koncept byl pokrytý co možná nejlépe. Jednotlivé „stavební bloky“ by se neměly pokud možno překrývat. Nevyplněná místa, popř. překryvy totiž vedou ke snížení použitelnosti klasifikace. Příklady, které se nacházejí v nepokryté části konceptu nemohou být zaklasifikovány. Překryvy mezi množinami pak způsobují nejasnosti v tom, kam přesně příklad zaklasifikovat.

V reálných datech se takřka vždy objevují nepřesnosti, které způsobují neostrosti mezi množinami. Získat takovou množinu dat, která skutečně úplně pokrývá hledaný koncept je také netriviálním problémem.

Pro maximální pokrytí konceptu proto preferujeme větší množství množin - preferujeme tedy přesnost před jednoduchostí.

Oproti tomu deskripce preferuje identifikaci skutečně nosných vlastností konceptu. Deskripce tak nevyžaduje, aby koncept byl pokrytý opravdu celý. Přípustné mohou být také určité překryvy mezi množinami, popř. situace kdy identifikovaná množina přesahuje hranice hledaného konceptu.

6.2 Metodiky dolování dat

Metodikami rozumíme postupy, které implementují jednotlivé nástroje používané pro data mining. Postupy v předchozí podkapitole jsou tedy univerzální, avšak různé nástroje je implementují různým způsobem.

V tomto výkladu se zaměříme na tři takové metodiky:

1. 5A - implementovanou v SPSS,
2. SEMMA - implementovanou v SAS a
3. CRISP-DM - nezávislý standard.

5A metodologie

5A je zkratka složená z počátečních písmen Assess, Access, Analyze, Act a Automate popisující kroky metodologie.

Assess (zhodnoť) znamená potřeb data miningového projektu. Hovoříme specifikaci problému, možných zdrojů dat a také našich očekávání stran budoucího řešení.

V rámci *Access (přistup [myšleno k potřebným datům])* přistupujeme k datům z různých zdrojů, vybíráme ta, která považujeme ze relevantní a integrujeme je do ucelených datových sad pro potřeby budoucích analýz.

Analyze (analyzuj) představujeme krok, ve kterém aplikujeme zvolené analytické metody na shromážděná data a získáváme výsledky.

Název dalšího kroku metodiky 5A *Act* se do češtiny překládá v použitém kontextu poměrně obtížně. Doslovný překlad je *jednej*, ale ten úplně neodpovídá tomu, jak je tento krok myšlen. 5A totiž rozlišuje mezi tzv. znalostmi a akčními znalostmi.

Toto si lze představit tak, že vybraná data podrobíme analýzám zvolenými metodami a dostaneme výsledky (v předchozích krocích 5A) a tyto výsledky interpretujeme. Všechny konzistentní interpretace nám představují znalosti. Jsou ale všechny znalosti použitelné pro řešení našeho problému? Act proto znamená identifikaci podmnožiny znalostí, která jsou akční - přímo použitelné pro řešení problému.

Konečně *Automate (automatizuj)* představuje finální krok 5A zaměřený na zautomatizování akčních znalostí pro řešení problému.

Představme si příklad problému klasifikace klientů banky na bonitní/nebonitní z pohledu přidělování úvěrů. Na základě informací o stávajících klientech banky a jejich schopnosti splácet úvěry odvodíme pravidla přidělování úvěrů a implementujeme do informačního systému banky (zautomatizujeme jej).

Při posuzování nových žádostí o úvěr pak bankovní úřednice pouze vyplní shromážděné informace o klientovi do systému a kliknutím na tlačítko spustí proces vyhodnocování bonity.

Je potřeba podotknout, že samotné IBM ve svém nástroji SPSS Modeler postupně od 5A upustilo a přešlo na vlastní rozšířenou verzi standardu CRISP-DM nazvanou Analytics Solutions Unified Method for Data Mining/Predictive Analytics (ASUM-DM).

SEMMA

I SEMMA je zkratkou - konkrétně pro Sample, Eplore, Modify, Model a Assess.

Sample (výběr) - rozumíme jím výběr ve smyslu statistiky. Výběr je soubor, který obsahuje tu část prvků ze základního souboru, jejíž vlastnosti skutečně pozorujeme nebo měříme. Patří zde výběr dat z jejich původních umístění a jejich integrace do datasetů pro pozdější zpracování.

Explore (průzkum) je krok, v rámci kterého se snažíme pochopit data, se kterými pracujeme. Účelem je identifikovat možné vztahy mezi daty, možnosti případně omezení, která by mohla být relevantní pro provádění analýz. K tomuto účelu se často používají vizualizace dat, zkoumání jejich distribuce apod.

Modify (úprava) - připravuje data pro provedení analýz. Formálně odpovídá kroku transformace dat z předchozí podkapitoly. Výstupem jsou data připravená pro aplikaci zvolených analytických metod.

Zvolené metody jsou aplikovány v kroku *Model (modeluj)*. Tady je použití metodiky SEMMA poměrně specifické, úzce svázané s nástrojem SAS Enterprise Miner, pro který byla metodika vyvinuta. Tento nástroj má některé specifické vlastnosti v oblasti modelování a také hodnocení kvality modelů (*Assess*).

Nástroj funguje tak že uživatel v grafickém uživatelském rozhraní specifikuje data, která mají být zpracována a řadu různých analytických metod (ať už skutečně různých nebo pouze se změněnými parametry), které mají být na datech použity.

Následně se na základě kontrolního vzorku dat provede automatické vyhodnocení kvality použitých modelů a doporučí se ten nejlepší.

Určitou představu o způsobu fingování si lze udělat z obr. 6.4.

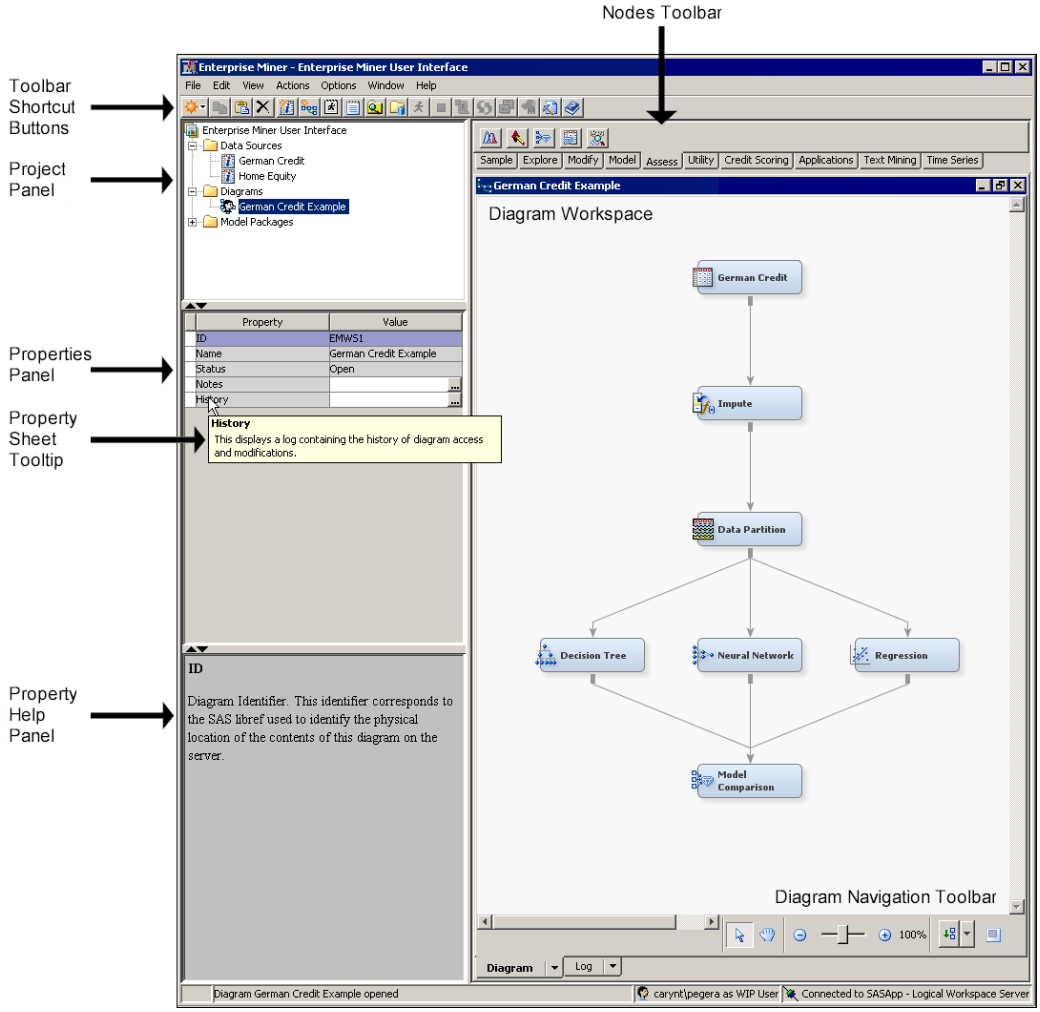

Obrázek 6.4: Proces data miningu v SAS Enterprise Miner (převzato z [69])

Všimněte si, že takový postup je jednoduše možné použít pouze v SAS Enterprise Miner. Praktická použitelnost takového postupu je tak omezená. Všimněte si také, že SEMMA se zaměřuje takřka výhradně na problematiku modelování.

Pokud to srovnáme s např. 5A (nebo CRISP-DM dále) neobsahuje úvahy o tom, jak se data mining začleňuje do celkového fungování organizace, jak se použijí výsledky apod. Takové otázky ja proto nutné řešit samostatně (nebo použít jinou metodologii práce s daty).

CRISP-DM

Metodologie CRISP-DM vznikla v roce 1996 v rámci projektu EU ESPRIT. Účelem projektu bylo vyvinout nezávislý, otevřený standard pro realizaci data miningu. CRISP-DM je zkratka pro Cross-industry standard process for data mining (CRISP-DM), tedy česky mezioborový standard procesu pro data mining.

Graficky je možno postup znázornit jako na obr. 6.5.

Podle standardu je data mining realizován v šesti základních krocích. V prvním kroku pracujeme na *pochopení problému*. Problém je obvykle úzce spojen s fungováním organizace jako takové. Není tedy řešen izolovaně od fungování zbytku organizace.

V druhém kroku se snažíme *pochopit data* - jaká máme k dispozici a co nám říkají, jaká v současnosti k dispozici nemáme, ale z hlediska řešení by byla přínosná. Podstatnou informací je taktéž, kde přesně se data nachází a v jakém formátu.

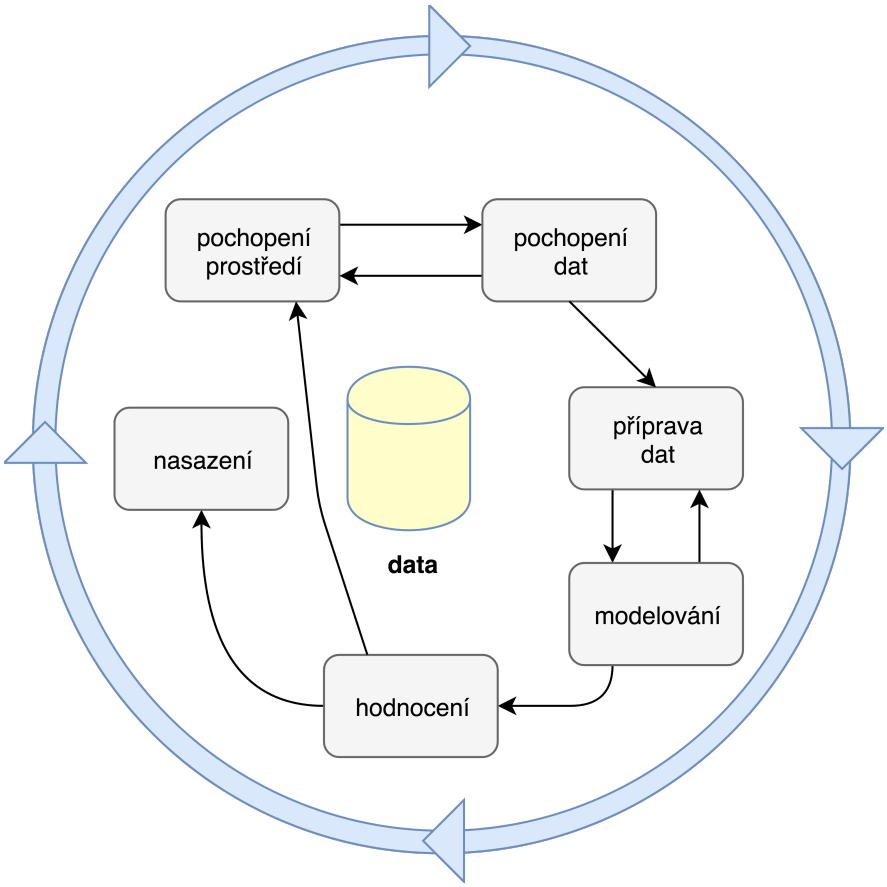

Obrázek 6.5: Životní cyklus data miningu (převzato z [41])

Následně potřebná data připravíme k analýze. V CRISP-DM se do této fáze dává jak fyzický výběr dat z jejich původního umístění, tak jejich transformace do použitelné podoby.

V *modelování* jsou na připravená data aplikovány zvolené analytické metody a získáváme výsledky. Tyto výsledky jsou našim vodítkem pro *hodnocení* kvality.

Byl splněn účel data miningu? Pokud ano, získali jsme dostatek informací k tomu, abychom problém vyřešili. Automatizované *nasazení* je pak logickým zakončením celého procesu.

Pokud ale nejsou výsledky dostatečné pro ukončení data miningového projektu, je potřeba identifikovat příčinu neúspěchu. Chyba mohla nastat buďto ve zvolených metodách - použili jsme nevhodné metody a nebo jsme špatně nastavili jejich parametry. Chyba ale může být přímo v datech. Data např. nemusí být dostatečně reprezentativní, aby nám vůbec umožnila problém vyřešit. V takovém případě pak řešíme problém, jak získat lepší data.

Problém mohl ale nastat v samotném našem chápaní problému. To může např. znamenat, že se data miningem snažíme řešit jiný problém, než ve skutečnosti máme.

I v případě neúspěchu jsme v procesu získali lepší pochopení situace a to nám může otevřít nové cesty pro řešení problému.

Srovnání metodologií a postupů
Porovnejte vlastnosti metodologií 5A, SEMMA a CRISP-DM. Podívejte se jakým způsobem korespondují (implementují) kroky řešení data miningu zobrazené na obr. 6.1.

Metodika vs metoda
Rozlišujte prosím mezi pojmy *metodika* a *metoda*. V této podkapitole (a v obecné rovině i v téo předchozí) jsme se zabývali metodikami. Jedná se o standardizované postupy (posloupnost činností), které vedou k určitému cíli - v našem případě k získání znalostí. Metodika obsahuje informace o způsobu použití metod a také metodické informace, např. ve smyslu jak dosažené výsledky metod interpretovat. Takže SEMMA, 5A, CRISP-DM jsou metodiky a např. lineární regrese, neuronové sítě, baysovský klasifikátor jsou metodami. **Prosím neplést!**

6.3 Zdroje data miningu

Jak jsme již rozebrali výše, data mining bere údaje z jejich původních zdrojů a pak s nimi dále pracuje. Jak jsou ale taková data organizována?

V běžných provozních systémech jsou používány obvykle relační databáze. V takových databázích se vytvářejí 2D datové struktury exaktně definovaných tabulek a relací (vztahů) mezi nimi. Data samotná odpovídají jednotlivým datovým transakcím popisujících určitý děj nebo stav reálného světa.

My jsme se problematiky databází již trochu dotkli v souvislosti s problematikou tzv. *realtimových databází* a získané poznatky nám dobře poslouží i nyní.

Jako příklad bychom si mohli uvést prodej výrobku e-shopu. V určitém časovém okamžiku dojde k potvrzení objednávky určitého množství výrobků za určitou cenu. Takové datové struktury bychom mohli zjednodušeně popsat pomocí Entity Relationship Diagram (ERD) na obr. 6.6.

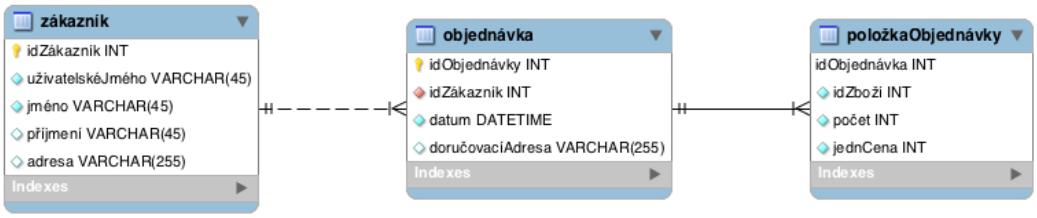

Obrázek 6.6: Příklad struktury zjednodušené objednávky

Příklad na obr. 6.6 je potřeba vnímat pouze jako ilustrativní. Pro praktickou realizaci e-shopu bychom potřebovali podstatně více dat organizovaných ve větším množství tabulek.

Provedení analýz ale vyžaduje aby jako vstup byla předložena pouze jedna tabulka. Proto jsme v předchozích podkapitolách věnovali tolik času identifikaci potřebných dat, jejich předzpracování a transformaci.

Data miningový projekt je také komplikován tím, že podobných bází dat (systémů) je potřeba jako zdroj použít často více. V takovém případě, ale vazba mezi daty z různých systémů nemusí být úplně jasná. Datový analytik v takovém případě musí pochopit dostupná data a manuálně specifikovat vazby mezi daty.

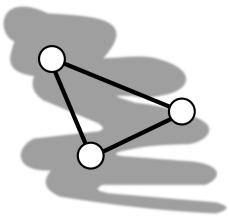

Databázová teorie
Základní informace o relačních databázích, způsobu návrhu báze dat je možno nalézt třeba ve skriptech předmětu *Bezpečnostní informatika* [85].

Ne všechny údaje jsou ale organizovány tímto způsobem. Na obr. 6.7 je znázorněna celková (zjednodušená) struktura informačních systémů středních/velkých společností.

Jako základ fungování podniku jsou na obr. 6.7 ERP systémy sloužící po pokrytí běžných agend, které mají všechny organizace bez ohledu na předmět jejich činnosti. jedná se o:

- ERP - plánování zdrojů podniku (financování apod.)
- Supply Chain Management (SCM) - řízení odběratelsko - dodavatelského řetězce.

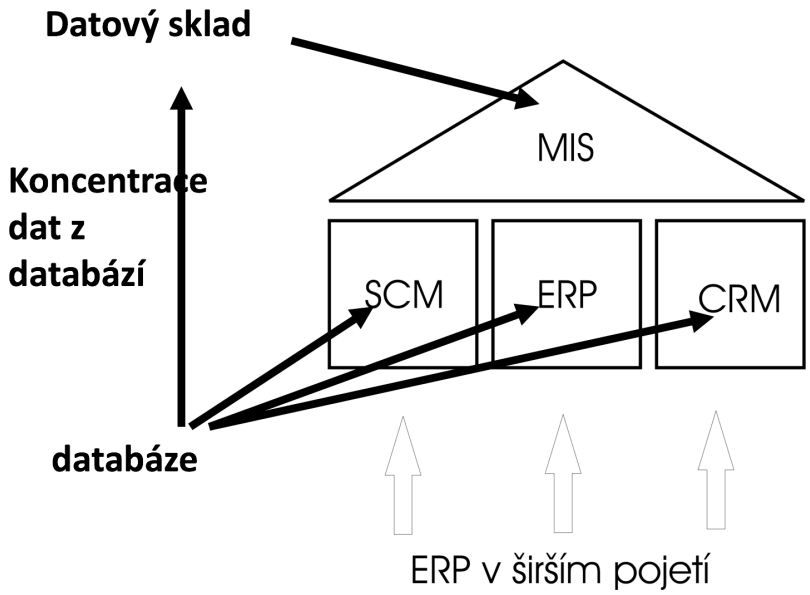

Obrázek 6.7: Struktura informačních systémů podniku

- Customer Relationship Management (CRM) - řízení vztahu se zákazníky

V ERP systémech jsou ukládány transakční informace. Tyto však nejsou přímo použitelné např. pro dlouhodobé řízení. Pro tyto účely jsou z ERP integrovány do Management Information System (MIS). Pro tyto účely je potřeba data agregovat napříč transakcemi a získat tak pohled např. regionálně, popř. za určité období (měsíc, čtvrtletí) apod.

Odlišný způsob práce s daty je pak často výhodné organizovat odlišně než pomocí relačních databází. Takovou novou organizaci dat může poskytnout *datový sklad*. Vnitřně je datový sklad organizován jako Online Analytical Processing (OLAP).

OLAP je multidimenzionálním konceptem uložení a manipulace s daty. Data jsou organizována do „krychlí“, které umožňují rychlé a pohodlné agregace. Informace prodejích by pomocí krychle bylo možné znázornit podobně jako na obr. 6.8.

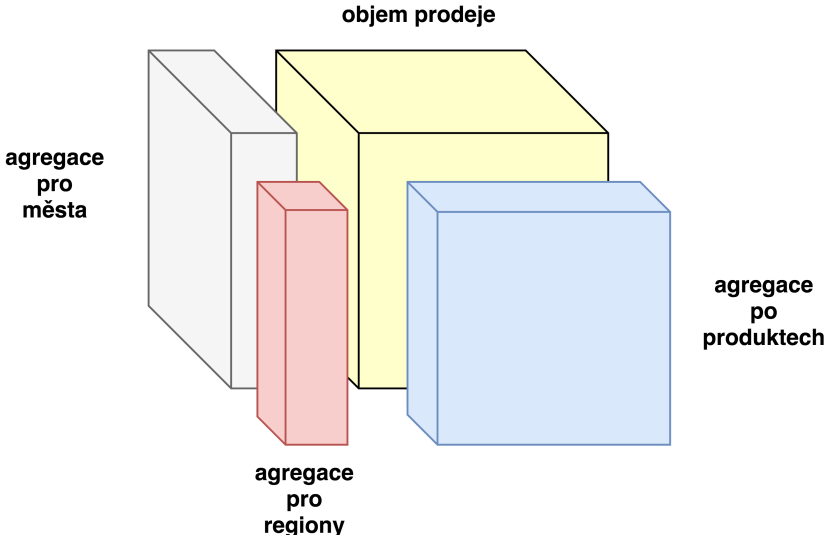

Obrázek 6.8: Datová krychle v OLAP (adaptováno z [23])

Hlavní tělo krychle je na obr. znázorněno žlutou barvou. Krychli v rámci práce OLAP lze dle potřeb natáčet data agregovat podle zvolených kritérií apod. Základními operacemi OLAP proto jsou:

- natáčení (pivot),
- řezy (slice),
- výběr části krychle (dice),
- zobrazování agregovaných hodnot.

OLAP lze implementovat různým způsobem. Lze tvořit jedinou krychli, do které bude integrované všechno - takové řešení je někdy označonáno jako *hyperkrychle* (hypercube). Řešení používající více krychlí jsou pak označovány jako *multikrychle* (multicube).

Hyperkrychle je náročnější z hlediska prvotní integrace dat, následná manipulace s nimi je ale pak jednodušší. Multikrychle je pak naopak jednodušší z hlediska integrace dat, ale následné propojování dat mezi krychlemi více zatěžuje OLAP server.

Rozdíl může být také ve způsobu uložení dat. Multidimensional Online Analytical Processing (MOLAP) je založen na řešení pomocí datové krychle nebo krychlí. Lze tedy říci, že se jedná o „čisté“ OLAP řešení.

Relational Online Analytical Processing (ROLAP) ponechává data v relační databázi. OLAP server pak pracuje tak, že vybírá data příkazy jazyka SQL a vytváří „virtuální krychle“. Uživatel OLAP tedy používá běžné operace manipulující s datovou krychlí. Mezi ním a daty je však navíc ještě jedna mezivrstva převádějící příkazy OLAP do SQL jazyka manipulujícího s relační databází.

Řešení různých výrobců pak mohou přicházet s dalšími variantami práce s daty. Microsoft např. pracuje ještě s tzv. Hybrid Online Analytical Processing (HOLAP) [54]. Vetšinou se však jedná o speciální případy MOLAP nebo ROLAP řešení.

Ostatní zdroje data miningu

Rozvoj výpočetní techniky směrem ke zpracování velkých objemů dat se posunul natolik do předu, že v současnosti je možno zpracovávat takové objemy dat, které pomocí běžných databází nejsou zpracovatelné. Dobrým příkladem mohou být data ze sociálních sítí, informace o webových stránkách na Internetu apod.

Pro zpracování takových objemů dat byly vyvinuty nové databáze a postupy, které označujeme jako *NoSQL* databáze. Takové neorganizují data do tabulek propojených relacemi, jak je obvyklé u relačních databází. Data zůstávají „na jedné hromadě“ a jsou k nim doplňovány komplexní anotace, popisující vazby mezi daty, identifikující různé možné použití apod.

My v předmětu Bezpečnostní informatika 3 (Informatika v bezpečnosti) takové objemy dat zpracovávat nebudeme, proto berte výše uvedenou informaci jako doplňkovou.

Posledním možným zdrojem pro data mining jsou výsledky data miningu. Proces dolování tedy může být více stupňový. Můžeme použít modely pro doplnění některých dat, nebo jejich jiné zpracování. Výstupy těchto metod pak mohou otevírat nové cesty pro odvozování znalostí z dat.

Při aplikaci metod je ale potřeba mít na paměti, že data samotná i výsledky metod jsou vždy zatíženy určitou chybou. jinými slovy nelze si vymyslet data a pak předpokládat, že výsledek data miningu bude mít jakoukoliv vypovídající hodnotu.

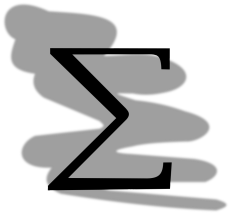

Shrnutí

Data mining umožňuje analyzovat velké množství různorodých dat a nacházet v nich nové, užitečné znalosti. Odvykle se postupuje tak, že se shromáždí data z různých zdrojů, připraví se do potřebného formátu vyžadovaného zvolenými analytickými metodami, které se na připravená data aplikují. Výsledky metod jsou pak interpretovány ve světle problému, který se snažíme data miningem vyřešit.
Data mining provádíme obvykle pomocí specializovaných analytických nástrojů. Většina z nich implementuje některou z metodik data miningu. V současnosti nejrozšířenější metodikou je CRISP-DM umožňující zasadit data mining do celkového kontextu fungování organizace, pro řešení jejích „business problémů“.
Vstupy pro data mining mohou být organizovány různě. Největší část dat je obvykle dostupná v různých provozních informačních systémech organizace. Tyto systémy obvykle využívají jako databázový backend relační databázi strukturující data do tabulek a vazeb mezi nimi (relací).
Při větších objemech dat, vyžadujících provádění periodických a složitých agregací je možné budovat tzv. datové sklady. Ty jsou často organizovány do podoby datové krychle umožňující použití OLAP systémů pro realizaci analytických operací nad nimi.

Otázky

1. Vyjmenujte základní kroky data miningu.
2. Jaký je rozdíl mezi metodikou a metodou?
3. Jaký je rozdíl mezi relační databází a OLAP?
4. Jaké má výhody použití OLAP?
5. Jaký je nejčastější problém řešený data miningem a definujte jej.

Odpovědi

1. Selekce, předzpracování, transformace dat, dolování (modelování), interpretace výsledků.
2. viz vykřičník mezi kapitolami 6.2 a 6.3.
3. Relační databáze organizují data do tabulek (a spojení mezi nimi), OLAP pracuje s datovými krychlemi.
4. OLAP umožňuje jednodušeji provádět nad daty agregace např. geograficky, objektově nebo časově.
5. Klasifikace. Řeší přiřazení hodnoceného případu do jedné z cílových tříd na základě vstupních údajů.

Kapitola 7

Úvod do R

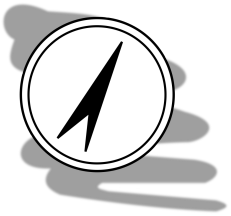

Náhled kapitoly
Pozor - tato kapitola je zaměřena prakticky. Proto předtím, než vůbec začnete studovat R jako nástroj jej nainstalujte na svůj počítač a jednotlivé probírané kroky rovnou zkoušejte na počítači. Zjistíte, že to, co ve skriptech není příliš jasné, se náhle vyjasní při praktické aplikaci.
Nebojte se experimentovat. Skripta jsou vždy do určité míry omezená a mohou tak obsahovat vždy pouze základy. Ilustrační příklady ale lze jednoduše dále rozšiřovat. Experimentováním jednak utužíte znalosti, jednak lépe proniknete do probírané problematiky.

Po prostudování této kapitoly budete
mít

- k dispozici špičkové analytické prostředí
- základní znalosti o filozofii použití R

umět

- řešit některé základní problémy v R (načítat data, manipulovat s nimi, vykreslovat grafy)

Čas pro studium
Prostudování této kapitoly může proběhnout buďto velmi rychle nebo také velmi pomalu. Jako autor skript Vám doporučuji, postupovat spíše pomalu a seznámit se s fungováním R. Čas, který do nástroje investujete se Vám bohatě vrátí při zpracování dat pro diplomovou práci a v praxi při zpracování libovolných dat.

7.1 Instalace prostředí

Před započetím práce bude potřeba připravit si pracovní prostředí. Během výuky budeme používat prostředí R a také editor RStudio. Nejprve provedeme instalaci samotného R. Prostředí je dostupné prakticky pro všechny používané operační systémy na https://www.r-project.org/. Stažení se provádí z CRAN. CRAN je síť serverů (zrcadel) sloužících pro obsluhu základní instalace R a také jeho toolkitů.

Jednotlivé servery jsou rozmístěny po celém světě, čímž je zajištěno, že stahování probíhá z místa, které je nejblíže uživatelům (a také je tím řešena vzájemná zastupitelnost v případě výpadku).

Základní instalace prostředí je dostupná Windows, Linux a Mac.

MS Windows

Přímý odkaz je https://cran.r-project.org/bin/windows/base/. Pro instalaci je potřeba stáhnout a spustit instalátor zvolené verze. Pro instalaci doporučujeme vždy poslední stabilní dostupnou verzi (v době psaní těchto skript to byla verze 4.0.2).

Po dokončení průvodce, budete mít k dispozici základní instalaci R, včetně jednoduchého editoru. Prostředí bude mít schopnost instalovat rozšiřující balíky, ale pouze v případě, že jsou dostupné v binární podobě. Bohužel velká část toolkitů je dostupná pouze v podobě zdrojového kódu, který je před použitím potřeba zkompilovat.

R tuto činnost provádí automatizovaně (z pohledu uživatele je většinou jediným rozdílem trochu delší doba instalace toolkitu) - potřebuje ale mít naistalovaná navíc RTools - ty jsou dostupné ke stažení z https://cran.r-project.org/bin/windows/Rtools/.

Po dokončení instalace RTools je možno ještě pokračovat dále instalací MikTeX, InnoSetup a Perl - tyto balíky ale nejsou povinné a pro naši práci je potřebovat nebudeme.

Ze stránek https://www.rstudio.com/ stáhneme a nainstalujeme *RStudio Desktop* - z dostupných edicí zvolíme Open Source Licenci, která je dostupná bezplatně.

Dostupné jsou i další zpoplatněné verze, které doplňují podporu a určitou pokročilou funkcionalitu pro práci v týmech, tvorby větších projektů apod., které pro náš způsob použití nebudeme potřebovat.

Po dokončení instalace RStudia máme k dispozici vše potřebné pro zahájení práce.

Mac (OS X)

Instalace pro Mac probíhá ve skutečnosti velmi podobně jako instalace pro Windows. Základní prostředí R instalujeme z balíku (.pkg souboru) staženého z https://cran.r-project.org/bin/macosx/ a RStudio z https://www.rstudio.com/.

Pro podporu kompilace je potřeba ale doinstalovat podporu pro Clang a Fortran, dostupnou z https://cran.r-project.org/bin/macosx/tools/. Podporu Tcl/Tk není potřeba moderních instalacích R řešit (je vestavěná). I tyto balíky stáhneme a nainstalujeme.

Linux

Verze R a RStudia je dostupná v repozitářích řady distribucí Linux. Tato verze ale nutně není nejaktuálnější. Pro naše účely by ale měla stačit.

Pro Ubuntu (a jiné distribuce založené na Debian) by mohla instalace z příkazové řádky vypadat následovně.

Výpis 7.1: Příklad instalačního skriptu pro Bash instalujícího nástroje R a RStudio pro distribuce OS Linux na bázi Debian Linux

```
sudo apt update
sudo apt-get install r-base
sudo apt-get install gdebi-core
cd ~/Downloads
wget https://download1.rstudio.org/rstudio-xenial-1.1.456-amd64.deb
sudo gdebi rstudio-xenial-1.1.456-amd64.deb
```

Prosím berte v úvahu, že Vaše instalace se může drobně lišit např. podle verze RStudia, kterou stáhnete. Místo instalace z repozitářů Vaší distribuce Linux, lze také přidat oficiální repozitář R podle návodu [63] a R instalovat z něj.

Podle stavu Vaší instalace Linuxu, mohou být vyžadovány také některé další balíky. Linux ale obvykle velmi dobře signalizuje, které balíky mu chybí. Takže odstranění těchto problémů by mělo být relativně bezbolestné.

Distribuce Linux navíc obsahují nástroje vyžadované pro kompilaci toolkitů, takže instalace dalších podpůrných balíků obvykle není vyžadována.

Oficiálně podporované jsou pak i distribuce RedHat (Fedora) a SuSe. Pokud používáte jinou distribuci Linux, bude nutné provést nejspíše kompilaci ze zdrojových kódů.

7.2 RStudio

Zkusme prozkoumat RStudio. Po spuštění se zobrazí rozhraní podobné obr. 7.1. V mém případě je RStudio provozováno na Macu (OS X), podle zvoleného operačního systému se proto vzhled může drobně lišit. Funkčně, ale mezi různými operačními systémy rozdíl není.

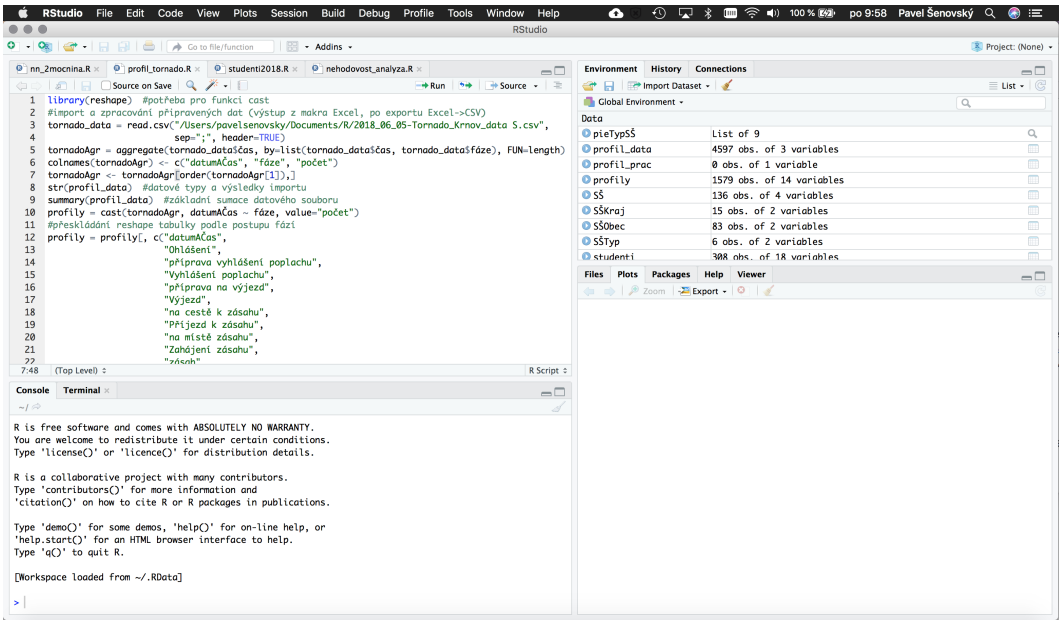

Obrázek 7.1: Rozhraní RStudio v OS X

Rozhraní RStudi má čtyři základní části:

- zdrojové kódy našich analytických projektů, popř. prohlížeč dat (vlevo nahoře)
- konzole R (vlevo dole)
- prostředí (s jednotlivými načtenými datasety) - vpravo nahoře
- soubory, grafy, nápověda ... vpravo dole

Nejvíce času strávíme zápisem příkazů jazyka R - tedy v části vlevo nahoře. Zde můžeme mít otevřenu řadu záložek obsahující soubory .R, se kterými právě pracujeme.

Např. na obr. 7.1 je znázorněn soubor řešící vytvoření časového profilu výjezdů jednotek HZS k zásahům vyvolaným tornádem v Krnově (2018). Editor podporuje zvýrazňování syntaxe, poskytuje bublinkovou nápovědu k jednotlivým parametrům používaných funkcí a také nápovědu podobnou intelisence - napovídající např. jména samotných funkcí.

Zapsané příkazy lze pak spouštět buďto jednotlivě po řádcích, postupným klikáním na tlačítko *Run*, nebo lze označit segmenty kódu, popř. celý obsah souboru a Run pak provede všechny takto označené kroky.

Kód R

Kód v R za určitých okolností dokáže být náročný. V tomto předmětu ale v R nebudeme programovat v tradičním smyslu tohoto slova. Kód je proto potřeba si představit spíše jako posloupnost funkcí tabulkového procesoru, ale bez nutnosti věci naklikat.

Z mnoha pohledů je R vlastně jednodušší než Excel. Na rozdíl od Excelu totiž R neřešíte, co se má dít na úrovni jednotlivých polí tabulek, ale co se má dít s daty jako takovými. Tento způsob práce je mnohem jednodušší, protože přesnou specifikaci postupu necháváte na R.

Efektivní použití nástroje ale vyžaduje, aby jeho uživatel provedl myšlenkový skok a akceptoval způsob, jakým R pracuje. To může bt zejména v počátcích práce problém.

Okno konzole obsahuje interaktivní konzoli R, do které lze přímo zadávat příkazy. Většina příkazů se zadává prostřednictvím kódu v editoru vlevo nahoře. Spouštění kódu pak generuje výstupy v konzoli. V případě, že ale chceme realizovat jednorázovou akci - např. instalaci nové knihovny, lze příkaz zadat do konzole přímo.

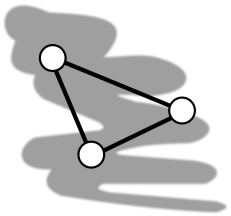

Proč R?
... a ne třeba Excel. MS Excel je skvělý produkt, ale v případě zpracování velkých objemů dat není právě nejpříjemnější. Excel také neobsahuje plnohodnotnou podporu statistických nástrojů, nebo nástrojů data miningu. K těmto účelům jej tak lze použít, ale uživateli s řešením těchto problémů příliš nepomůže.
Oproti tomu R prostřednictvím různých toolkitů má k dispozici celou škálu nástrojů pro řešení různých typů problémů, bez velikostních omezení. Produktivita práce je tak obvykle v případě R vyšší než u tabulkových procesorů. Cenou za rychlost je nutnost naučit se nové funkce (nebo se je naučit „vygooglovat“).

Při výkladu samotného jazyka tak budeme zkoumat jednak funkce R, jednak jejich výstup.
Vpravo nahoře je dostupný výpis prostředí R - zejména jaké proměnné jsou definovány se základními informacemi. V seznamu proměnných je vidět počet pozorování z počtu proměnných. To lze interpretovat jako počet řádků ve sloupcích - např. 4597 obs. of 3 variables znamenám, že tabulka obsahuje 4597 řádků a 3 sloupce. Kliknutím na modrou šipku vedle názvu proměnné můžeme získat seznam jejích sloupců včetně základních informacích o datovém typu sloupců a náhledu jeho hodnot, viz obr. 7.2.

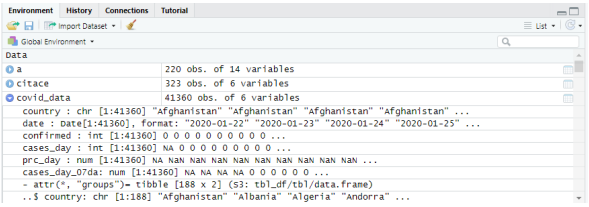

Obrázek 7.2: Podrobnosti o sloupcích tabulek, matic a dataframů v RStudio

Dvojitým kliknutím na název proměnné ji lze spustit v prohlížeči. Např. proměnná *tornado_data* vypadá v prohlížeči jako na obr. 7.3. Spuštění prohlížeče dat je možné provést taktéž kliknutím na ikonu tabulky , která le vždy u proměnné vpravo, viz obr. 7.2.

Filter

	Název.JPO	fáze	čas
1	stanice Krnov – 811011	Ohlášení	18.6.2013 17:30
2	stanice Krnov – 811011	Vyhlášení poplachu	18.6.2013 17:30
3	stanice Krnov – 811011	Výjezd	18.6.2013 17:31
4	stanice Krnov – 811011	Příjezd k zásahu	18.6.2013 17:33
5	stanice Krnov – 811011	Zahájení zásahu	18.6.2013 18:05
6	stanice Krnov – 811011	Odjezd na základnu	19.6.2013 4:35
7	stanice Krnov – 811011	Příjezd na základnu	19.6.2013 4:58
8	stanice Krnov – 811011	na cestě k zásahu	18.6.2013 17:32
9	stanice Krnov – 811011	na místě zásahu	18.6.2013 17:34
10	stanice Krnov – 811011	na místě zásahu	18.6.2013 17:35
11	stanice Krnov – 811011	na místě zásahu	18.6.2013 17:36
12	stanice Krnov – 811011	na místě zásahu	18.6.2013 17:37
13	stanice Krnov – 811011	na místě zásahu	18.6.2013 17:38
14	stanice Krnov – 811011	na místě zásahu	18.6.2013 17:39
15	stanice Krnov – 811011	na místě zásahu	18.6.2013 17:40

Showing 1 to 15 of 27,361 entries

Obrázek 7.3: Data Viewer - proměnná tornado_data

Všimněte si, že do prohlížeče nejsou načtena všechna data, ale pouze 15 záznamů. Prohlížeč totiž primárně slouží pro průzkum načtených proměnných, nikoliv jejich editaci. R předpokládá, že data byla pořízena v jiném systému. Do R se tak pouze naimportují a pak zpracují.
V prohlížeči tak pohodlně zjistíme, jak data vypadají, což nám umožní se následně efektivně rozhodnout o tom, co s nimi budeme dělat. V prohlížeči lze ale data filtrovat a vyzkoušet si tak např.

různé typy výběrů dat.

To samozřejmě neznamená, že data nelze upravovat - tyto úpravy ale nerealizujeme obvykle na úrovni jednotlivých buněk tabulky. Obvykle postupujeme tak, že z existujících dat odvozujeme data nová, popř. provádíme různé druhy transformací nad daty.

Konečně vpravo dole RStudio zobrazuje případná grafika, jako jsou grafy, apod. Lze zde také prohlížet vestavěnou nápovědu apod.

7.3 Základy jazyka R

Tato sekce obsahuje funkční segmenty R kódu, jejichž funkci si můžete prakticky vyzkoušet ve vlastní instalaci R. Doporučujeme proto nečíst text „na sucho“ - ale prakticky s ním experimentovat.

Operátory a proměnné

R podporuje všechny běžné operátory: +, -, *, /, ^(umocnění), %% (zbytek po dělení). Pro přiřazení lze použít buďto = nebo <- (lomená závorka následovaná pomlčkou). My v zápisech budeme používat rovnítko, v literatuře se ale <- používá velmi často.

Experimentovat můžeme v tomto případě přímo v konzoli.

Výpis 7.2: Základní oprátory R a přiřazení výsledku do proměnné

```
> 2 + 2
[1] 4
> 3 %% 2
[1] 1
> a = 5
> b = 3
> c = a * b
> a
[1] 5
> b
[1] 3
> c
[1] 15
```

V kódu výše rozlišujte mezi řádky začínající > tyto řádky odpovídají příkazům zadávaných do konzole. Řádky bez > jsou pak odpovědí systému na příkaz.

Tedy máme nějaké jednoduché sčítání (2 + 2), zbytek po dělení (3 %% 2) a do proměnné a přiřadíme hodnotu 5, do b hodnotu 3, obě proměnné sečteme a výsledek uložíme do proměnné c.

Obsah proměnné zobrazíme zavoláním jejího jména.

Pro úplnost uvádíme také operátory porovnání: rovno ==, není rovno !=, větší >, větší nebo rovno >=, menší <, menší nebo rovno <=.

Základní funkce

Komentáře začínají znakem #. Vše so po tomto znaku na daném řádku následuje, je považováno za komentář.

Výpis 7.3: Základní funkce v R

```
sqrt(4) # √4 = 2
abs(-4) # |−4| = 4
round(x, 2) # zaokrouhlí x na 2 desetinná místa
log(x) # přirozený logaritmus
log10(x) # logaritmus x o základu 10
log2(x)  # logaritmus x o základu 2
trunc(x) # odebrání desetinných míst (zůstane celá část x)
ceiling(x) # zaokrouhlení x nahoru
floor(x) # zaokrouhlení x dolů
exp(x)  # e^x
sin(x), cosin(x), tan(x) # trigonometrické funkce
asin(x), acos(x), atan(x) # inverzní trigonometrické funkce
```

Použití základních funkcí je relativně jednoduché, podívejme se jak na vektory.

Vektory

Výpis 7.4: Manipulace s vektory v R

```
a = c(1, 2, 3, 4) # vytvoří vektor 1, 2, 3, 4
b = c(TRUE, FALSE, TRUE, FALSE) # vytvoří vektor boolenovských hodnot
b2 = c(T, F, T, F) # je možno také zjednodušit T = TRUE, F = FALSE
c = c("one", "two", "three") # vytvoří vektor textových řetězců
class(a) # slouží pro zjištění datového typu (výsledek je numeric, character, integer, complex,
    logical)
d = as.integer(3) # vytvoří proměnnou typu integer o hodnotě 3
e = rep(v, times=3) # vytvoří vektor tak, že zopakuje první parameter (v) times krát
f = 1:5 # vytvoří vektor na základě sekvence 1, 2, 3, 4, 5, tedy od 1 do 5
g = seq(100, 2000, by=300) # vytvoří vektor na základě sekvence od 100 do 2000 s krokem 300
```

Základní funkcí, pro vytvoření vektoru je *c()*. Do závorek - parametrů funkce c - se pak dávají jednotlivé prvky, ze kterých má být vektor složen. Tímto způsobem lze skládat také vektory. Zkusme vytvořit vektory a, b obsahující čísla a následně tyto vektory spojme funkcí c(). Výsledný vektor bude obsahovat všechny prvky obou spojovaných vektorů.

Výpis 7.5: Spojování vektorů v R

```
> a = c(1, 2, 3)
> b = c(4, 5, 6)
> c = c(a, b)
> c
[1] 1 2 3 4 5 6
```

Data.Frame

Nejpoužívanější datovou strukturou v R je tzv. *Data.Frame*. Data.Frame si lze jednoduše představit jako tabulku. Zkusme udělat jednoduchý Data.Frame na základě vektorů obsahujících údaje o měsíčních prodejích:

Výpis 7.6: Realizace Data framu spojením vektorů v R

```
> ID = c(1,2,3,4)
> mesic = c("Leden", "Unor", "Brezen", "Duben")
> prodeje = c(15000, 20000, 125000, 40000)
> region = c("vychod", "zapad", "jih", "sever")
> prodejData = data.frame(ID, mesic, prodeje, region)
> prodejData
ID mesic prodeje region
1 1 Leden 15000 vychod
2 2 Unor 20000 zapad
3 3 Brezen 125000 jih
4 4 Duben 40000 sever
```

My z praktických důvodů budeme načítat většinou Data.Frame z externích souborů.
S jednotlivými sloupci tabulky lze poměrně dobře manipulovat.

Výpis 7.7: Manipulace se sloupci Data framu v R

```
prodejData[2] # vypíše sloupec mesic
prodejData[c("mesic", "region")] # vypíše sloupce měsíc a region
prodejData$prodeje  # vypíše sloupec prodeje
prodejData[1:2] # vypíše první 2 sloupce
prodejData[-c(2,3)] # odebere sloupce 2 a 3
prodejData[-3] # odebere sloupec 3
prodejData$ID = NULL # odebere sloupec ID
# přidá další řádek
prodejData[nrow(prodejData) + 1,] = c(5, "Unor", 25000, "vychod")
prodejData = prodejData[-nrow(prodejData)] # smaže poslední řádek
```

Všimněte si trošku odlišné práce buďto s označováním sloupců přes $ nebo přes [ ]. Zatímco notace $ umožňuje přistoupit pouze k jednomu (pojmenovanému sloupci), pak [ ] umožňuje filtrovat tabulku, např.

Výpis 7.8: Aplikace filtrů na sloupce Data framu v R

```
> podminka = prodejData$prodeje > 20000 & prodejData$mesic == "Leden"
> prodejData[podminka,] # vybere řádky splňující podmínku
[1] ID mesic prodeje region
<0 rows> (or 0-length row.names)
> prodejData[!podminka,] # vybere řádky, které nesplňují podmínku
ID mesic prodeje region
1 1 Leden 15000 vychod
2 2 Unor 20000 zapad
3 3 Brezen 125000 jih
4 4 Duben 40000 sever
5 5 Unor 25000 vychod
```

Podmínka je vytvořena na prodeje v lednu větší než 20 000. V našich datech, ale řádky splňující tuto podmínku nejsou - R zahlásí <0 rows>. Alternativně můžeme explicitně vypsat řádky které podmínku nesplňují (!pominka). V tomto případě se nám zobrazí všechna data.

Tabulky je možno také řadit:

Výpis 7.9: Řazení v Data framu

```
prodejData[order(prodejData$prodeje),] # seřadit řádky datasetu prodejData podle prodejů
# seřadí podle prodejů a tam kde jsou stejné podle měsíce
prodejData[order(prodejData$prodeje, prodejData$mesic)]
prodejData[, order(names(prodejData))] # seřadí abecedně sloupce datasetu
```

Všimněte si, že u řazení a filtrací rozhoduje o tom, na co se budou aplikovat čárka v [ ] - tedy [řádky, sloupce].

Faktory

Pokud se podíváme na sloupec *mesic* v předchozí tabulce - ve skutečnosti měsíc nutně nemusí být vyjádřen textovým řetězcem - mohli bychom jej vyjádřit také číselně: 1 - leden, 2 - únor, ...

Podobně když uvažujeme o známkách ve škole pak můžeme známku vyjádřit slovně nebo číselně: 1 - výborně, 2 - velmi dobře, ... V případě měsíců i známek nám přitom záleží na přesném mapování čísel a jejich textového označení. Každopádně se z analytického pohledu jedná o tzv. nominální popř. ordinální proměnné.

K nominálním proměnným nelze připojit „kvantitu“ - tedy, pokud hodnotám takových proměnných přiřadíme čísla, pak tato čísla jsou pouze rozlišujícím znakem, ale neumožňují porovnání. Známkování je pak dobrým příkladem ordinální proměnné - zde lze provést řazení, podle zvoleného klíče.

R tento typ transformací řeší přes faktory. Uvažujme o příkladu známkování:

Výpis 7.10: Použití faktorů v R

```
znamky = c("vyborne", "velmi dobre", "dobre", "nedostatecne") # vektor typu character
znamky = factor(znamky)
znamky
```

Funkce *factor* přiřadí převáděným položkám integer hodnotu, tato hodnota, ale není viditelná. Jak to funguje můžeme zjistit porovnáním dvou prvků vektoru známky (po převodu na faktor). Můžeme zkusit např. min(znamky), ale R se bude bránit. Pomocí factor jsme v našem příkladu totiž převedli proměnnou typu character na nominální proměnnou. My už víme, že v takovém případě porovnávání nemá smysl.

Ordinální proměnnou uděláme z nominální specifikací hodnot použité škály v rámci funkce factor:

Výpis 7.11: Vytvoření ordinální proměnné v R

```
> znamky = c("vyborne", "velmi dobre", "dobre", "nedostatecne")
> znamky = factor(znamky,
levels=c("vyborne", "velmi dobre", "dobre", "nedostatecne"),
ordered=TRUE)
> znamky[1] > znamky[2]
[1] FALSE
> min(znamky)
[1] vyborne
Levels: vyborne < velmi dobre < dobre < nedostatecne
```

```
> max(znamky)
[1] nedostatecne
Levels: vyborne < velmi dobre < dobre < nedostatecne
```

Nejen, že v tomto případě lze vzájemně porovnávat položky, lze používat i některé funkce (např. min a max).

Známkování - změna pořadí
Z čistě formálního pohledu by v příkladu výše mělo být pro známkování použito obrácené pořadí - použijte své nově nabyté znalosti a změňte pořadí tak, aby odpovídalo způsobu jak obvykle známkujeme.

Import a export dat v R
Jednu z nejčastějších úloh, kterou potřebujeme řešit prakticky v každém data miningovém projektu je import dat. Data lze importovat z různých datových zdrojů (různých databází, MS Excel, textových souborů apod.). Při importu je potřeba vždy zohlednit omezení, která nástroj pro import má.

Jako nejjednodušší a zároveň nejspolehlivější se většinou uvádí výměnný formát Comma Separated Values (CSV). Jedná se o čistě textový formát, kde řádek tabulky tvoří jeden řádek textového souboru a sloupce jsou oddělovány zvoleným oddělovačem - např. čárkou (může být však použit také jiný oddělovač).

Import z CSV souboru by mohl vypadat následovně:

Výpis 7.12: Načtení CSV souboru

```
import_data = read.csv(cesta, sep=";", header=TRUE)
str(import_data)
```

V tomto případě se bude importovat soubor identifikovaný cestou k tomuto souboru. Jako oddělovač sloupců je použit středník. Importovaný soubor obsahuje v prvním řádku hlavičku. Za import samotný je zodpovědná funkce read.csv.

Kromě této funkce existují další, které lze k tomuto účelu použít:

- read.table - nejuniverzálnější funkce pro import textových datových souborů
- read.delim - pro textové soubory s tabulátorem jako oddělovačem sloupců
- read.csv2 a read.delim2 - jako oddělovač desetinných míst se používá čárka

Všimněte si také funkce str v příkladu výše - ta je velmi důležitá protože vypíše informaci o identifikovaných datových formátech jednotlivých sloupců a celkový počet řádek. Tady je potřeba dodat, že způsob, jakým jsou data importována často neodpovídá záměrům, které s daty máme - řádky je proto potřeba často upravovat, měnit jejich formáty apod.

Pro import z relačních databází je možno použít toolkity specializované na danou databázi, např. RMySQL, ROracle, RPostgreSQL, RSQLite, RODBC. Posledně zmíněný je možno považovat za do velké míry univerzální, protože umožňuje přistoupit k databázi pomocí ODBC rozhraní. Přitom prakticky všechny relační databáze ODBC v nějaké formě podporují.

Analogickou operací k importu je export dat. V případě, že chceme použít CSV soubor, mohl by export vypdat následovně.

Výpis 7.13: Zápis dat do textového souboru

```
write.table(data_k_exp, file = "cesta k souboru.csv", sep=";", row.names=FALSE,
fileEncoding = "UTF-8")
```

Export je tedy relativně přímočarý. Data musí před voláním funkce write.table uložená jako tabulka nebo data.frame. V případě, že data obsahují text s interpunkčními znaménky je potřeba specifikovat také parametr fileEncoding specifikující znakovou sadu, která má být použita během exportu. V našem případě je používáno UTF-8, což je více méně univerzální kódování.

Parametr row.names specifikuje, že se nemají při exportu používat popisky řádků. Popisky R přidává jinak k datům automaticky prostě tak, že k řádku přidá pořadové číslo tohoto řádku v datovém souboru.

Základní statistické funkce

Základní přehled funkcí:

Výpis 7.14: Základní statistické funkce v R

```
mean(x) #průměr z x
length(x) #počet prvků v x
median(x) #medián z x
unique(dataset) #z předloženého datasetu vytvoří vektor obsahující pouze unikátní položky datasetu (tedy bez opakování)
range(x) #vrací rozsah hodnot v předloženém datasetu (nejmenší a největší), vrací jej jako dvouprvkový vektor
quantile(x, probs=seq(0, 1, 0.25)) #R nezná quartily, v tomto případě se to obchází jednoduchou sekcencí od 0 do 1 po 0.25. Místo sekvence lze zadat i jednu položku
sd(x) #standardní odchylka (standard deviation)
min(x), max(x) #minimum a maximum
var(x) #rozptyl
summary(x) # poskytuje přehled základních statistik (min, první kvartil, medián, průměr, třetí kvartil, max), pokud u výše uvedených funkcí místo parametru ve formátu vektoru použijeme data.frame, provede se výpočet pro všechny sloupce framu.
```

Vykreslování grafů

R obsahuje řadu režimů a knihoven pro vykreslování grafů. V této podkapitole jsou ukázány příklady nejjednoduššího prostředí pro tvrobu grafů, které je v rámci R dostupné. V samostatné podkapitole věnované knihovně Plotly bude ale ukázány pokročilejší možnosti tvorby grafů.

Nejjednodušší funkce pro tvorbu grafů jsou následující:

- plot - běžné grafy
- hist - histogram
- pie - koláčový graf
- boxplot - graf typu box and whiskers

Bohužel tento typ grafů nevypadá vizuálně hezky. R poskytuje alternativu k tomuto prostředí pomocí knihovny GGPlot2, která umožňuje vytvářet graficky extrémně sofistikovanou grafiku. Cenou za větší možnosti knihovny je ale podstatně vyšší komplexita nastavení.

My v těchto skriptech nebudeme mít prostor pro zvládnutí této knihovny, případně se ale do studia můžete pustit sami. Grafické příklady (k motivaci) lze najít např. na Google při vyhledání „image ggplot2“.

Pro demonstraci můžeme použít vestavěný dataset iris, který obsahuje některé charakteristiky odrůd kosatců:

Výpis 7.15: Vykreslování základních typů grafů pro dataset IRIS

```
summary(iris)
plot(iris)
plot(iris$Sepal.Length~iris$Sepal.Width, col="red",
main="Delka vs sirka kosatcu", xlab="delka listu",
ylab="sirka listu")
hist(iris$Sepal.Length, col="blue", main="Rozlozeni delky listu",
xlab="delka listu", ylab="frekvence")
boxplot(iris, las=2,
main="Boxplot graf namerenych vlastnosti kosatcu", at=c(1,2,4,5,7),
names=c("Sep.length", "Sep.width", "Pet.length", "Pet.wight", "Species"),
col=c("red", "red", "blue", "blue", "green", "green"))
```

Datový soubor obsahuje popis vlastností vzorku rostlin - především pak délku a šířků listů a okvětních lístků. Funkce plot(iris) vykreslí párové srovnání sloupců datového souboru, viz obr. 7.4.

Názvy sloupců se vykreslují na diagonále grafu. Všimněte si, že grafy nad a pod diagonálou jsou podle diagonály zrcadlově obráceny.

Takový typ grafu se často používá pro rychlou vizualizaci hodnot v datovém souboru. Mnohem častěji, ale potřebujeme získat větší kontrolu nad vykreslováním grafu.

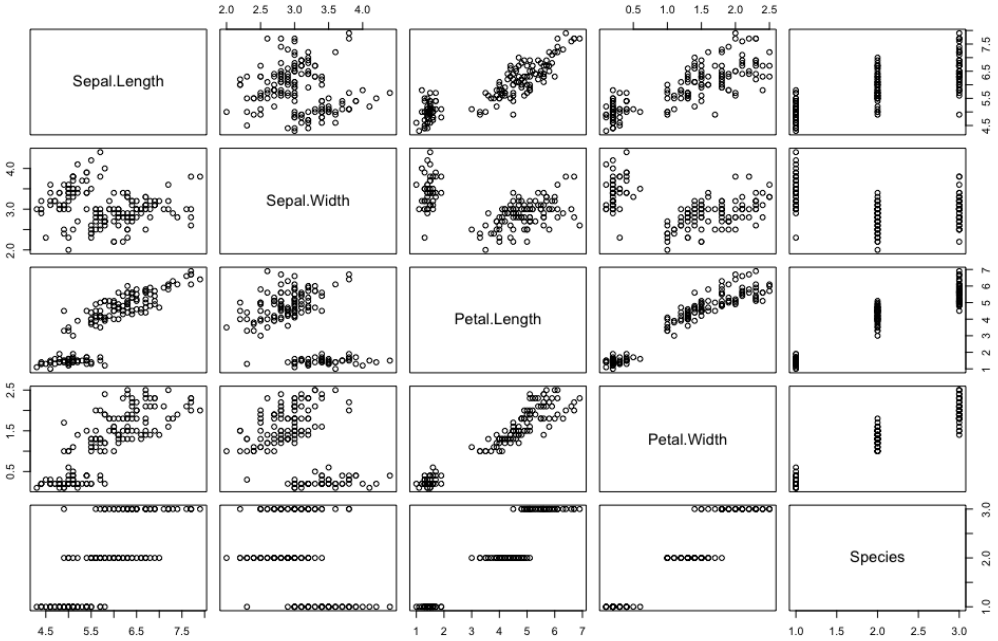

Obrázek 7.4: Párové srovnání vlastností kosatců v datové sadě iris

Delší forma zápisu specifikuje bodový graf, ale definuje pro něj řadu parametrů. Prvním parametrem jsou přitom data, která se mají vykreslit. Tato data se definují ve formátu osa_X ~osa_Y. Oddělovačem os je pak znak tilda (vlnovka). Podle toho, co potřebujeme nastavit můžeme použít jeden nebo více parametrů.

V našem případě jsou nastavovány barva bodů (col), popisky os (xlab, ylab) hlavní nadpis grafu (main). Graf je znázorněn na obr. 7.5.

V rámci funkce plot lze také změnit způsob vykreslování. Iris dataset se ale k tomuto účelu nehodí. Pro demonstraci proto použiji námi v rámci skript vytvořený dataset prodejData a vizualizovat budeme prodeje. Všechny typy vykreslování (příkladu níže) jsou znázorněny na obr. 7.6.

Výpis 7.16: Funkce *plot* - jednotlivé typy grafů

```
1 plot(prodejData$prodeje, type="p")
2 plot(prodejData$prodeje, type="l")
3 plot(prodejData$prodeje, type="b")
4 plot(prodejData$prodeje, type="h")
```

Vraťme se ale k datasetu iris - příklad histogramu je na obr. 7.7. I u histogramu lze použít řadu parametrů. Pro obr. 7.7 byla pomocí parametru col nastavena barva na modrou a přidány popisky os a grafu jako takového (parametry xlab, ylab, main).

Dalším typem grafu, který graf typu box and whiskers - viz obr. 7.8. Tento typ grafu je velmi populární pro rychlou vizuální kontrolu rozložení hodnot jednotlivých proměnných. Struktura vykreslovaného boxu je následující (zhora dolů):

- horní outliners (hodnoty $>$ 1.5 * IQR, kde IQR (interquartile range) je oblast mezi 3. a 1. kvartilem)
- maximum
- 3. kvartil
- medián
- 1. kvartil
- minimum
- dolní outliners

Také funkce boxplot má řadu parametrů, kromě těch, které jsme použili u ostatních grafů jsem použil v příkladu parametr las=2, který seskupuje položky po dvojicích. Tímto způsobem jsem zdů-

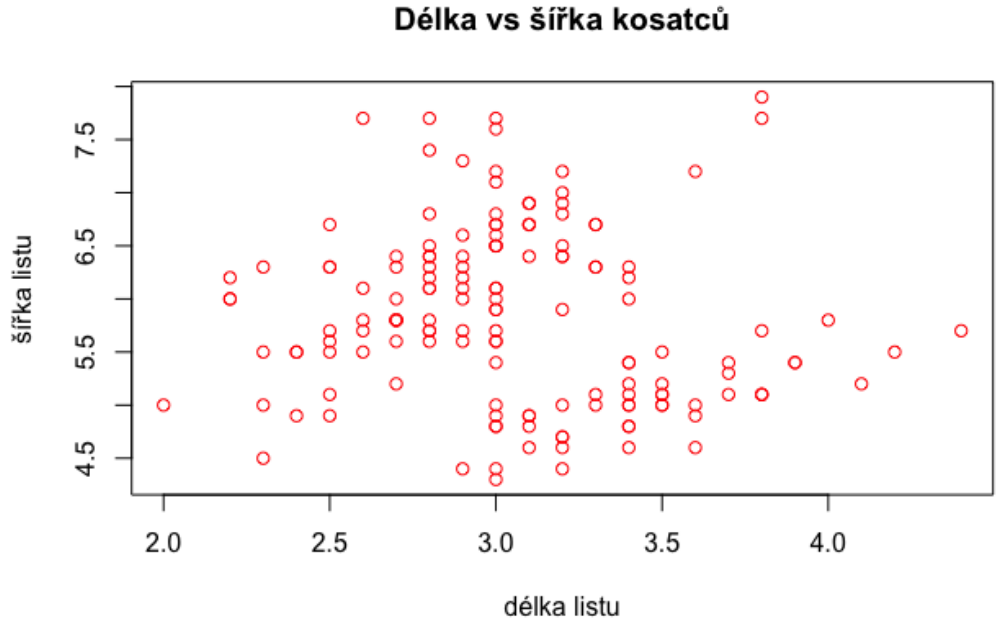

Obrázek 7.5: Délka vs šířka listu kosatců v datasetu iris (bodový graf)

raznil souvislost mezi položkami. Patametr at se zadává jako vektor popisující umístění jednotlivých položek v grafu. Všimněte si že pozice 3 a 6 jsou vynechány čímž vznikají v grafu mezery.

Pomocí parametru names lze přepsat názvy polí. Pomocí parametru col jsou definovány barvy. V tomto případě jsou barvy zadávány vektorem.

Poslední typ grafu, který jsem ještě neprobrali, je graf koláčový vytvářený funkjcí *pie*. Tento graf je do určité míry specifický, protože vyžaduje určitou přípravu dat. Data, která jsou používána pro jeho vytvoření musí být agregovaná.

Funkce pie tak nemá agregaci zabudovanou přímo v sobě. Pro demonstraci použijeme náš upravený dataset prodejů. Jeho úpravu a vykreslení koláčového grafu budeme realizovat následujícím skriptem:

Výpis 7.17: Tvorba koláčových grafů v R

```
1  vykon <- c("mizerny", "mizerny", "skvely", "prumerny", "skvely")
2  vykon <- factor(vykon, levels=c("mizerny", "prumerny", "skvely"))
3  prodejData$vykon <- vykon
4  prodeje = table(prodejData$vykon)
5  prodeje
6  pie(prodeje, main="Rozlozeni prodeju")
```

Všimněte si způsobu, jakým došlo ke zpracování údajů v proměnné prodeje. Takové údaje je již možno zobrazit v koláčovém grafu, viz obr. 7.9.

```
mizerný průměrný   skvělý
      2         1        2
```

7.4 Knihovna dplyr

Knihovna dplyr je jednou z nejpoužívanějších knihoven v rámci jazyka R. Jejím hlavním účelem je přidání operátoru „roury“ (pipe), který mění (zjednodušuje) výrazně filozofii práce s R. Jelikož dplyr závisí na řadě dalších knihoven. Pro demonstraci použijeme externí data o aktuálním stavu nákazy COVID-19 dostupná z John Homkins University.

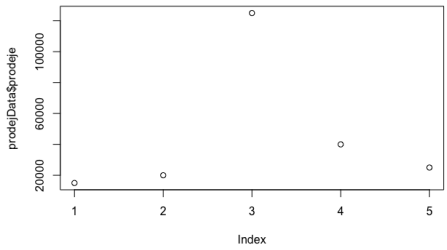

(a) type = „p“

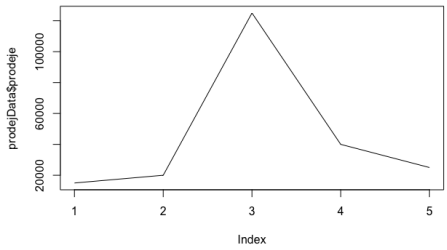

(b) type = „l“

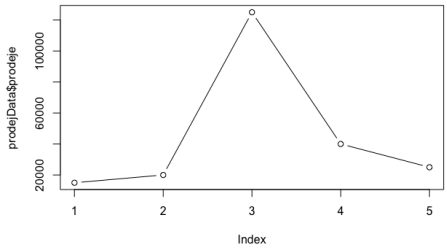

(c) type = „b“

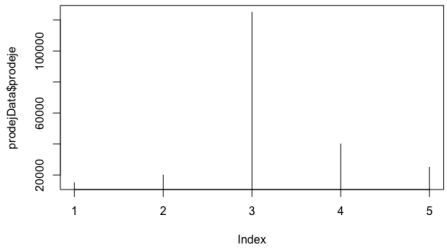

(d) type = „h“

Obrázek 7.6: Dostupné typy vykreslování ve funkci plot

Dostupná data se nachází ve třech samostatných datových zdrojích, které budeme postupně načítat a transformovat. K tomuto účelu použijeme v předchozí podkapitole vysvětlenou funkci *read.csv*. V tomto případě, ale budeme načítat data z webové adresy, nebudeme je tedy předem ukládat na disk.

Data jsou dostupná ve třech sadách pro potvrzené případy (time_series_covid19_confirmed_global.csv), zaznamenaná úmrtí (time_series_covid19_deaths_global.csv) a uzdravení (time_series_covid19_recovered_global.csv). Data jsou dostupná ve formátu:

- Province.State - region státu,
- Country.Region - stát,
- Lat - zeměpisná šířka,
- Long - zeměpisná délka,
- Xměsíc.den.rok - sloupce obsahující sledovanou položku (počet potvrzených případů, úmrtí nebo uzdravených) podle souboru, který je právě zpracováván.

Výpis 7.18: Načtení dat o COVID z John Hopkins university do R

```
1   library("curl")
2  con = curl("https://raw.githubusercontent.com/CSSEGISandData/COVID-19/master/csse_covid_19_data/csse_
       covid_19_time_series/time_series_covid19_confirmed_global.csv")
3  ts_conf = read.csv(text = readLines(con))
4  close(con)
5  con = curl("https://raw.githubusercontent.com/CSSEGISandData/COVID-19/master/csse_covid_19_data/csse_
       covid_19_time_series/time_series_covid19_deaths_global.csv")
6  ts_death = read.csv(text = readLines(con))
7  close(con)
8  con = curl("https://raw.githubusercontent.com/CSSEGISandData/COVID-19/master/csse_covid_19_data/csse_
       covid_19_time_series/time_series_covid19_recovered_global.csv")
9  ts_reco = read.csv(text = readLines(con))
10 close(con)
```

Data jsou tedy v tzv. *širokém* datovém formátu. S takovým formátem se nepracuje úplně jednoduše. Široký formát znamená, že každý stát v datovém souboru má jeden řádek. Data samotná vztažená k jednotlivým datům jsou pak umisťovaná do sloupců Xdatum. Takový formát obvykle pro zpracování nepreferujeme - potřebujeme jej převést do *dlouhého* formátu.

Veškeré potřebné transformace jsou zachyceny na příkladu zpracování datasetu potvrzených případů.

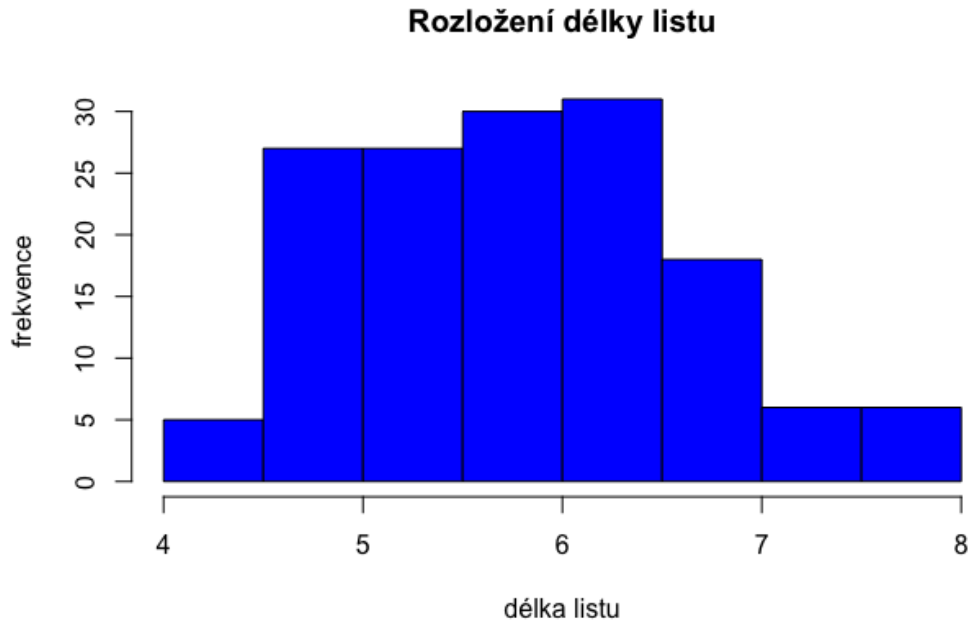

Obrázek 7.7: Rozložení délky listu dataset iris (histogram)

Výpis 7.19: Zpracování dat o potvrzených případech pomocí R

```
1  library("dplyr") #manipulace s daty
2  library("stringr")
3  library("tidyr") # tidy data
4  library("zoo") #pro výpočet plovoucího průměru
5  covid_data = ts_conf %>%
6    select(-"Province.State", -Long, -Lat) %>%
7    gather(date, cases, -"Country.Region") %>%
8    rename(country = "Country.Region") %>%
9    group_by(country, date) %>%
10   summarize(confirmed = sum(cases))
11 covid_data$date = str_remove(covid_data$date, "[X]")
12 covid_data$date = as.Date(covid_data$date, '%m.%d.%y')
13 covid_data$country <- covid_data$country %>%
14 recode('Taiwan*' = "Taiwan",
15   'Korea, South' = "South Korea")
16 staty = unique(covid_data$country)
17 newCovid = NULL
18 for (stat in staty) {
19   a = covid_data[covid_data$country == stat,]
20   a = a[order(a$date),]
21   a = mutate(a, cases_day = (confirmed - lag(confirmed, n = 1L)))
22   a = mutate(a, prc_day = (cases_day/ (lag(confirmed, n = 1L)/100)))
23   newCovid = rbind(newCovid, a)
24 }
25 covid_data = newCovid %>%
26   mutate(cases_day_07da = rollmean(cases_day, k = 7, fill = NA))
```

Zpracování dat je pro začátečníka složitější, ale pokud se podíváme na údaje podrobněji, pak postup je poměrně jednoduchý. Nejprve je potřeba připojit jednotlivé knihovny. Knihovny dplyr a tidyr poskytují převážnou část funkčnosti, kterou využíváme pro zpracování dat.

Pomocí nástroje roura (pipe) %>% provádíme směřování výstupu. Např. na řádku 5 posíláme data načtená do ts_conf do funkce *select*, kte provádíme výběr sloupců které nás zajímají. Obcházíme tím nutnost použít řadu pracovních proměnných, do kterých bychom jinak museli ukládat mezivýsledky celého procesu.

Dplyt podporuje následující funkce:

- *mutate()* - vytvoření nového sloupce z dat v ostatních sloupcích (mutace dat)

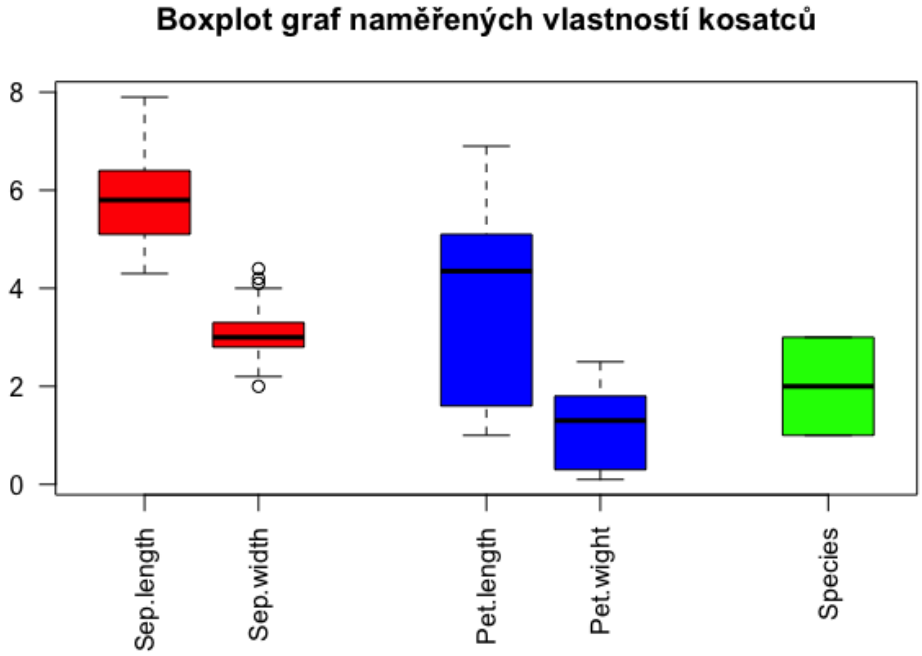

Obrázek 7.8: Délka listu dataset iris (boxplot)

- *arrange()* - specifikuje podle čeho se má provést řazení
- *filter()* - umožňuje specifikovat parametry výběru řádků tabulky
- *slice()* - umožňuje vybrat podmnožinu řádků na základě jejich polohy, např. vyber prvních 5 řádků z ts_conf: ts_conf %>% slice(1:5)
- *select()* - umožňuje specifikovat pozitivně nebo negativně sloupce, které mají, nebo naopak nemají být vybrány, např ts_conf %>% select(-"Province.State") specifikuje, že z dat v ts_conf se má odstranit sloupec "Province.State".
- *rename()* - umožňuje přejmenovat sloupec nebo sloupce, např. ts_conf %>% rename(country = "Country.Region") provede přejmenování sloupce "Country.Region"na country. Pokud je potřeba přejmenovat více sloupců, pak se oddělují čárkou.
- *group_by()* - umožňuje provést seskupení dat podle hodnot ve specifikovaných sloupcích. Seskupení se provede tam, kde hodnoty v zadaných sloupcích jsou stejné. Seskupování provádíme obvykle tam, kde chceme aplikovat nějakou funkci - v našem případě získat kumulovanou hodnotu nakažených.
- funkce group_by() je pak revokována pomocí funkce *ungroup*. Tato funkce se aplikuje až v případě, kdy už data v seskupené podobě nepotřebujeme.
- *summarize()* - aplikuje sumarizační (agregační) funkci. V našem příkladu jsne použili funkci *sum()* pro součet, je možné ale použít řadu jiných funkcí *mean()* pro průměr, *median()* pro medián, *n()* pro počet seskupených záznamů a řada dalších.
- poslední skupinu funkcí tvoří funkce pro spojování tabulek. Z hlediska použití je nejčastější funkce *inner_join()*, která zabezpečuje vnitřní spojení, podporovány jsou ale také další typy spojení podle toho k jakým údajům se ve výsledku potřebujete dostat.

Funkce *gather()* v příkladu provádí rekódování dat z širokého formátu do dlouhého formátu.

Z výsledku našeho snažení obsaženého v proměnné covid_data nejprve z data pomocí funkce *str_remove()* odstraníme X. Tato funkce je obsažena v knihovně stringr. Výsledek je ale stále ve formátu textového řetězce. Pomocí funkce *As.Date()* jej převedeme na datum. Tato transformace je potřebná k tomu, aby data bylo možné podle data správně řadit a také k jednotlivým dnům v případě potřeby data agregovat.

Nejméně pochopitelnou částí výpisu výše je pravděpodobně cyklus. Pro jeho pochopení je potřeba si uvědomit, jak jsou vlastně data konstruovaná. Hlavním údajem, který je ve zpracovávaných datech ukládán je počet potvrzených případů v daném státu a v daném dni. Tento počet je ale kumulovaný,

Obrázek 7.9: Rozložení počtu prodejů podle jejich úspěšnosti (pie)

pokud nás zajímají údaje o vývoji v jednotlivých dnech, např. kolik nových případů se objevilo, pak je nutné tento údaj odvodit. K tomuto účelu je použita funkce *lag()* která umožňuje jít v časové řadě zpět nebo dopředu o zvolený počet kroku, v našem případě dní.

Z tohoto vyplývá, že počet nově infikovaných v daném dni je možno odvodit jako rozdíl kumulovaného počtu infikovaných ve dni hodnocení a stejného údaje den předem: cases_day = (confirmed - lag(confirmed, n = 1L)). Stejným způsobem je odvozeno procento nárůstu prc_day.

Konečně nad výsledkem je proveden výpočet sedmidenního klouzavého průměru případů, pomocí funkce *rollmean()* z knihovny zoo.

Obdobným způsobem můžeme zpracovat datové sady zemřelých ts_death a uzdravených ts_recovered.

Výpis 7.20: Zpracování dat o potvrzených případech úmrtí v důsledku COVID-19 pomocí R

```
covid_death = ts_death %>%
  select(-"Province.State", -Long, -Lat) %>%
  gather(date, cases, -"Country.Region") %>%
  rename(country = "Country.Region") %>%
  group_by(country, date) %>%
  summarize(confirmed = sum(cases))
covid_death$date = str_remove(covid_death$date, "[X]")
covid_death$date = as.Date(covid_death$date, '%m.%d.%y')
covid_death$country <- covid_death$country %>%
  recode(`Taiwan*` = "Taiwan",
    `Korea, South` = "South Korea")
    newCovid = NULL
for (stat in staty) {
  a = covid_death[covid_death$country == stat,]
  a = a[order(a$date),]
  a = mutate(a, cases_day = (confirmed - lag(confirmed, n = 1L)))
  a = mutate(a, prc_day = (cases_day/ (lag(confirmed, n = 1L)/100)))
  newCovid = rbind(newCovid, a)
}
covid_death = newCovid %>%
  mutate(death_day_7da = rollmean(cases_day, k = 7, fill = NA))
```

Poslední operací, kterou s daty uděláme, je realizace propojení tabulek do jednoho celku. To nám umožní s daty manipulovat najednou.

Počty uzdravených
Jak je patrné z výpisu kódu v R pro zemřelé, je proces transformace dat totožný. Stejně tomu bude i s daty o uzdravených.

Zkuste proto samostatně navrhnout skript, kterým tato data transformujete.

V případě, že Vám to opravdu nejde můžete konzultovat hotový skript, který je dostupný na LMS.

Výpis 7.21: Propojení souvisejících dat do jednoho celku pomocí R

```
covid_join <- covid_data %>% inner_join(covid_death, by = c("country", "date"))
covid_join <- covid_join %>%
  rename (
    confirmed = confirmed.x,
    cases_day = cases_day.x,
    prc_day = prc_day.x,
    death = confirmed.y,
    death_day = cases_day.y,
    death_day_prc = prc_day.y
  ) %>%
  mutate(death_prc = death/(confirmed/100))
covid_join <- covid_join %>% inner_join(covid_reco, by = c("country", "date"))
covid_join <- covid_join %>%
  rename (
  confirmed = confirmed.x,
  recovered = confirmed.y
  )
covid_join$nemocni <- covid_join$confirmed - covid_join$recovered - covid_join$death
```

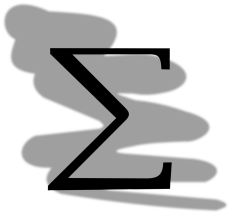

Dplyr - shrnutí
V této kapitole jsme odvedli velký kus práce. Naučili jsme se importovat data z Internetu a provést jejich transformaci do formátu, který můžeme dále zpracovávat. Naučili jsme se také, jak lze data obsažená v samostatných tabulkách propojovat, abychom získali ucelený data set.

Operace tohoto typu jsou pro data mining typické a zabírají velké množství času, pokud ale zvládneme funkce, které jsou nabízeny knihovnami jako je *dplyr* může být tato práce výrazně jednodušší.

V následující podkapitole budeme připravená data vizualizovat pomocí různých grafů.

7.5 Grafy pomocí knihovny Plotly

Plotly je oblíbená knihovna pro vykreslování grafů různého typu. V této podkapitole si ukážeme prakticky některé základní typy. Knihovna, ale umožňuje vykreslovat data také pomocí exotičtějších typů grafů. Grafy jsou takovým oknem, kterým můžeme data zkoumat v podobě, která je obvykle pochopitelnější než jsou data v hrubé - tabelární podobě.

Graf je tedy mocným nástrojem, kterým můžeme předat efektivně informaci a přesvědčit příjemce takové informace o její správnosti. Správné prezentaci dat je proto potřeba věnovat patřičnou pozornost.

Pro knihovnu Plotly v R existuje skvěle zpracovaný tutoriál na https://plotly.com/r/. Tento tutoriál doporučuji konzultovat jako první v případě, že Vám nějaká data nepůjdou zobrazit způsobem, který očekáváte nebo jste prostě z hlediska svých potřeb přesáhli objem informací poskytovaných těmito skripty.

Jako první zkusme zpracovat jednoduchý graf vývoje sedmidenního klouzavého průměru počtu nemocných. Provedeme srovnání zemí, se kterými bývá někdy Česká republika srovnávána: tedy ČR, Nizozemí a Švédska.

Výpis 7.22: Sedmidenní klouzavý průměr nakažených v ČR Nizozemí a Švédsku

```
covid_plot <- covid_data %>%
  filter(cases_day > 0 & country %in% c("Czechia", "Sweden", "Netherlands")) %>%
  group_by(country)
fig <- plot_ly(data = covid_plot,
    x = ~covid_plot$date,
    y = ~covid_plot$cases_day_07da,
    mode = 'lines',
    type = "scatter",
    color = covid_plot$country) %>%
  layout(
    title = "Pocet pripadu v jednotlivych dnech - 7-mi denni klouzavy prumer",
    xaxis = list(title = "datum"),
    yaxis = list(title = "nove pripady"),
    legend = list(x = 0.01, y = 0.9))
fig
```

Výsledkem je graf na obr. 7.10.

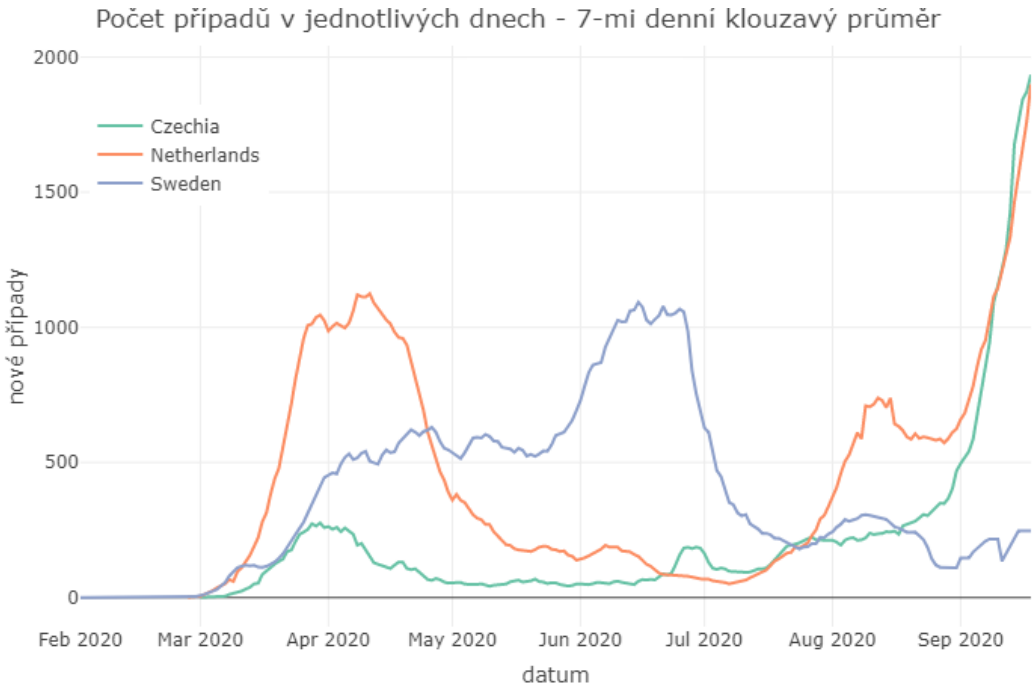

Obrázek 7.10: Počet případů COVID-19 v jednotlivých dnech - 7-mi denní klouzavý průměr

Všimněte si jakým způsobem pracujeme. Nejprve jsme si z obecných dat (covid_data, ale fungovalo by také použití spojené tabulky covid_join) vybereme údaje, která nás zajímají. V našem případě vyfiltrujeme státy ČR, Švédsko a Nizozemí. Výsledek uložíme do dočasné proměnné covid_plot. Alternativně bychom mohli data rovnou poslat rourou do funkce *plotly()*, která slouží pro přípravu grafu.

Graf připravujeme do samostatného objektu nazvaného v našem případě fig, který následně zavoláme a systém provede vykreslení grafu podle specifikovaných parametrů.

Parametry jsou následující:

- *data* - odkaz na tabulku obsahující data
- *x* a *y* - odkazy na sloupce obsahující data, která odpovídají hodnotám na osách x a y
- *mode* - mód vykreslování, v našem případě *lines*, tedy čára, může být ale také markers (body) nebo obojí dohromady lines+markers.
- *type* - typ grafu, v našem případě používáme *scatter*, což je bodový graf (XY)
- *color* - specifikuje podle čeho se mají rozlišit barvy v grafu

Samostatně se následně definuje rozložení prvků grafu jako je *title* - titulek grafu, *xaxis* a *yaxis* pro nastavení os. V našem případě nastavujeme pouze popisek a nic více. Lze ale např. nastavit,

aby se použila logaritmická škála apod. Konečně položka *legend* umožňuje nastavit x-ovou a y-ovou souřadnici levého horního rohu legendy. Naše hodnota x = 0.01 a y = 0.9 odpovídá umístění skoro úplně vlevo a skoro nahoře.

Rozsah hodnot je vždy 0 - 1. Pravému spodnímu okraji budou odpovídat souřadnice třeba x = 0.8, y = 0.1. Umístění je ale vždy potřeba vizuálně vyzkoušet a podle potřeby doupravit. Různě dlouhý text popisku a počet položek legendy může způsobit že třeba výše uvedené hodnoty nebudu postačovat. Pokud souřadnice neuvedeme, pak se legenda uvede vedle grafu - vůbec tedy do něj nezasáhne.

Všimněte si také, že výsledný graf je interaktivní. Pokud najedete kurzorem na křivku grafu v RStudiu začne Vám ukazovat naměřenou hodnotu místa, kam ukazuje Váš kurzor. Kliknutím a tažením můžete specifikovat výřez, což umožňuje jednoduchý průzkum různých částí křivky.

To je výhodné zejména v okamžiku, kdy jsme na počátku procesu data miningu a hledáme cesty, jak lépe porozumět datům. Také nám to umožňuje pouze „na hrubo“ nastavit potřebné rozsahy s tím, že výřezem upravíme oblast grafu, která nás zajímá.

Po najetí kurzorem na graf se zobrazí také panel nástrojů (na horním okraji grafu). Zde je dostupný např. nástroj, kterým můžete výsledek Vaší práce exportovat do PNG formátu vhodného pro vložení do MS Word nebo jiného textového procesoru.

Jednoduchý graf - úprava zemí
Upravte předchozí graf tak, aby zobrazoval sedmidenní klouzavé průměry nakažených v ČR a států s ní sousedících.

Zkusme vytvořit graf, který zobrazí body ale v logaritmické škále. Využijeme toho, že exponenciální růst se pod takovým měřítkem jeví jako diagonála. Abychom tento efekt viděli na našich datech budeme vykreslovat denní přírůstek vůči celkovému (kumulovanému) počtu nakažených.

Výpis 7.23: Logaritmické osy grafu - demonstrace vizualizace exponenciálního růstu

```
covid_plot <- covid_data %>%
  filter(country %in% c("China", "Italy", "Spain", "US", "Czechia", "South Korea")) %>%
  group_by(country)
fig <- plot_ly(data = covid_plot,
    x = ~covid_plot$confirmed,
    y = ~covid_plot$cases_day,
    mode = 'markers',
    type = "scatter",
    color = covid_plot$country) %>%
layout(
  title = "Exponencialni rust CR, Italie, Spanelsko, USA, Cina a Jizni Korea",
  xaxis = list(title = "kumulativni pocet pripadu",
    type = "log"),
  yaxis = list(title = "denni pocet pripadu",
    type = "log"),
  legend = list(x = 0.1, y = 0.9))
fig
```

Změn je relativně málo - zajímají nás jiné státy, mechanismus výběru ale zůstal stejný. Největší změna je v layoutu grafu, kde pro jednotlivé osy kromě popisku (title) je nastavován také typ (type) a to konkrétně logaritmický. Výsledný graf je znázorněn na obr. 7.11.

Jako poslední příklad, který v této části textu použijeme je sloupcový graf. Na našich datech zkusíme vizualizovat vývoj denního počtu nově diagnostikovaných COVID-19 v ČR za poslední 2 týdny. Postup níže by Vám již měl připadat povědomý. Výsledný graf je dostupný na obr. 7.12.

Výpis 7.24: Sloupcový graf - vývoj denního počtu nově diagnostikovaných COVID-19 v ČR za poslední 2 týdny

```
covid_plot <- covid_data %>%
  filter(date > (max(date) - as.difftime(14, unit="days")) & country %in% c("Czechia")) %>%
  group_by(country)
fig <- plot_ly(data = covid_plot,
  x = ~covid_plot$date,
```

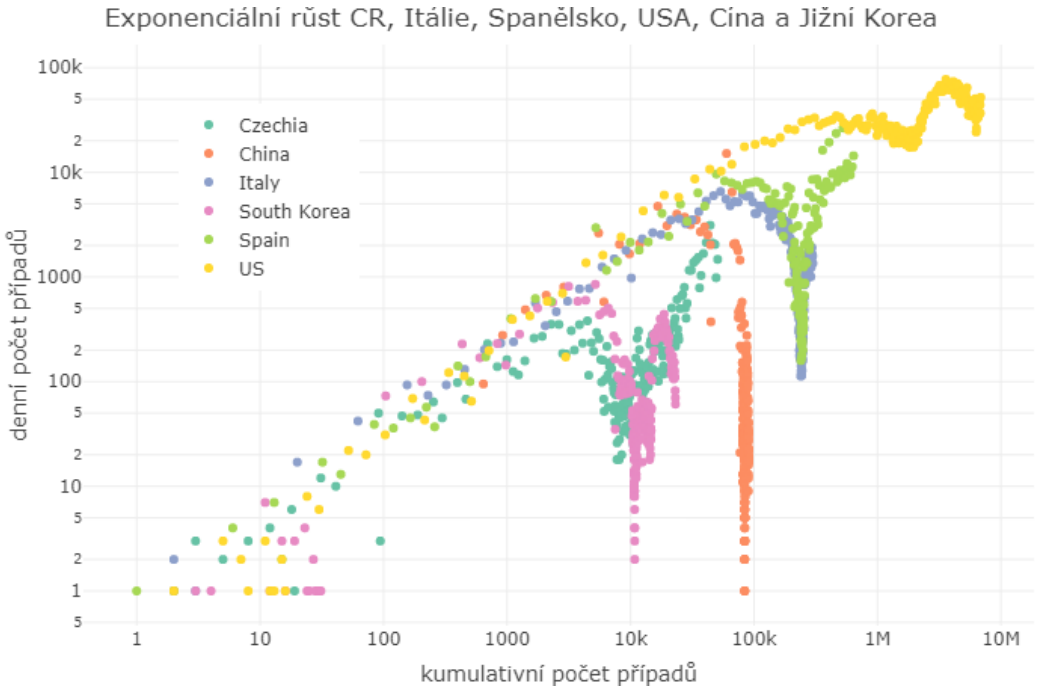

Obrázek 7.11: Exponenciální nárůst nakažených COVID-19 ve vybraných státech - demonstrace logaritmických měřítek os

```
6     y = ~covid_plot$cases_day,
7     type = "bar") %>%
8   layout(
9     title = "Pocet novych pripadu v CR v poslednich 2 tydnech",
10    xaxis = list(title = "datum"),
11    yaxis = list(title = "nove pripady")) %>%
12  add_text(
13    text = ~covid_plot$cases_day,
14    textposition = "top middle",
15    cliponaxis = FALSE)
16  fig
```

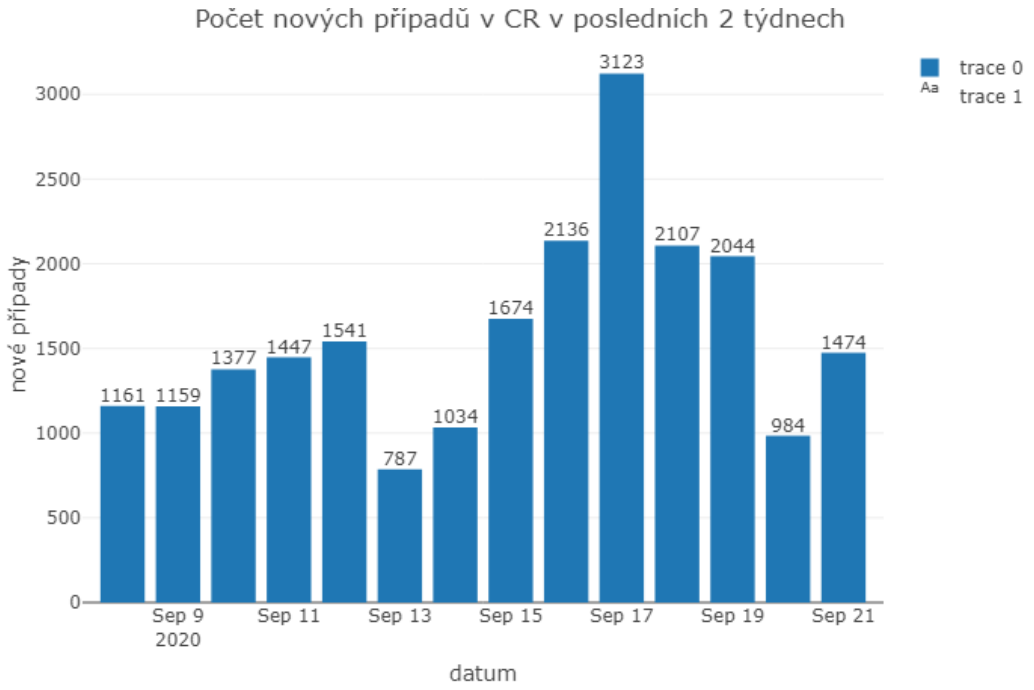

Obrázek 7.12: Vývoj denního počtu nově diagnostikovaných COVID-19 v ČR za poslední 2 týdny

Experimentování s grafy
Jediný způsob, jak výše uvedené informace vstřebat je experimentovat. Revidujte proto předchozí příklady. Pokud např. Vás napadly otázky, jak situace vypadá v jiných státech - nyní máte nástroj a také příležitost jak to zjistit.

Pro inspiraci můžete použít také rozšířený příklad uložený na LMS.

Konzultujte https://plotly.com/r/ - zaujaly Vás nějaké grafy uváděné v tutoriálu. Zkuste je použít na našich datech!

Místo shrnutí
V této kapitole jsme nainstalovali prostředí R a editor RStudio. Následně jsme prošli některé ez nejčastěji používaných postupů a funkcí.
Pokud jste pečlivě zkoušeli příklady uvedené v kapitole a chápete, jak systém funguje, gratuluji - zvládli jste základy R. Samozřejmě pro získáni jistoty v práci je potřeba prakticky realizovat v tomto prostředí nějakou práci.
Pokud jste jednotlivé příklady nerealizovali - teď je na to vhodná doba. Začněte procházet kapitolu, pěkně od začátku a zkuste, jak funguje každá funkce, o které jsme v kapitole psali.

Kapitola 8

Pravidlové metody

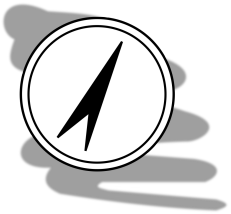

Náhled kapitoly
V této kapitole za zaměříme na pravidlové metody data miningu.

Po prostudování této kapitoly budete
vědět

- jak fungují pravidlové metody data miningu
- jaké jsou jejich výhody ale také omezení

umět

- prakticky použít metody *rozhodovacích stromů* a asociativních pravidel v R
- použít knihovnu carret pro nastavení hyper-parametrů rozhodovacího stromu pro zvýšení kvality odvozených modelů

Čas pro studium
Pro prostudování budete potřebovat 2 - 4 hodiny. V závěru kapitoly je vysvětleno použití knihovny carret. Tato knihovna je určena pro nastavení hyperprostoru parametru statistických metod. Tímto způsobem se můžeme elegantně zbavit závislosti na pokusech s přenastavováním parametrů modelu po jednom.

Model sám se tedy zadaptuje. Tato část kapitoly je náročnější, na druhou stranu má také pro Vás největší přínos, protože stejné principy je možno použít na většinu modelů, se kterými se v tomto předmětu setkáme a řadou dalších, jako jsou třeba regresní modely, se kterými jste se mohli potkat v průběhu studia jiných předmětů.

Pravidlové metody nám umožňují řešit problém generováním pravidel ve formátu IF podmínka THEN závěr. Forma a účel metod se ale liší.

Při výkladu se zaměříme na tři metody:

- rozhodovací pravidla
- rozhodovací stromy
- asociační pravidla

Vzhledem k tomu, že rozhodovací pravidla a stromy řeší klasifikační problémy a sdílejí řadu společných omezení a navíc je možno rozhodovací stromy na pravidla převést, probereme tyto metody společně.

V samostatné podkapitole jsou pak probrána asociační pravidla. Ty jsou určeny pro řešení problému deskripce a dolování nugetů.

8.1 Příprava dat

Všechny výše uvedené metody mají více-méně podobné nároky na vstupní údaje. Rozdíl je pouze v tom, že rozhodovací stromy a pravidla řeší klasifikační problémy. K správnému odvození pravidel je proto nutné, aby připravená data obsahovala již zaklasifikované příklady. Tato data by přitom z pohledu statistiky měla být reprezentativní vzhledem k problému, který má být data miningem řešen.

Připravenou datovou sada by zároveň mělo být možné rozdělit do dvou menších, které můžeme označit jako *trénovací množina* a *validační množina*. Trénovací množina se používá pro „natrénování“ pravidel, pomocí validační množiny se provádí ověření kvality natrénovaného modelu.

V žádném případě není možné kvalitu modelu hodnotit na základě trénovací množiny. Platí totiž, že jelikož byl model na základě trénovací množiny vytvořen, dobře reprezentuje data v ní obsažená. Otázka ale je, zda také dobře reprezentuje problém (resp. jeho řešení).

Trénovací množina je obvykle větší než množina validační. Orientačně lze uvažovat o poměru 2:1 nebo 3:1, přitom by ale mělo platit, že obě množiny jsou vůči problému statisticky reprezentativní. Z tohoto důvodu je stanovení přesného poměru závislé na řešeném problému.

Data jsou do obou množin přidělována náhodně. Náhodný výběr by měl vést k tomu, že také chyba odvozeného modelu bude náhodná. Při nenáhodném výběru riskujeme, že do množiny zaneseme systematickou chybu a množina pak nebude správně reprezentovat problém.

Pokud takový problém vznikne v trénovací množině bude mít výsledný model pro některé oblasti hodnocení větší chybu než očekávanou. V případě, že pak takový problém nastane u validační množiny ztratíme možnost existenci takového problému vůbec odhalit.

Graficky je postup použití množin znázorněn na obr. 8.1.

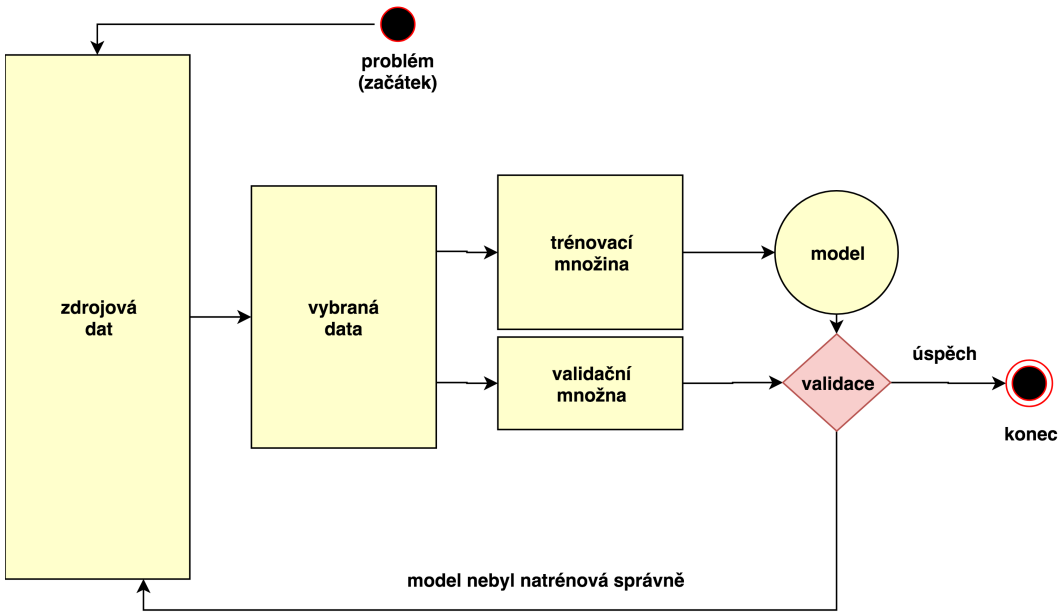

Obrázek 8.1: Filozofie použití trénovací a validační množiny

Proces zobrazený na obr. 8.1 je univerzálně použitelný. Není tedy specifický pro metody rozhodovacích stromů, popř. rozhodovacích pravidel.

Do určité míry alternativním postupem je, že pro odvození modelu použijeme některý z postupů *vzorkování* (samplování). Základem je výběr náhodného vzorku dat z dostupné datové sady. Vzorek musí být dostatečně velký, aby měl potenciál zachytit podstatné vlastnosti, které chceme zachytit modelem. Tento postup je velmi účinný, pro jeho realizaci je ale potřeba velké množství dat.

U jednotlivých sloupců datového sobotu je pak potřeba určit zda se jedná o sloupec vstupní nebo cílový. Cílový sloupec pak obsahuje samotné zaklasifikování.

Z pohledu nároků na data je potřeba provést přípravu tak, aby data neobsahovala:

- chybějící hodnoty
- spojité numerické veličiny
- ... pokud možno chyby

V data miningu existují analytické metody, které jsou schopny se s chybějícími hodnotami vypořádat. Bohužel pravidlové metody nejsou jedny z nich. Z tohoto důvodu je nutno data připravit tak, aby chybějící údaje neobsahovaly. Lze zvolit různé strategie k řešení tohoto problému.

Nejjednodušší řešení může být ve smazání řádků, kde v jakémkoliv sloupci chybí hodnota. Nevýhodou tohoto přístupu je, že se tímto způsobem ztrácí z datového souboru určitá část informací. To také může znamenat, že datový soubor ztratí určitou část své vypovídající schopnosti a to jen z důvodu např. jedné chybějící položky na řádku.

Tento způsob je tak vhodný pouze v případě, kdy poměr řádků s chybějící hodnotou k celkovému počtu řádků datového souboru je zanedbatelný.

Alternativní cestou k řešení problému je chybějící hodnoty doplnit. V některých případech mohou být chybějící hodnoty odvozeny ze zbývajících hodnot - např. s použitím nějakého statistického modelu nebo modelu na bázi neuronových sítí. Ne vždy je ale možno se touto cestou ubírat. V takovém případě je možno doplnit:

- nejčastější hodnotou,
- proporcionálním rozdělením hodnot,
- náhodnou hodnotou.

Doplnění nejčastěji se vyskytující hodnotou (v daném sloupci) je založeno na myšlence, že hodnota, která se nejčastěji objevuje v existujících datech se bude nejčastěji objevovat i v datech, která chybí. Doplněním této hodnoty by tak měla vzniknout minimální chyba.

Aby výše uvedené fungovalo je ale nutné aby v datovém souboru skutečně v daném sloupci existovala ona dominantní hodnota. Zároveň musí být splněn předpoklad, že rozložení chybějících hodnot následuje stejná pravidla jako hodnoty existující. To ale nutně nemusí být splněno. Lze uvažovat o scénáři, kdy absence hodnot souvisí např. s citlivostí přístroje - přístroj hodnotu není schopen naměřit. V takovém případě, ale rozložení chybějících hodnot nenásleduje rozložení hodnot zbývajících - ale měla by být nahrazena hodnotou základní (od které měření neprokázalo odchylku).

Pokud v souboru neexistuje jedna dominantní hodnota, pak lze použít proporcionální rozložení existujících hodno datového souboru. Takže pokud ve sloupci je rozložení hodnot 1 - 50 %, 2 - 30 % a 3 - 20 %. Pak ve stejném poměru je nutné doplňovat hodnoty i do těch chybějících. Opět je zde předpoklad, že chybějící hodnoty ve skutečnosti následují pravidla hodnot přítomných.

Poslední možností je doplnění náhodné hodnoty. V takovém případě akceptujeme obvykle, že nevíme, jaký charakter by mohla mít chybějící data a proto doplňujeme hodnotu náhodnou (v určitém specifikovaném intervalu). S touto strategií můžeme přijmout jisté předpoklady o chybě, kterou doplněním údajů do dat vnášíme - bude náhodná.

Bez ohledu na to jakou strategii přípravy dat zvolíme, vnášíme do dat chybu. Tato chyba může být významná a nebo také zanedbatelná. Předem ale lze jen obtížně odhadnout jaký bude výsledek. Proto je tak důležitá příprava kvalitní validační množiny, která nám umožní vliv těchto chyb na naši schopnost dosáhnout žádoucího výsledku kvantifikovat.

Pokud jsou v datovém souboru spojité numerické veličiny je potřeba provést jejich rozdělení na intervaly. Jedná se o jednu z prvních úloh statistiky a tak způsob realizace najdete prakticky v každé učebnici statistiky, viz např. [44] (kapitola 2.2).

Adekvátnost modelu
Omezení na ordinální hodnoty se v případě rozhodovacích stromů týká primárně metod, které se dělají ručně, tak jak je demonstrováno v těchto skriptech. Poslední podkapitole, ale demonstrujeme použití rozhodovacího stromu pro odvození sofistikovanějšího modelu a využíváme k tomu mnohem pokročilejší nástroje dostupné jako knihovna v R. Tento nástroj, ale výše uvedené omezení nemá!

Vždy jsme tedy omezeni postupy a nástroji, které jsme zvolili pro řešení problému. **Omezení se tak liší případ od případu**. Úspěch modelování je vždy determinován naší schopností porozumět zpracovávaným datům a také nástrojům, které využíváme.

Vybaveni základními znalostmi, můžeme se pustit do metod samotných.

8.2 Rozhodovací stromy

Segmentují znalosti do podoby stromu. Pravidla pak popisují průchod tímto stromem od kořene stromu směrem k listu. List pak představuje samotné zatřídění případu.

Z požadavků na data (viz výše) už víme, že každý sloupec dat obsahuje konečný počet hodnot. Různé hodnoty nám pak představují větvení. Vhodné sestavení stromu je pak z velké části o identifikaci těch sloupců v datech, které mají největší potenciál vysvětlit zatřídění.

Existuje řada algoritmů, které pro segmentaci lze použít. jedním z nejjednodušších je algoritmus Top Down Induction of Decision Trees (TDIDT) známý pod řadou názvů - rozděl a panuj (odděl a panuj), AQ algoritmus a další.

Princip je jednoduchý:

1. jeden sloupec se zvolí jako kořen stromu
2. data se rozdělí podle hodnot zvoleného sloupce - uzel se rozvětví
3. pokud v takto vzniklých uzlech nepatří všechny data do stejné cílové třídy opakuj od bodu 1.

Prakticky to znamená, že sloupec se objeví ve stromu pouze jednou (pokud je použit tento algoritmus) a některé sloupce se nemusí objevit ve stromu vůbec.

Při volbě vhodného datového sloupce pro větvení stromu je možné se opřít např. o *informační entropii*. Tento pojem by Vám neměl být zcela neznámý - konečně v *Bezpečnostní informatice* [84] v druhém ročníku bakalářského studia.

Připomeňme si vzorec pro výpočet entropie (8.1):

$$H = -\sum_{t=1}^{T}(p_t \log_2 p_t) \tag{8.1}$$

Kde H je informační entropie, p_t je pravděpodobnost výskytu třídy t. Z praktického pohledu pro výpočet entropie hodnota pravděpodobnosti není známá, ale můžeme ji aproximovat pomocí relativní četnosti n_t, spočítané z předpřipravených dat v datasetu.

Dosazením do vzorce (8.1) získáme vzorec (8.2).

$$H(A_v) = -\sum_{t=1}^{T}\frac{n_t(A_v)}{n(A_v)}\log_2\frac{n_t(A_v)}{n(A_v)} \tag{8.2}$$

Pravděpodobnost p_t jsme nahradili poměrem počtu případů nabývající určité třídy $n_t(A_v)$ k celkovému počtu případ $n(A_v)$.

Entropii atributu (sloupce) pak spočteme podle vzorce (8.3):

$$H(A) = -\sum_{v\in hodnoty(A)}\frac{n(A_v)}{n}H(A_v) \tag{8.3}$$

Jelikož entropie popisuje neurčitost - hledáme takové sloupce v datech, jejichž hodnota entropie $H(A)$ je malá. Pro větvení tak vybíráme sloupec s nejnižší vypočtenou hodnotou entropie.

Zkusme provést orientační výpočet jednoduchého příkladu: *Naším úkolem bude vytvořit sadu pravidel pro klasifikaci klientů banky z pohledu bonity vzhledem k případnému schválení úvěru. Pro navržení sady pravidel máme k dispozici údaje o klientech a rozhodnutí o úvěru, která byla provedena v minulosti. Tyto údaje jsou zobrazeny v tabulce 8.1.*

V datech je cílový sloupec *úvěr* oddělen o zbytku souboru. Sloupec klient tvoří identifikátor každého řádku datového souboru a proto nám nebude tento sloupec vstupovat do výpočtu.

Pro spočtení entropie budeme muset nejprve spočítat, jak jednotlivé hodnoty sloupců vedou na hodnotu cílového sloupce. Pro příjem nám tak vznikne čtyřpolní tabulka (viz tabulka 8.2), jelikož příjem nabývá pouze dvou hodnot (vysoký/nízký) a úvěr nabývá také pouze dvou hodnot (ano/ne).

Výpočet entropie sloupce *příjem* pak proběhne následovně podle vzorců 8.2 a (8.3):

Tabulka 8.1: Přidělování úvěrů banky (převzato z [23])

klient	**příjem**	**konto**	**pohlaví**	**nezam.**	**úvěr**
k1	vysoký	vysoké	žena	ne	ano
k2	vysoký	vysoké	muž	ne	ano
k3	nízký	nízké	muž	ne	ne
k4	nízký	vysoké	žena	ano	ano
k5	nízký	vysoké	muž	ano	ano
k6	nízký	nízké	žena	ano	ne
k7	vysoký	nízké	muž	ne	ano
k8	vysoký	nízké	žena	ano	ano
k9	nízký	střední	muž	ano	ne
k10	vysoký	střední	žena	ne	ano
k11	nízký	střední	žena	ano	ne
k12	nízký	střední	muž	ne	ano

Tabulka 8.2: Příjem vs úvěr

	úvěr ano	**úvěr ne**
příjem vysoký	5	0
příjem nízký	3	4

$$H(prijem) = \frac{5}{12}H(prijem(vysoky)) + \frac{7}{12}H(prijem(nizky))$$

$$H(prijem(vysoky)) = -\frac{5}{5}\log_2\frac{5}{5} - \frac{0}{5}\log_2\frac{0}{5} = 0 + 0 = 0$$

$$H(prijem(nizky)) = -\frac{3}{7}\log_2\frac{3}{7} - \frac{4}{7}\log_2\frac{4}{7} = 0,9852$$

$$H(prijem) = \frac{5}{12}0 + \frac{7}{12}0,985 = 0,5747$$

Pro ostatní sloupce zápis omezím už pouze na výpočet jeho entropie. (Pokud Vám ale zcela není jasný mechanismus výpočtu - rozepište jej na kus papíru. Rovnice níže Vám pak mohou posloužit jako zpětná kontrola.)

$$H(konto) = \frac{4}{12}0 + \frac{4}{12}1 + \frac{4}{12}1 = 0,6667$$

$$H(pohlavi) = \frac{6}{12}0,9183 + \frac{6}{12}0,9183 = 0,9183$$

$$H(neram) = \frac{6}{12}0,65 + \frac{6}{12}1 = 0,825$$

Pokud porovnáme hodnotu entropie všech vstupních sloupců, vyplyne z toho jasně sloupec *příjem* jako nejvhodnější k větvení. Toto větvení nám datový soubor rozdělí na dvě části. Pět řádků, kde je příjem vysoký konzistentně vede na přidělení úvěru. Na konci této větve tak již bude koncový uzel. Zbývajících sedm případů je ale nutno ještě zkoumat.

Pro další krok proto z datového souboru vyřadíme již konzistentně zatřízené řádky (k1, k2, k7, k8, k10) - upravenou tabulku 8.3 použijeme pro další analýzu. Sloupec příjem již také nevstoupí do výpočtu.

Vypočteme entropie:

$$H(konto) = \frac{2}{7}0 + \frac{3}{7}0,9183 + \frac{2}{7}0 = 0,3936$$

$$H(pohlavi) = \frac{4}{7}1 + \frac{3}{7}0,9183 = 0,965$$

Tabulka 8.3: Přidělování úvěrů - 2. větvení

klient	příjem	konto	pohlaví	nezam.	úvěr
k3	nízký	nízké	muž	ne	ne
k4	nízký	vysoké	žena	ano	ano
k5	nízký	vysoké	muž	ano	ano
k6	nízký	nízké	žena	ano	ne
k9	nízký	střední	muž	ano	ne
k11	nízký	střední	žena	ano	ne
k12	nízký	střední	muž	ne	ano

$$H(nezam) = \frac{2}{7}0 + \frac{5}{7}0,971 = 0,9793$$

Z výpočtu je patrné, že sloupec *konto* je nejvhodnější pro další větvení. V tomto případě konto vysoké vede konzistentně na přidělení úvěru, zatímco konto nízké vede konzistentně na jeho zamítnutí. V těchto případech se tedy bude jednat o listové uzly. Konto střední ve dvou případech vede na přidělení a v jednom případě na zamítnutí úvěru.

Proto opět vyřadíme už zatříděné řádky (viz tabulka 8.4) a pokračujeme dále ve výpočtu.

Tabulka 8.4: Přidělování úvěrů - 3. větvení

klient	příjem	konto	pohlaví	nezam.	úvěr
k9	nízký	střední	muž	ano	ne
k11	nízký	střední	žena	ano	ne
k12	nízký	střední	muž	ne	ano

$$H(pohlavi) = \frac{2}{3}1 + \frac{1}{3}0 = 0,6667$$

$$H(nezamestnany) = \frac{2}{3}0 + \frac{1}{3}0 = 0$$

Výsledek je zcela jasný - pro větvení použijeme sloupec nezaměstnaný a větvení nám umožňuje konzistentně zaklasifikovat všechny zbývající případy. Výsledný strom by mohl vypadat jako na obr. 8.2.

Do podoby pravidel bychom mohli převést následovně:

Výpis 8.1: Metoda rozděl a panuj - strom klientů banky

```
1 IF prijem(vysoky) THEN uver(ano)
2 IF prijem(nizky) && konto(vysoke) THEN uver(ano)
3 IF prijem(nizky) && konto(nizke) THEN uver(ne)
4 IF prijem(nizky) && konto(sterdni) && nezam(ne) THEN uver(ano)
5 IF prijem(nizky) && konto(stredni) && nezam(ano) THEN uver(ne)
```

Každé pravidlo je samostatně funkční. Vyhodnocování probíhá postupně od prvního pravidla k poslednímu. Mělo by platit, že se kladně vyhodnotí pouze jedna podmínka (závěr pravidla se vykoná pouze jednou). Vyhodnocena však budou všechna pravidla, což z pohledu požadovaného výpočetního výkonu není efektivní.

Alternativně by bylo možné zorganizovat do podoby *rozhodovacího seznamu*. V takovém případě se dají podmínky výše přepsat do následující podoby:

Výpis 8.2: Metoda rozděl a panuj - strom klientů banky; převod do podoby rozhodovacího seznamu

```
1 IF prijem(vysoky) THEN
2    uver(ano)
3 ELSE IF konto(vysoke) THEN
4    uver(ano)
```

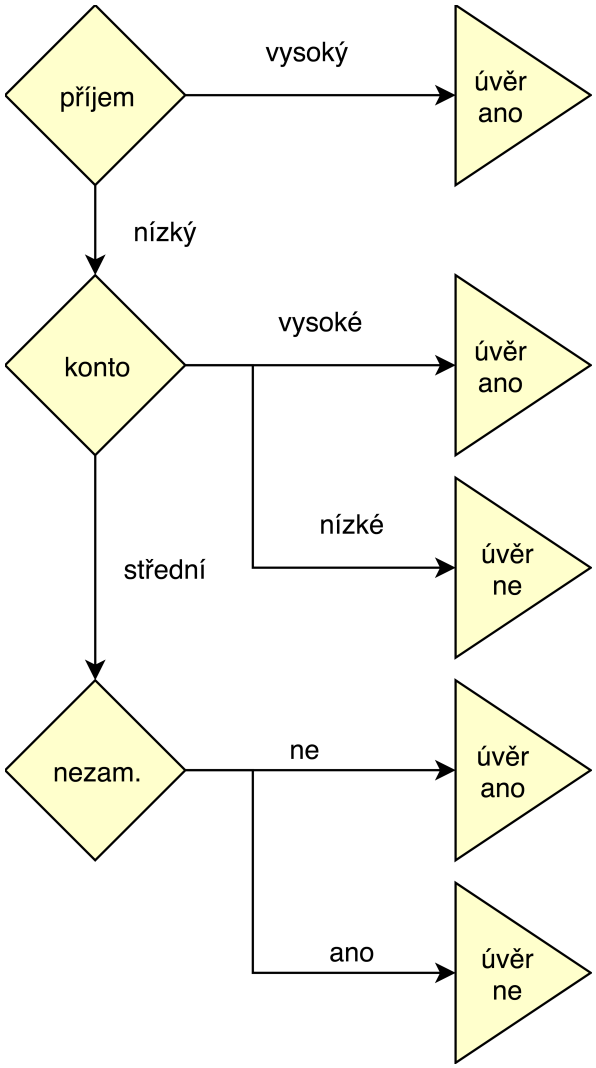

Obrázek 8.2: Klienti banky - ručně vytvořený rozhodovací strom

```
ELSE IF konto(nizke) THEN
   uver(ne)
ELSE IF nezam(ne) THEN
   uver(ano)
ELSE uver(ne)
```

Z pohledu vyhodnocování je rozhodovací seznam jednodušší, protože jednotlivé části podmínky se vzájemně vylučují. To výrazně omezuje počet vyhodnocení, které je potřeba provést ke správnému zaklasifikování hodnoceného příkladu. Všimněte si také, že maximální počet vyhodnocení, které je nutno provést je 4. Pokud to srovnáme se sadou pravidel - je nutno provést 12 vyhodnocení vždy.

Při vyhodnocování velkého množství případů tak může být dosaženo poměrně značné časové úspory.

Čas lze spořit také na straně odvození stromu. Pro nalezení nejvhodnějšího sloupce pro větvení stromu je možno použít místo informační entropie třeba *ginni index*. Tento index lze chápat jako zjednodušení informační entropie viz vzorec 8.4). Index nám umožňuje rozlišit mezi sloupci z pohledu jejich příspěvku k „řešení entropie“ - umožní seřadit sloupce z pohledu vhodnosti k větvení stromu, ale zároveň nám neumožňuje kvantifikovat rozdíly mezi nimi.

$$Ginni = 1 - \sum_{t=1}^{T} p_t^2 \tag{8.4}$$

Pravděpodobnosti opět převedeme do podoby relativních četnosti (8.5) a ginni index celého sloupce spočteme dle vzorce (8.6).

$$Ginni(A_v) = 1 - \sum_{t=1}^{T} \left(\frac{n_t(A_v)}{n(A_v)} \right)^2 \tag{8.5}$$

$$Ginni(A) = \sum_{v \in hodnota(A)} \frac{n(A_v)}{n} Ginni(A_v) \tag{8.6}$$

I pokud vše maximálně zjednodušíme je jasné, že ruční výpočet není nikterak příjemný a jeho složitost výrazně roste s počtem vyhodnocovaných záznamů. Naší snaho by proto mělo být v maximální možné míře využít analytické nástroje, které výpočet udělají za nás.

Pro následující realizaci příkladu v R budeme potřebovat vstupní soubor CSV obsahující tabulku 8.1. Tabulku můžete připravit např. v tabulkovém procesoru MS Excel a vyexportujte jej do formátu CSV.

K odvození stromu použijeme toolkit „Tree“ [65]. Před prvním použitím je tento toolkit potřeba instalovat z CRAN. To provedeme zadáním příkazu:

Výpis 8.3: Instalace knihovny tree

```
1 > install.packages("tree")
```

do konzole R. R by se samo mělo připojit k vybranému repozitáři CRAN, stáhnout z něj toolkit a doinstalovat jej do prostředí R.

Instalovaných rozšíření pro R je obvykle větší množství (podle toho, co od R očekáváme). Z tohoto důvodu neškodí jednou za čas instalovaná rozšíření aktualizovat. Pokud používáte RStudio je aktualizace jednoduchá - kliknete na menu *Tools* → *Check for package updates*.

RStudio pak instalované balíky ukáže v tabulce a umožní je aktualizovat po jednom nebo hromadně.

Výpis 8.4: Binární strom přidělování úvěrů klientům banky

```
1  library("tree")
2  klienti = read.csv("klienti_banky.csv", sep = ";", header=TRUE)
3  #následující nastavení je nutné pouze z důvodu velmi malého počtu měření
4  #v trénovací množině
5  tree_nastaveni = tree.control(12, mincut = 1, minsize = 2, mindev = 0.00000001)
6  model_tree = tree(
7     klienti$uver ~ klienti$prijem + klienti$konto + klienti$pohlavi + klienti$nezam,
8     data = klienti, control = tree_nastaveni)
9  summary(model_tree)
10 plot(model_tree) #vykreslí strom pomocí grafu
11 text(model_tree, pretty=0, cex=0.6) #textové popisky ke grafu
```

Poměrně velká část kódu by pro Vás již měla být srozumitelná, zbytek probereme. Pro použití toolkitu je potřeba naistalovaný balík připojit pomocí funkce *library* s názvem toolkitu jako parametrem. Funkcí *read.csv* si budete muset přizpůsobit podle toho, kde přesně se CSV soubor nachází a jaké jsou jeho parametry. Můj CSV soubor používá např. jako oddělovač sloupců znak středníku.

Funkci *tree.control* je nutné použít pouze proto, že náš příklad je ... školní. U reálných příkladů je obvykle možné tato nastavení vynechat. jde o tom, že reálný strom obvykle pro svou konstrukci vyžaduje aby každý listový uzel byl pokryt určitým minimálním počtem řádků v trénovací množině. V našem příkladu však tato minimální hodnota není splněna a tak bez přenastavení by se nám neodvodil strom správně.

Proto tento řádek prostě přepište a příliš se jím netrapte :-).

Samotný strom je odvozen pomocí funkce *tree*. V našem případě má funkce tři parametry:

1. model

2. data, ze kterých bude model sestaven
3. control - nastavení stromu (u praktických příkladů obvykle není potřeba uvádět)

V modelu máme odděleny jednotlivé role pomocí znaku ~. Začínáme specifikací proměnné obsahující cílovou proměnnou. Za ~pak následují vstupní sloupce analýzy oddělené znakem +. Plus v tomto případě není označením sčítání, ale přiřazením do určité části modelu.

Logicky další parametry odkazují v případě *data* na tabulku s daty a control na proměnnou s výsledkem funkce tree.control - pokud je strom přenastaven.

Funkce *summary* je jednou z nejzajímavějších funkcí, kterou nám dává R k dispozici. Tato funkce poskytuje shrnutí k tomu, co jí předáme jako parametr. V úvodu do R jsme ji použili pro rychlý popis vlastností datového souboru. Pokud ale této funkci předáme natrénovaný model zobrazí jeho vlastnosti - v našem případě:

Výpis 8.5: Binární strom přidělování úvěrů klientům banky - metriky a výsledky

```
Classification tree:
tree(formula = klienti$uver ~ klienti$prijem + klienti$konto +
     klienti$pohlavi + klienti$nezam, data = klienti, control = tree_nastaveni)
Variables actually used in tree construction:
[1] "klienti$prijem" "klienti$konto" "klienti$nezam"
Number of terminal nodes: 5
Residual mean deviance: 0 = 0 / 7
Misclassification error rate: 0 = 0 / 12
```

V našem případě bylo odvozeno pět listových uzlů a model dokonale pokryl všechny trénované příklady (residual mean variance = 0 a misclassification error rate = 2). Ze čtyř vstupních proměnných se pro vytvoření stromu použily jenom tři - stejně, jako když jsme strom tvořili ručně.

Samotnou strukturu stromu vykreslíme příkazem *plot* a funkce *text* pak do grafu přidá textové popisky grafu. Samotný graf je přiložen na obr. 8.3.

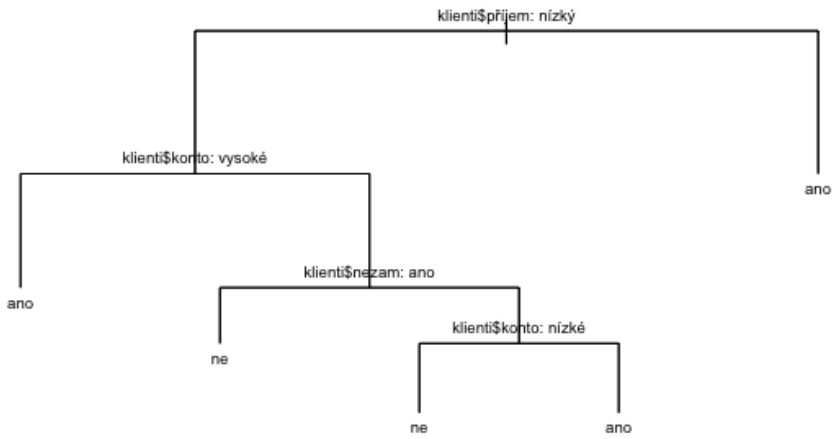

Obrázek 8.3: Klienti banky - strom vygenerovaný toolkitem *Tree*

Všimněte si, že ve srovnání s obr. 8.2 je způsob zobrazení poněkud jiný. To je dáno tím, že toolkit Tree používá tzv. binární stromy - tedy jiný algoritmus výpočtu než jsme použili k výpočtu ručnímu.

Jak realizovat případ, kdy naopak chceme konzultovat strom? Tedy na základě trénovací množiny jsme odvodili strom a nyní máme už data bez přiřazených tříd - resp. přiřazení potřebujeme realizovat na základě průchodu stromem.

Já jsem situaci zjednodušil tím, že pro klasifikaci jsem použil náhodně vybraný řádek trénovací množiny, ale bez sloupce *úvěr*. To není korektní postup jak jsme si řekli v kapitole *Příprava dat*, pro demonstraci postupu nám to ale bude stačit.

Výpis 8.6: Binární strom přidělování úvěrů klientům banky - hodnocení kvality modelu

```
1 scoreMnozina = klienti
2 predpoved = predict(model_tree, scoreMnozina, type="class")
3 predpoved #zobrazí, jak byly jednotlivé případy zaklasifikovány
4 table(pred=predpoved, true=scoreMnozina$uver) #konstrukce confusion matrix
5 mean(predpoved != scoreMnozina$uver) #výpočet průměrné chyby v klasifikaci
```

Předpověď výsledku e realizována funkcí *predict*. Všimněte si tzv. *confusion matice* (viz tab. 8.5). Ta umožňuje porovnat jak byly klasifikovány případy a jak měly být klasifikovány případy.

Tabulka 8.5: Binární strom přidělování úvěrů klientům banky - confussion matice

	true	
pred	ano	ne
ano	8	0
ne	0	4

Podle tabulky výše jsou předpovědi v řádcích (pred) a skutečné hodnoty pak ve sloupcích (true).

8.3 Případová studie rozhodovacího stromu - AMES dataset

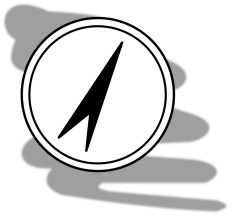

Případová studie
V předchozí podkapitole jsme si ukázali, jak rozhodovací stromy vlastně fungují. S trochou štěstí by jste měli být schopni případně nějaký jednoduchý strom spočítat ať už ručně nebo s použitím výpočetní techniky a knihovny *tree* R.

Co se podívat na nějaký rozsáhlejší dataset a vyzkoušet si možnosti rozhodovacích stromů „v plné palbě“ se vším, co nám nabízejí? ... máme před sebou spousty práce, ale s potenciálně velkým přínosem.

Pro případovou studii použijeme dataset AMES, který byl zveřejněn v roce 2011 [30]. Dataset obsahuje data z prodeje 2903 domů ve městě Ames (Iowa, USA) v letech 2006 - 2010. Pro R jsou data dostupná v knihovně AmesHousing [47].

Pro jednotlivé prodeje bylo sledováno celkem 82 proměnných, které daný prodej charakterizovaly. Jelikož v této případové studii se setkáváme s datasetem poprvé, podíváme se na strukturu proměnných:

- *Order* - číslo pozorování (z hlediska modelování irelevantní)
- *PID*(Parcel identification number) - identifikační číslo parcely. Údaj je případně možno využít pro připojení dalších informací o pozemku, v této případové studii tento údaj ale také nevyužijeme
- *MS SubClass* - popisuje obydlí, které bylo prodáváno
- *MS Zoning* - identifikátor klasifikace zóny, ve které se budova nachází
- *Lot Frontage* - Linear feet of street connected to property
- *Lot Area* - plocha pozemku $[in^2]$
- *Street* - typ přístupu k pozemku/domu
- *Alley* - typ uličky/cesty vedoucí k pozemku/domu
- *Lot Shape* - becný tvar domu
- *Land Contour* - „plochost“ budovy (nakolik budova narušuje celkové kontury/panorama krajiny)
- *Utilities* - typ připojených infrastruktur (např. plyn, voda, elektřina, apod.)
- *Lot Config* - konfigurace pozemku
- *Land Slope* - sklon pozemku
- *Neighborhood* - sousedství - fyzické umístění na území města Ames
- *Condition 1* - blízkost k různým službám

- *Condition 2* - blízkost k různým službám, pokud je dostupných více než jedna
- *Bldg Type* - typ obydlí
- *House Style* - styl obydlí
- *Overall Qual* - hodnotí celkový použitý materiál a povrchovou úpravu domu
- *Overall Cond* - hosnotí celkové podmínky domu
- *Year Built* - rok dokončení stavby
- *Year Remod/Add* - rok, kdy došlo k poslední remodelaci domu (pro domy, které neprošly remodelací je rok stejný jako rok dokončení stavby)
- *Roof Style* - typ střechy
- *Roof Matl* - materiál použitý pro stavbu střechy
- *Exterior 1* - externí povrch domu
- *Exterior 2* - externí povrch domu (pokud byl použit více než jeden materiál)
- *Mas Vnr Type* - : typ zdiva
- *Mas Vnr Area* - zastavěná plocha $[in^2]$
- *Exter Qual* - hodnocení kvality materiálů použitých na exteriér domu
- *Exter Cond* - hodnocení současného stavu materiálu na exteriéru domu
- *Foundation* - typ základů
- *Bsmt Qual* - hodnocení výšky sklepa
- *Bsmt Cond* - hodnocení obecného stavu sklepa
- *Bsmt Exposure* - přístupnost sklepa, týká se vchodu nebo stěn na úrovni povrchu
- *BsmtFin Type 1* - rating „dokončené“[1] plochy sklepa
- *BsmtFin SF 1* - Typ 1 $[in^2]$
- *BsmtFinType 2* - rating plochy sklepa, pokud je tvořen více typy
- *BsmtFin SF 2* - Typ 2 $[in^2]$
- *Bsmt Unf SF* - „nedokončená“ plocha sklepa $[in^2]$
- *Total Bsmt SF* - celková plocha sklepa $[in^2]$
- *Heating* - typ vytápění
- *HeatingQC* - kvalita a celkový stav vytápění
- *Central Air* - centrální klimatizace
- *Electrical* - elektrické systémy
- *1st Flr SF* - plocha prvního podlaží $[in^2]$
- *2nd Flr SF* - plocha druhého podlaží $[in^2]$
- *Low Qual Fin SF* - nízko kvalitní „dokončení“, všechna podlaží
- *Gr Liv Area* - nadzemní obytná plocha $[in^2]$
- *Bsmt Full Bath* - sklep, úplná[2] koupelna
- *Bsmt Half Bath* - sklep, poloviční koupelna
- *Full Bath* - plná koupelna v nadzemín části domu
- *Half Bath* - poloviční koupelna v nadzemní části domu
- *Bedroom* - ložnice v nadzemní části (neobsahuje ložnice ve sklepě)
- *Kitchen* - Kuchyně v nadzemní části
- *KitchenQual* - kvalita kuchyně
- *TotRmsAbvGrd* - celkový počet místností v nadzemní části (neobsahuje koupelny)
- *Functional* - funkcionalita domu (předpokládá se typická pokud sleva není zdůvodněná
- *Fireplaces* - počet krbů
- *FireplaceQu* - kvalita krbu
- *Garage Type* - umístění garáže
- *Garage Yr Blt* - rok, ve kterém byla garáž dokončena
- *Garage Finish* - vnitřní úprava garáže
- *Garage Cars* - velikost garáže specifikovaná počtem aut, které je možno do ní zaparkovat
- *Garage Area* -velikost garáže $[in^2]$
- *Garage Qual* - kvalita garáže
- *Garage Cond* - stav garáže
- *Paved Drive* - : zpevněná příjezdová cesta

[1] jako dokončené plocha je vnímán takový sklep, který je dokončen podobně jako běžné součásti domu, tedy včetně zavedené elektřiny, vytápění, dodělané podlahy, vyrovnané stropy a omítnuté stěny.

[2] umyvadlo, sprcha, vana a záchod (za každou chybějící část 1/4 hodnocení dolů - např. bez vany a záchodu se jedná o poloviční koupelnu)

- *Wood Deck SF* - plocha dřevěné terasy [in^2]
- *Open Porch SF* - plocha otevřené verandy [in^2]
- *Enclosed Porch* - plocha uzavřené verandy [in^2]
- *3-Ssn Porch* - plocha verandy pro tři roční období [in^2]
- *Screen Porch* - čelní plocha verandy [in^2]
- *Pool Area* - velikost bazénu [in^2]
- *Pool QC* - kvalita bazénu
- *Fence* - kvalita plotu
- *Misc Feature* - různé vlastnosti, které nejsou pokryty jinými kategoriemi
- *Misc Val*: hodnota různých vlastností [USD]
- *Mo Sold* - měsíc, ve kterém byl realizován prodej
- *Yr Sold* - rok prodeje
- *Sale Type* - typ prodeje
- *Sale Condition* - podmínky prodeje

82 sloupců a tisíce řádků představují určitou výzvu. V takovém počtu proměnných nemůžeme postupovat naivně ve snaze po jednom zkoušet, jaká kombinace sloupců povede k nejlepšímu výsledku. Potřebujeme tedy mít k dispozici sofistikovaný nástroj, který nás odstíní do značné míry od komplexity celkového výpočtu.

Proměnné jsou různého typu, některé jsou kategoriální, jiné obsahují numerické hodnoty. Řada proměnných také obsahuje chybějící hodnoty. Jinými slovy dataset je zatížen problémy, které bychom při ručním výpočtu podle předchozí kapitoly nebyli schopni vypočítat. Se správnými knihovnami pro R, ale výpočet není problém, viz výpis kódu níže.

Příklad níže je inspirován příkladem publikovaným v Boehmke a Greenwel [25]. Oproti v knize zveřejněné verzi se zaměřuje pouze na jeden model zpracování datasetu (model přístupný v proměnné *ames_ dt3*), na který aplikuje všechny potřebné postupy. Oproti verzi příkladu v knize jsou doplněny některé dodatečné postupy pro prezentaci výsledků.

Příkladem doplněného postupu je funkce *split.fun* sloužící k úpravě vzhledu výsledného stromu.

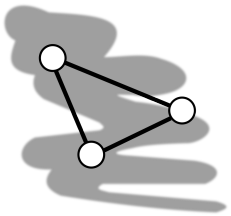

Hands-On Machine Learning with R
Z hlediska dalšího zkoumání parametrů může být výhodné konzultovat příklady přímo z knihy. Výhodou je, že kniha je ve fultextové podobě,, včetně příkladů dostupná bezplatně on-line na adrese https://bradleyboehmke.github.io/HOML/

Výpis 8.7: Regresní strom pro AMES dataset

```
library("AmesHousing") #obsahuje dataset AMES
library("rpart") #knihovna pro práci s rozhodovacími stromy
library("rpart.plot") #knihovna pro vykreslování stromů
library("caret")
library("vip")
library("dplyr")
library("plotly")

ames_train = make_ames()
ames_dt3 <- train(
  Sale_Price ~ .,
  data = ames_train,
  method = "rpart",
  trControl = trainControl(method = "cv", number = 10),
  tuneLength = 20
)
rpart.plot(ames_dt3$finalModel, split.fun=split.fun)
#výpočet CP
x = ames_dt3$finalModel$cp[,1]
y = ames_dt3$finalModel$cp[,3]
fig <- plot_ly(
  x = x,
  y = y,
  mode = 'lines+markers',
```

```
25    type = "scatter") %>%
26  layout(
27    title = "Velikost stromu vs presnost vypoctu",
28    xaxis = list(title = "parametr kompexity (cp)",
29    autorange="reversed"),
30    yaxis = list(title = "relativni chyba")
31  )
32  fig
33  fig <- plot_ly(
34    x = ames_dt3$results$cp,
35    y = ames_dt3$results$RMSE,
36    mode = 'lines+markers',
37    type = "scatter") %>%
38  layout(
39    title = "Stredni kvadraticka chyba stromu",
40    xaxis = list(title = "parametr kompexity (cp)"),
41    yaxis = list(title = "RMSE (stredni kvadraticka chyba - krizova validace)")
42  )
43  fig
44  uzly = length(ames_dt3$results$RMSE):1
45  fig <- plot_ly(
46    x = uzly,
47    y = ames_dt3$results$RMSE,
48    mode = 'lines+markers',
49    type = "scatter") %>%
50  layout(
51    title = "Zavislost stredni kvadraticke chyby stromu na poctu listovych uzlu",
52    xaxis = list(title = "velikost stromu"),
53    yaxis = list(title = "RMSE (stredni kvadraticka chyba - krizova validace)")
54  )
55  fig
56  vip(ames_dt3, num_features = 26, bar = FALSE)
```

Výpočet stromu a jeho vizualizaci provedeme pomocí knihoven *rpart* [78] a *rpart.plot* [56].

Data bereme z knihovny AmesHousing. Použijeme data ve zpracované podobě přístupná pomocí funkce *make_ ames()*. Strom samotný odvozujeme funkcí *rpart* ze stejnojmenné knihovny. Parametry jsou poměrně intuitivní. Syntaxe parametru formula může na první pohled vypadat divně, ale není. Sale_price je cílový atribut, odděluje cílový atribut od zbytku modelu (ze kterého má být odvozen) a „.“ je zástupný symbol pro všechny sloupce.

Parametr *data* obsahuje odkaz na proměnnou obsahující data ke zpracování. Výsledný strom je možno vypsat v textové podobě vypsáním obsahu proměnné *ames_ dt1*, my ale místo toho použijeme funkci *rpart.plot*, ze stejnojmenné knihovny, pro vykreslení stromu, viz obr. 8.4.

Pro regresní stromy je typické, že mohou být takřka libovolně košaté. Uvědomme si, že pro větvení může být použit kterýkoliv sloupec a jeho kterákoliv hodnota. Jak je ale vidno na obr. 8.4, je strom ve skutečnosti jednodušší. Funkce rpart totiž má implementovaný také mechanismus prořezávání stromu.

Tento mechanismus spočívá v automatickém porovnávání chyb stromu generovaných stromy různě nastavenými parametry, především pak různě nastaveným počtem listových uzlů. K tomuto účelu se používá 10-ti násobná křížová validace (10-fold Cross Validation (CV)). Princip křížové validace je poměrně jednoduchý. Z datasetu se náhodně vyberou data do trénovací a validační množinu, pro kterou se odvodí model a spočte chyba. Desetinásobná znamená, že získáme 10 takových výběrů, každý jiný.

Nastavení CV se provádí pomocí *trainControl* funkce. To je poměrně zásadní výhoda, pro kterou používáme knihovnu caret. Tato knihovna nám slouží jako abstrakční vrstva nad různými modely. Nyní pracujeme s rozhodovacím stromem, pokud bychom ale pracovali s lineární regresí, pouze bychom změnili metodu na lm a změnili. hyperparametry.

Tímto postupem se snažíme vyhnout zkreslením v odvozeném modelu způsobené náhodným výběrem trénovací množiny.

Tento optimalizační princip je dobře viditelný na obr. 8.5, který vizualizuje vztah velikosti modelu/stromu měřeného počtem uzlů a jeho přesnosti. S přibývajícím počtem uzlů se sice přesnost modelu zvyšuje, ale přínos je s každým dalším uzlem menší a menší. Z hlediska optimalizace tak můžeme zvolit minimální zpřesnění výpočtu, které považujeme za přínosné a pokud přesáhneme tuto hranici bude přinášet každé další zvýšení komplexity stromu pouze zanedbatelné zvýšení bezpečnosti.

Při použití caret knihovny, ale obvykle preferujeme spíše použití metriky Root-mean-square error (RMSE), tedy střední kvadratické chyby, viz obr. 8.6. Tento pohled je ve skutečnosti velmi podobný

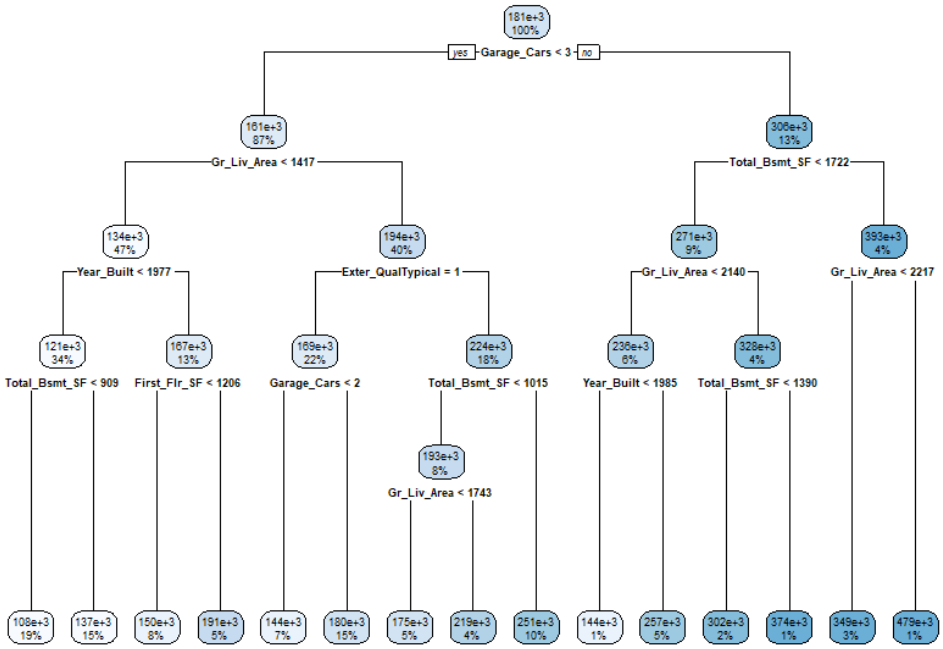

Obrázek 8.4: Regresní strom pro AMES dataset

jako je obr. 8.5, rozdíl je v orientaci osy x. Každý bod na obou křivkách představuje listový uzel stromu. S přibývajícím počtem uzlů se zlepšuje kvalita predikce a klesá hodnota chyb.

Ještě lépe viditelný přínos většího počtu listový uzlů je viditelný pokud pokud parametr kompelxity *cp* nahradíme počtem uzlů, viz obr. 8.7. V tomto případě je vzdálenost mezi jednotlivými uzly grafu konstantní, což nám umožňuje vidět postupné zlepšování RMSE až do úrovně okolo 40 000 pro 15 listových uzlů. Následně ale RMSE znovu roste!

Pokud zkonzultujeme obr. 8.4 zjistíme, že pro konstrukci stromu byla zvolena právě optimální hodnota 15-ti listových uzlů. Celkový počet listových uzlů jsme v rámci funkce *train* nastavili na 20 pomocí parametru *tuneLength*. Počet listových uzlů je právě hyperparametrem, který ovlivňujeme v případě rozhodovacího stromu nejčastěji.

Hodnotu 20 je možno určit odhadem tak, že pokusně spočteme strom přímo pomocí funkce rpart a podíváme se kolik listových uzlů navrhne. V našem případě navrhne 11 listových uzlů. Lze očekávat, že zvýšením počtu uzlů může být dosaženo lepších výsledků. Parametr *tuneLenght* by proto měl očividně být > 11, zároveň je ale možno předpokládat, že z hlediska výpočtu budeme přibližně okolo optima a tak nemá smysl, aby hodnota parametru byla příliš vysoká (např. 100).

Platí, že čím vyšší hodnota parametru, tím více stromů algoritmus spočítá. S použitím 10-ti násobné CV a tuneLenght $= 20$ je tak ve skutečnosti vypočteno 200 stromů! Vzhledem k rychlosti v současnosti používané výpočetní techniky i přes to výpočet proběhl ve skoro reálném čase. Pro rozsáhlejší datové sady je potřeba brát ná výše uvedené ohled.

Poslední informací, kterou můžeme z modelu dostat je hodnocení důležitosti jednotlivých proměnných. Pro hodnocení můžeme využít knihovnu *vip* a stejnojmennou funkci z ní. Tato funkce vezme model a vypíše specifikovaný počet proměnných seřazených od nejvýznamnější po nejméně významnou, viz obr. 8.8.

Při přípravě vizualizace výsledku je vždy otázkou, kolik proměnných se má v grafu objevit. Jelikož má dataset 82 sloupců (z toho jeden cílový) je očividné, že maximální hodnota bude rovna 81. Ve většině případů je pro odvození modelu používána pouze relativně malá část sloupců. Pokusná počáteční hodnota může proto být např. 40 odpovídající přibližně polovině sloupců. Podle výsledku lze upravovat počet zobrazovaných sloupců směrem nahoru nebo dolů podle potřeby.

V našem případě má jistou vysvětlovací schopnost pouze 25 sloupců. Na obr. 8.8 je znázorněno 26 sloupců, aby hodnota posledního sloupce datasetu byla 0. Tímto způsobem je na obr. jasně demon-

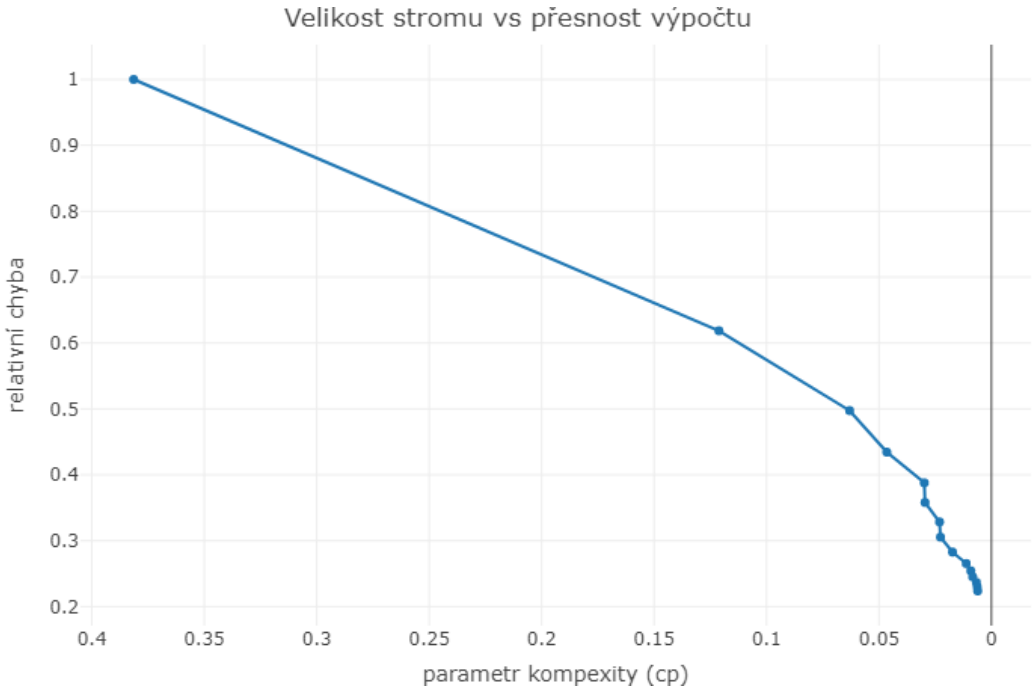

Obrázek 8.5: Vztah velikosti stromu a přesnosti výpočtu pro AMES dataset

Obrázek 8.6: Komplexita stromu a jeho přesnost pro AMES dataset měřeno pomocí RMSE

strováno, že v datasetu nejsou další významné sloupce.

8.4 Rozhodovací pravidla

K rozhodovacím pravidlům jsme dospěli již v předchozí kapitole, jako jedné z možností jak reprezentovat výsledek modelu rozhodovacího stromu. Co ale dělat v případě, kdy chceme odvodit pravidla aniž bychom odvozovali nejprve strom?

Pro demonstraci postupu použijeme opět příklad klientů banky, viz tabulka 8.1. Protože tento

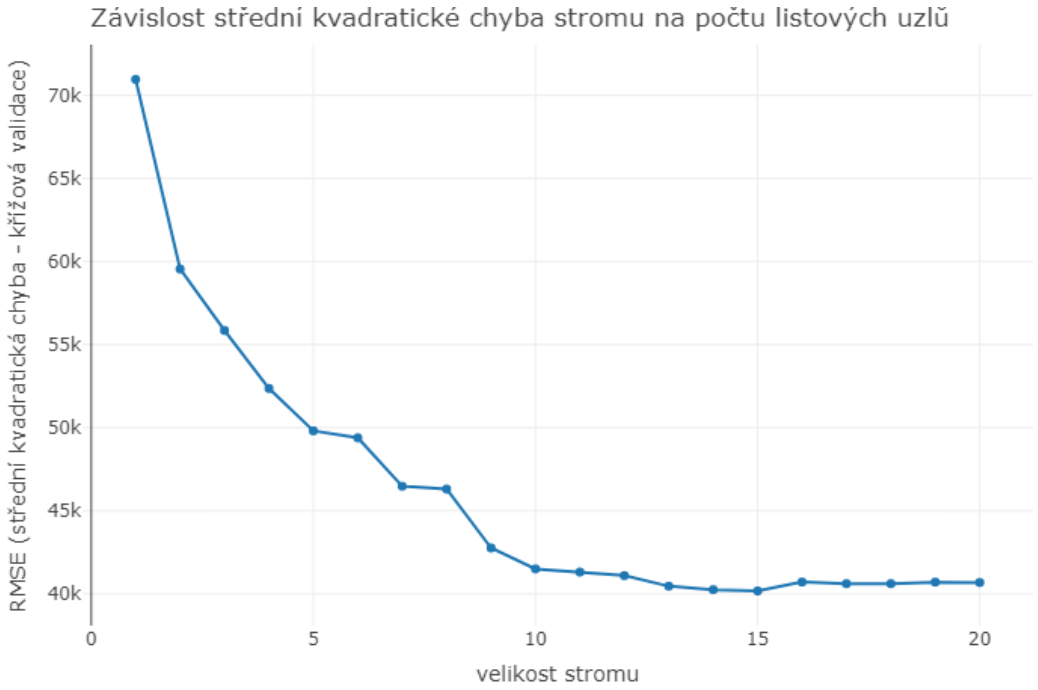

Obrázek 8.7: Vztah velikosti stromu a přesnosti výpočtu pro AMES dataset měřeno pomocí RMSE

Parametry modelu vs hyperparametry modelu
V textu jsme se setkali s novými pojmy *parametry* a *hyperparametry* modelu. Co to vlastně je? Formálně lze parametr definovat jako: *proměnná nebo hodnota odvozená z datasetu*. Dobrým příkladem parametru v případě lineární regrese je třeba parametr sklonu přímky. Oproti tomu hyperparametr je: *proměnná nebo hodnota, kterou není možné odvodit z dat*. Parametry i hyperparametry ovlivňují chování modelu a způsob jakým predikuje hodnoty.

Příkladem hyperparametru pro rozhodovací stromy je minimální počet měření, které musí obsahovat listový uzel. Většina modelů (včetně rozhodovacích stromů) má větší množství hyperparametrů.

Jelikož hyperparametry není možno odvodit z dat, musíme prostor hodnot jednotlivých hyperparametrů manuálně prohledávat. To je také naší zásadní motivací pro použití knihovny *carret*, která s „laděním“ hyperparametrů výrazně pomáhá.

příklad budeme dělat pouze ručně, zvolíme nejjednodušší způsob odvození těchto pravidel - budeme postupovat v datech sekvenčně.

Zvolíme první řádek, který vede na hledaný koncept - v našem případě na přidělení úvěru. Můžeme si zjednodušit situaci tak, že budeme předpokládat, že případy které konzistentně nevedou na úvěr(ano) povedou na úvěr(ne). To nám umožní zabývat se pouze podmnožinou pravidel.

Prvním řádkem, který splňuje naše požadavky je shodou okolností řádek první (k1). Z něj můžeme formulovat pravidlo: IF příjem(vysoký) && konto(vysoké) && pohlaví(žena) && nezaměstnaný(ne) THEN úvěr(ano).

Zkontrolujeme že dané pravidlo vede konzistentně na úvěr(ano), tedy že neexistuje jiný řádek obsahující stejné výchozí hodnoty, který by vedl na výsledek úvěr(ne). V našem případě tomu tak není.

Následně se pokusíme pravidlo zjednodušit. Postupujeme opět sekvenčně. Řádek k2 se liší od k1 v položce pohlaví. Z toho lze odvodit, že tento sloupec v tomto pravidle není určující a vyřadíme jej. Pravidlo se zjednoduší a zároveň nám pokryje místo jednoho řádku, dva.

Pohledem na k4 můžeme pravidlo ještě více zjednodušit do podoby IF konto(vysoké) THEN úvěr(ano). Tímto způsobem získáváme pravidlo, které umožňuje spolehlivě zaklasifikovat řádky k1, k2, k4 a k5. Tyto řádky z dalšího odvozování můžeme vyřadit.

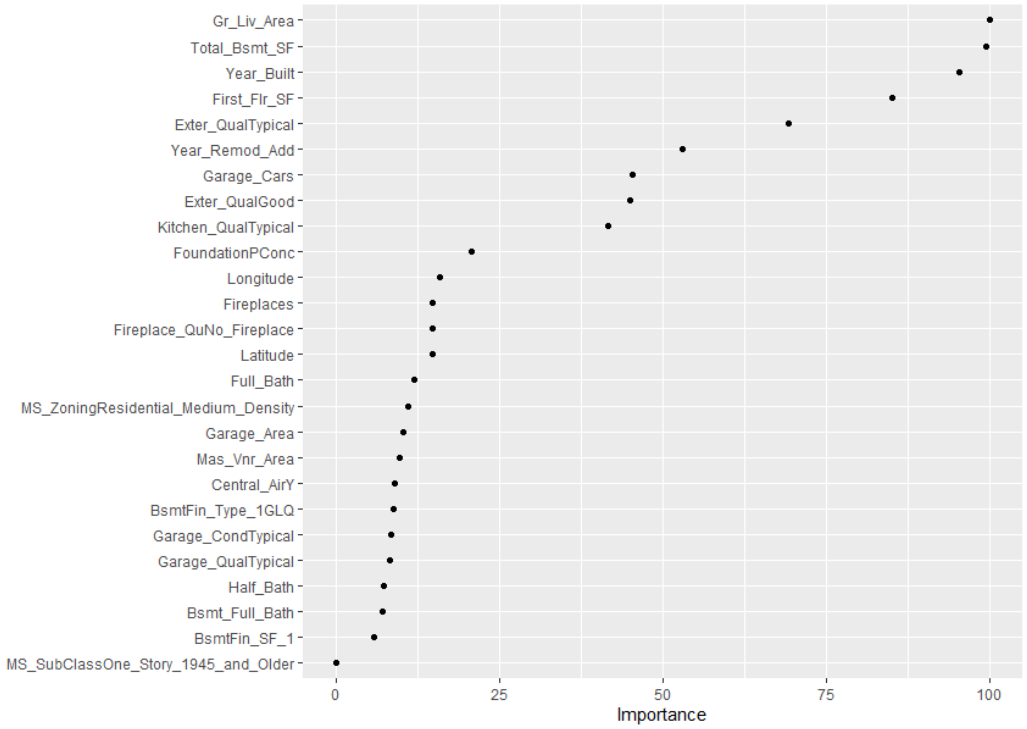

Obrázek 8.8: Hodnocení významnosti parametrů funkcí vip pro AMES data - model rozhodovacího stromu

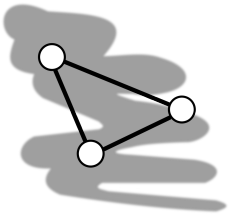

Případová studie
Dostali jsme se na konec případové studie... byla obsáhlá. Podobným způsobem budeme postupovat také pro další metody, které jsou v tomto předmětu probírány. Použijeme stejný příklad, aby jsme si v dalších kapitolách zjednodušili práci. V dalších kapitolách se tak zaměříme už pouze na interpretaci odlišností souvisejících s jinými typy modelu, které budeme používat.

Budeme ale stále používat stejný rámec hodnocení tzn.:

- výpočet modelu pomocí funkce train
- vizualizace modelu (pokud lze)
- interpretace RMSE
- hodnocení významnosti parametrů modelu (vip)

Postupujeme dále - dalším nepokrytým případem úvěr(ano) je k7. Odvodíme pravidlo IF Příjem(vysoký) && konto(nízké) && pohlaví(muž) && nezaměstnaný(ne) THEN úvěr(ano). Při porovnání s řádky k8 a k10 můžeme zjednodušit toto pravidlo na IF příjem(vysoký) THEN uvěr(ano). Pokryty tak máme řádky k7, k8 a k10, které s další analýzy vyřadíme.

Zbývá k12. Ten je poslední srovnáním s existujícími pravidly můžeme toto pravidlo zjednodušit do podoby: IF konto(střední) && nezaměstnaný(ne) THEN úvěr(ano).

Vzniká nám sada pravidel

Výpis 8.8: Rozhodovací pravidla

```
IF konto(vysoke) THEN uver(ano)
IF prijem(vysoky) THEN uver(ano)
IF konto(stredni) && nezamestnany(ne) THEN uver(ano)
```

Srovnejte tuto sadu pravidel se sadou, kterou jsme odvodili v předchozí podkapitole. Všimněte si, že obě sady jsou rozdílné, přesto obě sady spolehlivě pokrývají celou trénovací množinu.

Tento stav je z hlediska data miningu poměrně častý. Vzhledem ke složitosti problému používané algoritmy totiž nehledají **optimální řešení** (ve smyslu nejlepší řešení), ale **suboptimální** (ve smyslu

nejlepší reálně dosažitelné řešení, které stále ještě splňuje podmínky zadání).

Z praktických důvodů ale doporučujeme používat spíše rozhodovací stromy.

8.5 Asociační pravidla

Oproti rozhodovacím stromům a pravidlům nesloučí pravidla asociační ke klasifikaci případů. Umožňují ná ale lépe poznat data a vazby v nich. Tento druh algoritmů nám tak může posloužit pro deskripci nebo hledání nugetů.

Asociační pravidla byla vyvinuta v 80. letech minulého století Agrawalem a kol. [22] pro analýzu nákupního košíku. V tomto případě je potřeba analýzu nákupního košíku brát doslova. Výzkum se tedy zaměřil na hledání vazeb mezi jednotlivými položkami, které zákazníci nakupují, např. v supermarketech.

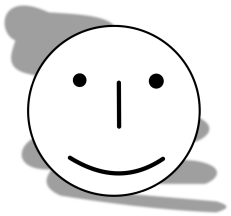

Kečup nebo hořčice
Dobrým příkladem vazby mezi zbožím může být třeba párek a hořčice. Neznamená to, že lidé kupují vždy tyto položky dohromady, spíše že se tato kombinace v nákupních košících objevuje častěji (je statisticky signifikantní).
Ti z Vás, kterým v nákupním košíku chybí ještě kečup, tak vězte, že se chuťově tragicky pletete :-).

Můžeme to vnímat trochu komicky jako v boxu *kečup vs hořčice*, ale aplikace jsou reálné. Výhoda asociačních pravidel je, že je možné zkoumat a testovat libovolné vztahy mezi dvojicemi položek, ale nemusíme se na ně vázat - testovat lze trojice atd.

Fáze odvozování tak do určité míry připomíná confusion matici, se kterou jsme pracovali výše. V kontextu příkladu párek - hořčice to můžeme shrnout tabulkou 8.6. Zkoumáme reakci zákazníka na koupi (nebo naopak nekoupení) párku - koupil hořčici.

Z tohoto pohledu párek bude v předpokladové části pravidla (antecedent), hořčice pak v závěrové části (sukcedent).

Tabulka 8.6: Párek vs hořčice

	hořčice suc	**!hořčice** !suc	$\sum$
párek (ant)	a	b	r
!párek (!ant)	c	d	s
$\sum$	k	l	n

V tabulce 8.6 tak a znamená kolikrát byl koupen párek a hořčice, b kolikrát byl koupen párek, ale ne hořčice... atd.

Ke dvojici pak lze vypočítat řadu charakteristik, např. podporu (8.7) nebo spolehlivost (8.8).

$$P(ant \wedge suc) = \frac{a}{a+b+c+d} = \frac{a}{n} \tag{8.7}$$

$$P(suc|ant) = \frac{a}{a+b} = \frac{a}{k} \tag{8.8}$$

Podpora tedy není nic jiného než poměr případů splňujících předpoklad i závěr pravidla k celkovému počtu případů. Spolehlivost pak představuje podmíněnou pravděpodobnost závěru.

Pro praktickou ukázku je potřeba ještě „předpřipravit“ několik charakteristik. Absolutní počet objektů splňujících předpoklad spočteme dle (8.9).

$$P(ant) = \frac{a+b}{a+b+c+d} = \frac{r}{n} \tag{8.9}$$

Analogicky absolutní počet objektů splňujících závěr je možno spočítat dle (8.10).

$$P(suc) = \frac{a+c}{a+b+c+d} = \frac{k}{n} \tag{8.10}$$

S těmito vzorci můžeme vypočítat *lift*, viz (8.11).

$$lift(ant \implies suc) = \frac{P(suc|ant)}{P(suc)} = \frac{P(ant \wedge suc)}{P(ant)P(suc)} \tag{8.11}$$

Lift je tedy definován jako poměr případů podporující pravidlo k součinu apriori pravděpodobností, že jednotlivé části pravidla nastanou bez ohledu na cokoliv jiného.

Hodnota lift může vyjít větší, menší nebo rovna 1. Hodnoty menší než 1 ukazují na negativní závislost popř. substituční efekt podle charakteru dat. Hodnoty větší než 1 ukazují na pozitivní závislost, popř. komplementární efekt.

Základem asociačních pravidel je tak generování kombinací hodnot jednotlivých sloupců a následný výpočet vlastností takových kombinací. Počet kombinací je i pro malé datové soubory obvykle velký. Např. pro datový soubor klientů banky (viz tab. 8.1) je možno vytvořit 323 kombinací hodnot.

Proto je více méně nemožné počítat asociační pravidla ručně. Zkusme demonstrovat tvorbu asociačních pravidel na příkladu. Tentokrát nepoužijeme klienty bank - protože bychom se mohli dozvědět šokující pravdy o tom, že např. pokud je člověk nezaměstnaný má nízký příjem apod. Pro demonstraci použijeme dataset Titanic, obsahující informace o pasažérech legendárního Titanicu a informaci o tom, zda přežili nebo ne.

Dataset můžete stáhnout buď z Intenetu (jedná se o open source dataset) nebo třeba z LMS, kde je k dispozici lokání kopie datasetu. Nejprve provedeme načtení a průzkum datasetu.

Výpis 8.9: Načtení datasetu Titanic do R

```
load("cesta/titanic.raw.rdata")
str(titanic.raw)
summary(titanic.raw)
```

RData je vnitřní formát, ve kterém pracuje R. Tento formát umožňuje ukládat datové sady včetně datových formátů, což je obvzláště výhodné u složitějších datasetů. Vyhnete se tím kroku, kdy např. data načtená z CSV souboru je nutno při každém načtení převést do vhodného formátu.

Funkce *load* umožňuje takový soubor načíst. Obdobným způsobem lze také data ukládat.

Výpis 8.10: Ukládání a načítání dat v R

```
save(klienti, file = "cesta/klienti.rdata")
#uložení více datasetů do souboru
save(klienti, prodejData, file = "cesta/cviceni.rdata")
load("cesta/cviceni.rdata") #opětovné načtení souboru
```

Funkce *str* vypíše vlastnosti datového souboru. Dataset Titanic obsahuje celkově 2201 pozorování (pasažérů + posádky lodi) ve čtyřech proměnných:

1. class - v jaké třídě byla osoba ubytována (1st, 2nd, 3rd, crew)
2. sex - pohlaví osoby (male/female)
3. age - věk osoby v okamžiku nehody (adult/child)
4. survived - zda osoba přežila (no/yes)

Vhled do struktury souboru nám pak poskytne funkce *summary*, její výstup je v tabulce 8.7.

Jedná se tedy o datový soubor, který je sice na jedné straně větší, avšak na straně druhé je strukturálně jednoduchý. Samotnou analýzu a vypsání pravidel můžeme provést následovně:

Výpis 8.11: Odvození asociačních pravidel pro dataset Titanic

```
library(arules)
pravidla = apriori(titanic.raw) #natrénování asociačních pravidel
pravidla #vypíše kolik pravidel bylo natrénováno
inspect(pravidla) #vypíše pravidla
```

Tabulka 8.7: Rozložení datasetu Titanic

Class (třída)	**Sex** (pohlaví)	**Age** (věk)	**Survived** (přežil)
1st: 325	Female: 470	Adult:2092	No :1490
2nd: 285	Male: 1731	Child: 109	Yes: 711
3rd: 706			
Crew: 885			

Pro práci s asociačními pravidly použijeme toolkit arules [39]. Tento toolkit implementuje dva populární algoritmy pro odvozování asociací a to tzv. apriori algoritmus a Eclat algoritmus. Pro náš příklad jsme použili první z těchto algoritmů pomocí funkce *apriori* s datasetem jako jejím parametrem.

Před prvním použitím toolkitu nezapomeňte, že je nutné jej nainstalovat (install.package("arules")).

Apriori algoritmus pro náš dataset odvodí 27 pravidel, která můžeme prozkoumat pomocí funkce *inspect*. Celý výpis pravidel vypadá následovně:

```
     lhs                                  rhs           support   confidence lift     count
[1]  {}                                => {Age=Adult}   0.9504771 0.9504771  1.0000000 2092
[2]  {Class=2nd}                       => {Age=Adult}   0.1185825 0.9157895  0.9635051  261
[3]  {Class=1st}                       => {Age=Adult}   0.1449341 0.9815385  1.0326798  319
[4]  {Sex=Female}                      => {Age=Adult}   0.1930940 0.9042553  0.9513700  425
[5]  {Class=3rd}                       => {Age=Adult}   0.2848705 0.8881020  0.9343750  627
[6]  {Survived=Yes}                    => {Age=Adult}   0.2971377 0.9198312  0.9677574  654
[7]  {Class=Crew}                      => {Sex=Male}    0.3916402 0.9740113  1.2384742  862
[8]  {Class=Crew}                      => {Age=Adult}   0.4020900 1.0000000  1.0521033  885
[9]  {Survived=No}                     => {Sex=Male}    0.6197183 0.9154362  1.1639949 1364
[10] {Survived=No}                     => {Age=Adult}   0.6533394 0.9651007  1.0153856 1438
[11] {Sex=Male}                        => {Age=Adult}   0.7573830 0.9630272  1.0132040 1667
[12] {Sex=Female,Survived=Yes}         => {Age=Adult}   0.1435711 0.9186047  0.9664669  316
[13] {Class=3rd,Sex=Male}              => {Survived=No} 0.1917310 0.8274510  1.2222950  422
[14] {Class=3rd,Survived=No}           => {Age=Adult}   0.2162653 0.9015152  0.9484870  476
[15] {Class=3rd,Sex=Male}              => {Age=Adult}   0.2099046 0.9058824  0.9530818  462
[16] {Sex=Male,Survived=Yes}           => {Age=Adult}   0.1535666 0.9209809  0.9689670  338
[17] {Class=Crew,Survived=No}          => {Sex=Male}    0.3044071 0.9955423  1.2658514  670
[18] {Class=Crew,Survived=No}          => {Age=Adult}   0.3057701 1.0000000  1.0521033  673
[19] {Class=Crew,Sex=Male}             => {Age=Adult}   0.3916402 1.0000000  1.0521033  862
[20] {Class=Crew,Age=Adult}            => {Sex=Male}    0.3916402 0.9740113  1.2384742  862
[21] {Sex=Male,Survived=No}            => {Age=Adult}   0.6038164 0.9743402  1.0251065 1329
[22] {Age=Adult,Survived=No}           => {Sex=Male}    0.6038164 0.9242003  1.1751385 1329
[23] {Class=3rd,Sex=Male,Survived=No}  => {Age=Adult}   0.1758292 0.9170616  0.9648435  387
[24] {Class=3rd,Age=Adult,Survived=No} => {Sex=Male}    0.1758292 0.8130252  1.0337773  387
[25] {Class=3rd,Sex=Male,Age=Adult}    => {Survived=No} 0.1758292 0.8376623  1.2373791  387
[26] {Class=Crew,Sex=Male,Survived=No} => {Age=Adult}   0.3044071 1.0000000  1.0521033  670
[27] {Class=Crew,Age=Adult,Survived=No} => {Sex=Male}   0.3044071 0.9955423  1.2658514  670
```

Co to ale znamená - jak můžeme tato pravidla interpretovat? *lhs* je zkratka pro left hand size (levá strana), pravidla), *rhs* - je zkratka pro right hand size (pravá strana). *Support* je podpora, viz 8.7, *confidence* je spolehlivost, viz 8.8 a *lift* vypočteme dle 8.11. *Count* pak představuje počet řádků datasetu vyhovující pravidlu.

První pravidlo je jednoduše interpretovatelné - ukazuje pouze na stratifikaci datového souboru - tedy faktu, že na Titanicu bylo 2201 osob, z toho 2092 dospělých, což představuje 95 % z celkového počtu osob na plavidle.

Problém s asociačními pravidly je ale v jejich interpretaci - uvažme např. pravidla na řádcích 9 - 11 - co přesně znamenají. Když nám vyšla u pravidla 9 podpora pro pravidlo nepřežil $\rightarrow$ muž přibližně 62 % s hodnotou lift 1,16 - co to znamená? Lift > 1 naznačuje negativní závislost, tedy muž $\rightarrow$ nepřežil (nepřežil z toho důvodu, že byl muž), proč tomu tak je?

Lze formulovat různé teorie, ale faktem je, že izolovaně to nemá smysl. V tomto případě by nás zajímala alternativní pravidla pro porovnání, např. žena → nepřežila. Ve skutečnosti ani toto by nám příliš nepomohlo. Ale se znalostí problému, můžeme pochopit co se ve skutečnosti stalo - jelikož nehoda Titaniku byla pečlivě zdokumentována a vyšetřena.

R. M. S. Titanik se potopil 15. dubna 1912 po srážce s ledovcem. Ke kolizi došlo v 23:40 místního času a k potopení lodi došlo v 02:20. Jako hlavní příčiny vysokého počtu obětí byl malý počet záchranných člunů a chybné vedení záchranných prací, kdy tyto čluny byly spouštěny na vodu navíc ještě ne zcela zaplněné.

Z hlediska záchrany byla preferována záchrana dětí a žen - odtud vyšší počet obětí z řad mužů. Lze také vysledovat spojení mezi třídou a záchrannou a to sestupně - pasažéři v první třídě byli zachraňováni častěji než ti z třídy druhé a ti zase častěji než pasažéři z třídy třetí.

Zdůvodnění v tomto případě lze hledat ve vzdálenosti, kterou museli pasažéři a posádka urazit k záchranným člunům. První třída byla nejblíže palubě, zatímco posádka byla umístěna nejblíže dnu.

Pokud se podíváme na pravidla touto optikou - co z nich můžeme vyčíst? ... nic moc, můžeme si ale pomoci, když specifikujeme, jaké pravidla nás ve skutečnosti zajímají. Řekněme, že se chceme zaměřit na přežití dětí.

Výpis 8.12: Asociační pravidla pro děti (dataset Titanic)

```
pravidla = apriori(titanic.raw, parameter = list(minlen=3, supp=0.002, conf=0.2),
    appearance = list(
            rhs=c("Survived=Yes"),
            lhs=c("Class=1st", "Class=2nd", "Class=3rd", "Age=Child", "Age=Adult"),
            default="none"), control = list(verbose=F))
pravidla.sorted = sort(pravidla, by="confidence")
inspect(pravidla.sorted)
```

Za tokových podmínek budou natrénována následující pravidla:

```
    lhs                     rhs             support     confidence lift      count
[1] {Class=2nd,Age=Child} => {Survived=Yes} 0.010904134 1.0000000  3.0956399  24
[2] {Class=1st,Age=Child} => {Survived=Yes} 0.002726034 1.0000000  3.0956399   6
[3] {Class=1st,Age=Adult} => {Survived=Yes} 0.089504771 0.6175549  1.9117275 197
[4] {Class=2nd,Age=Adult} => {Survived=Yes} 0.042707860 0.3601533  1.1149048  94
[5] {Class=3rd,Age=Child} => {Survived=Yes} 0.012267151 0.3417722  1.0580035  27
[6] {Class=3rd,Age=Adult} => {Survived=Yes} 0.068605179 0.2408293  0.7455209 151
```

Tento pohled nám už umožňuje srovnat šanci na přežití podle věku - co z tohoto pohledu vyvozujete? Na pomoc si vezměte údaje o zachráněných - můžete použít buď přímo dataset Titanic nebo použijte pro srovnání předpřipravená data dostupná např. na Wikipedii (doporučuji anglickou verzi článku - má přehlednější tabulku).

K orientaci může napomoci také vizualizace výsledku pomocí grafu. K tomuto účelu lze použít knihovnu arulesViz (opět před prvním použitím je nutné ji nainstalovat). Vizualizovat můžeme jako původní (viz obr 8.9) tak více cílenou sadu pravidel (viz obr. 8.10).

Výpis 8.13: Grafická interpretace asociačních pravidel (dataset Titanic)

```
library(arulesViz)
plot(pravidla, method="graph")
plot(pravidla.sorted, method="graph")
```

Všimněte si, že pro vygenerování druhé sady asociačních pravidel jsme museli upravit parametry apriori metody. Zejména jsme snížili naše nároky na spolehlivost - to nám umožní hledat pravidla, která pokrývají v analyzovaném prostoru malý počet dokumentovaných případů.

Jak je patrné z výše uvedeného - výpočet pravidel samotný je jednoduchý. To co je složité, je jejich interpretace. Pro úspěšnou analýzu proto musíme mít podrobné informace o zkoumaném problému. Odvozené znalosti bychom proto měli dále podrobit kritickému zkoumání. (Alespoň než na jejich základě začneme realizovat revoluci.)

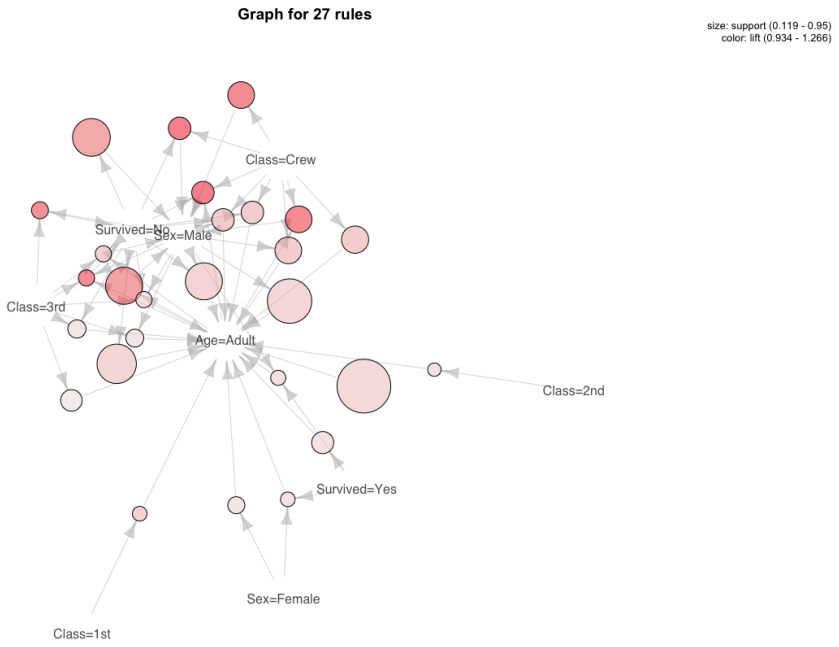

Obrázek 8.9: Asociační pravidla - dataset Titanic (27 základních pravidel)

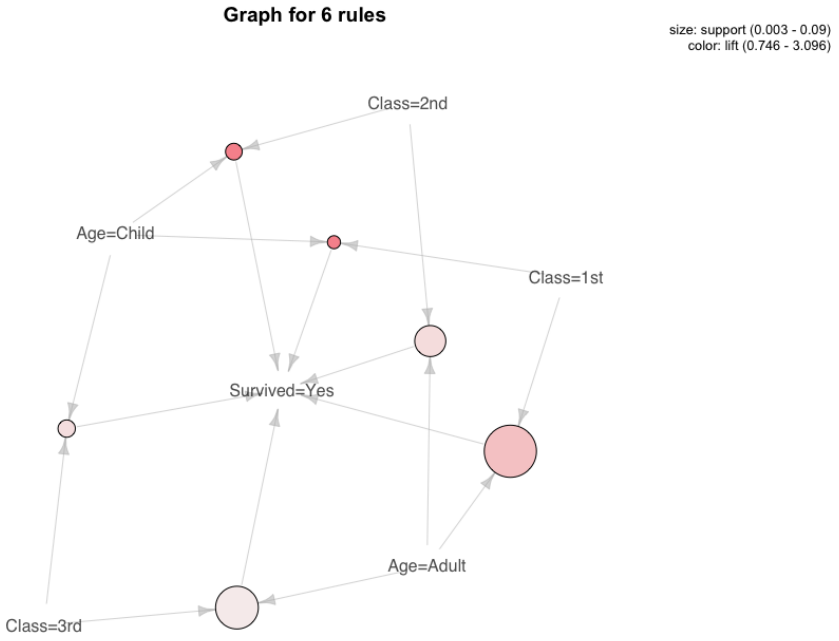

Obrázek 8.10: Asociační pravidla - dataset Titanic (zaměřeno na přeživší podle věku a třídy)

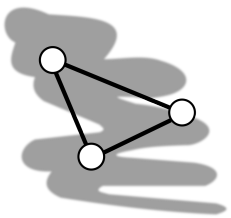

Titanic dataset a jeho analýza

Tento dataset je jedním z nejpoužívanějších pro demonstraci tvorby asociačních pravidel. Na Internetu tak lze dohledat desítky příkladů, které dataset analyzují z různých pohledů. Tyto příklady můžete vyhledat např. pomocí vyhledávače Google pomocí řetězce: *association rules titanic example*.

Řada příkladů používá také alternativní metody prezentace výsledků, včetně některých zajímavých možností jejich vizualizace.

Realizujte příklady z této kapitoly v R
... pokud jste tak ještě neučinili. Praktická realizace příkladů Vám umožní lépe zpracovat probíranou látku, která je po teoretické stránce poměrně složitá.

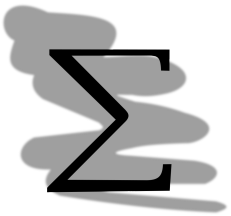

Shrnutí kapitoly
Pravidlové metody, řeší problémy data miningu tvorbou pravidel. *Rozhodovací pravidla a stromy* se zaměřují na řešení klasifikačních problému, zatímco *asociační pravidla* jsou určena k deskripci popř. hledání nugetů.
Výsledkem práce jsou vždy pravidla ve formátu IF předpoklad THEN závěr. Vyhodnocování pravidel lze zefektivnit převodem pravidel do formy rozhodovacího seznamu. V takovém případě je vyhodnocována pouze jedna podmínka, jejíž jednotlivé části se vzájemně vylučují.
Při konstrukci rozhodovacího stromu potřebujeme vodítko pro jeho efektivní stavbu. K tomuto účelu se často používá informační entropie. Pro větvení stromu používáme takový sloupec dat jehož entropie je nejmenší. Alternativně lze k tomuto účelu použít také Ginni index.
Vytvořený rozhodovací strom lze převést na pravidla.
Asociační pravidla umožňují analyzovat různé asociace existující mezi daty. K řešení lze použít celou řadu algoritmů - jedním z nejpoužívanějších je apriori algoritmus. Odvozená pravidla lze ohodnotit podle spolehlivosti, důvěryhodnosti a liftu. Finální interpretaci ale musí provést člověk v kontextu řešeného problému.

Kontrolní příklady

1. Mějme data o klientech banky ve formátu: konto, zaměstnaný, výše příjmu a přidělen úvěr - identifikujte cílový sloupec pro analýzu asociačními pravidly.
2. Jaké jsou nároky na data pravidlově orientovaných metod?
3. Jak rozhodujeme o vhodnosti datové položky k větvení rozhodovacího stromu?
4. Jaký je rozdíl mezí trénovací a validační množinou?

Řešení příkladů

1. Asociační pravidla se používají pro deskripci nebo hledání nugetů - cílový sloupec proto neurčujeme.
2. Problém jsou chybějící data a spojité numerické veličiny.
3. Můžeme použít např. informační entropii - k větvení používáme položku s minimální entropií.
4. Trénovací množina je obvykle větší a používá se pro odvození modelu, validační se použije následně pro dohad chyby odvozeného modelu.

Kapitola 9

Bayesovská klasifikace

Náhled kapitoly
V této kapitole probereme možnosti použití bayesovského klasifikátoru pro řešení klasifikačních problémů

Po prostudování této kapitoly budete
vědět

- jak fungují bayesův naivní klasifikátor
- jaké jsou výhody a omezení metody

umět

- prakticky použít metodu

Čas pro studium
Pro prostudování budete potřebovat 2 - 4 hodiny.

9.1 Úvod do Bayusovské klasifikace

Baysovský klasifikátor je odvozován od práce reverenda Theodora Bayese z krátkého pojednání o pravděpodobnosti, v rámci kterého zkoumá mezi pravděpodobností jedné události podmíněné událostí druhou a její inverzí. V moderní teorii pravděpodobnosti místo označení Bayesův theorém, popř. Bayesova věta nebo zákon používá spíše známější označení *podmíněná pravděpodobnost*.

Tento pojem by Vám neměl být zcela neznámý, neboť je vyučován v prakticky všech studijních oborech v rámci předmětů zaměřených na statistiku.

Vzorec je následující (9.1):

$$P(H|E) = \frac{P(E|H)P(H)}{P(E)} \tag{9.1}$$

Ve vzorci (9.1) pracujeme s podmíněnou pravděpodobností toho že nastane H za podmínky, že nastalo E. V kontextu našeho zájmu o data mining můžeme H označit za hypotézu a E jako důkaz (z angl. evidence). Podmíněnou pravděpodobnost pak vypočteme jako podíl součinu podmíněné pravděpodobnosti E za předpokladu, že nastalo H a apriori pravděpodobnosti E s apriori pravděpodobností H.

$P(E|H)$ je právě tou mysteriózní inverzí, na kterou jsme narazili v prvním odstavci této kapitoly.

Apriori pravděpodobností E a H pak rozumíme zastoupení jednotlivých důkazů a hypotéz v datovém souboru bez ohledu na další informace.

$P(H|E)$ je pak aposteriorní pravděpodobností - ta umožňuje změřit jak se změní pravděpodobnost H, za předpokladu, že nastalo E.

Zkusme tento koncept demonstrovat na příkladu. Mějte přitom prosím na paměti, že zatím se bavíme pouze o podmíněné pravděpodobnosti - nikoliv přímo o Baysově klasifikátoru.

Příklad: *Uvažujme školu, které víme, že ji navštěvuje 60 % chlapců a 40 % dívek. O studentkách víme, že nosí kalhoty nebo sukně a to přibližně půl na půl, předpokládáme, že všichni studenti nosí kalhoty. Pozorovatel vidí v dálce osobu, studující na dané škole, ale jediné, co je schopen rozeznat je, že nosí kalhoty. Jaká je pravděpodobnost toho, že se jedná o dívku?*

Tento příklad je tak jednoduchý, že je možné jej spočítat v hlavě. My jej ale vypočteme formálně a následně problém převedeme do formy klasifikačního problému. a závěry zobecníme.

Naší hypotézou tedy je, že student je dívka. Ze zadání proto můžeme odvodit, že podíl dívek na celkovém počtu studentů je 40 %, proto $P(H) = 0,4$.

Pravděpodobnost toho, že studující nosí kalhoty za předpokladu, že se jedná o dívku je 50 %, proto $P(E|H) = 0,5$.

Nejsložitější je pak výpočet $P(E)$, tedy pravděpodobnosti toho, že náhodně vybraný studující nosí kalhoty. Do této pravděpodobnosti nám vstupují všichni chlapci a polovina dívek. $P(E) = 0,5 \cdot 0,4 + 1 \cdot 0,6 = 0,8$.

Po dosazení do vzorce (9.1) tak získáme:

$$P(H|E) = \frac{P(E|H)P(H)}{P(E)} = \frac{0,5 \cdot 0,4}{0,8} = 0,25$$

Tedy odpovědí na naši otázku: *Jaká je pravděpodobnost toho, že v dálce viděný student s kalhoty je dívka* je 25 %.

Abychom problém převedli na klasifikační, museli bychom otázku reformulovat. *Pokud vidím v dálce studujícího s kalhoty jedná je spíše o chlapce nebo o dívku?* Tento případ je triviální, protože odpověď známe - jedná se spíše o chlapce, protože všichni chlapci v příkladu nosí kalhoty (na rozdíl od dívek) a zároveň je jich více.

To je ale výhoda, protože nám umožňuje posunout vnímání problému. Klasifikujeme do dvou tříd - chlapec/dívka. Vstupem do klasifikace jsou pak informace o podílu chlapců a dívek na škole a také informace o preferencích dívek stran nošení sukně.

S těmito informacemi můžeme spočítat pravděpodobnosti toho, osoba viděná v dálce je chlapec a že je dívka. Jako odpověď (zaklasifikování) pak bereme hypotézu s vyšší pravděpodobností. Matematicky tuto úvahu můžeme vyjádřit následovně (9.2):

$$H_{max} = H_J, pokud\ P(H_J|E) = \max_t \frac{P(E|H_t)P(H_t)}{P(E)} \tag{9.2}$$

Tedy výsledek určitě bude jedna z existujících hypotéz H, jejíž aposteriorní pravděpodobnost bude nejvyšší. 9.2. Všimněte si také $P(E)$ - pokud se nad tímto výrazem zamyslíme zjistíme, že je pro všechny hypotézy stejný. Jeho velikost je tedy z hlediska pořadí hypotéz podle pravděpodobnosti irelevantní.

To znamená, že můžeme tento výraz odstranit aniž bychom ztratili možnost identifikovat správně nejpravděpodobnější hypotézu H_{max}, ale s tím, že vypočtená hodnota již nebude mít charakter podmíněné pravděpodobnosti dle vzorce (9.1).

Zjednodušený vzorec je níže, viz (9.3)

$$H_{max} = H_J, pokud\ y = \max_t P(E|H)P(H_t) \tag{9.3}$$

Konečně jsme se tedy dostali k data miningu. S výše uvedenými vzorci je ale spojen jeden problém - berou v úvahu pouze jeden podpůrný „důkaz“. Pokud hypotéza má charakter výsledku klasifikace,

který je prakticky vždy tvořen jednou položkou, pak důkazy mají charakter vstupů. O nich víme z předchozí kapitoly, že jich obvykle máme větší množství a to i pro velmi jednoduché příklady.

Vzorce (9.2) a (9.3) tedy budeme potřebovat upravit, aby braly v úvahu podporu hypotézy větším počtem důkazů, viz (9.4). Tento vzorec bývá často označován jako *naivní bayesovský klasifikátor*.

$$P(H|E_1, ..., E_K) = \frac{P(E_1, ..., E_K|H)P(H)}{P(E_1, ..., E_K)} \tag{9.4}$$

Tento vzorec je možno po formálních úpravách zapsat následovně (9.5):

$$P(H|E_1, ..., E_K) = \frac{P(H)}{P(E_1, ..., E_K)} \prod_{k=1}^{K} P(E_K|H) \tag{9.5}$$

Symbol $\prod$ označuje součin. Svým použitím se tak podobá symbolu $\sum$, který sčítá. I v tomto případě představuje $P(E_1, ..., E_K)$ statickou hodnotu, která se pro různé hypotézy nemění.Můžeme ji tedy z výpočtu vyřadit, aniž by bylo narušeno pořadí hypotéz z hlediska pravděpodobnosti, viz (9.6).

$$H_{max} = H_J, pokud\ y = P(H) \prod_{k=1}^{K} P(E_K|H) \tag{9.6}$$

Podobně jako v případě konstrukce rozhodovacích stromů pomocí informační entropie je nutné aproximovat pravděpodobnosti pomocí relativních četností.

Výše uvedená forma klasifikátoru není jediná možná. Např. pro spojité proměnné lze použít *Gausův naivní Bayesův klasifikátor*, který vypadá následovně (9.7), pro binární hodnoty lze použít *Bernulliho naivní Bayesův klasifikátor* apod.

$$p(H = v|E_k) = \frac{1}{\sqrt{2\pi\sigma_k^2}} e^{-\frac{(v-\mu_k)^2}{2\sigma_k^2}} \tag{9.7}$$

Pro naše demonstraci, použijeme původní *naivní Bayesův klasifikátor*, tak jak je specifikován vzorcem (9.5). Řešit budeme klasifikační problém: konkrétně naši oblíbenou klasifikaci bonity klientů banky. Jako vstup použijeme data z tabulky 8.1.

Z tabulky vypočteme jednotlivé komponenty výpočtu:
P(úvěr(ano)) = 8/12 = 0,67
P(úvěr(ne)) = 4/12 = 0,33
P(příjem(vysoký)|úvěr(ano)) = 5/5 = 1
P(příjem(nízký)|úvěr(ano)) = 4/7 = 0,43
P(příjem(vysoký)|úvěr(ne)) = 0/5 = 0
P(příjem(nízký)|úvěr(ne)) = 4/7 = 0,57
P(konto(vysoké)|úvěr(ano)) = 4/4 = 1
P(konto(střední)|úvěr(ano)) = 2/4 = 0,5
P(konto(nízké)|úvěr(ano)) = 2/4 = 0,5
P(konto(vysoké)|úvěr(ne)) = 0/4 = 0
P(konto(střední)|úvěr(ne)) = 2/4 = 0,5
P(konto(nízké)|úvěr(ne)) =2/4 = 0,5
P(pohlaví(žena)|úvěr(ano)) = 4/6 = 0,67
P(pohlaví(muž)|úvěr(ano)) = 4/6 = 0,67
P(pohlaví(žena)|úvěr(ne)) = 2/6 = 0,33
P(pohlaví(muž)|úvěr(ne)) = 2/6 = 0,33
P(nezaměstnaný(ne)|úvěr(ano)) = 5/6 = 0,83
P(nezaměstnaný(ano)|úvěr(ano)) = 3/6 = 0,5
P(nezaměstnaný(ne)|úvěr(ne)) = 1/6 = 0,17
P(nezaměstnaný(ano)|úvěr(ne)) = 3/6 = 0,5

Řekněme, že budeme chtít zaklasifikovat případ k1, tedy: příjem(vysoký), konto(vysoké), pohlaví(žena), nezaměstnaný(ne).

Porovnávat pak budeme:

- P(úvěr(ano))P(konto(vysoké)|úvěr(ano))P(pohlaví(žena)|úvěr(ano))P(nezaměstnaný(ne)|úvěr(ano)) = 0,67 · 1 · 0,67 · 0,83 = **0,37**
- P(úvěr(ne))P(konto(vysoké)|úvěr(ne))P(pohlaví(žena)|úvěr(ne))P(nezaměstnaný(ne)|úvěr(ne)) = 0,33 · 0 · 0,33 · 0,17 = **0**

Dle výše uvedeného můžeme doporučit přidělení úvěru, což odpovídá záznamu v trénovací množině.

Všimněte si, že komponenty výpočtu jsme si předpřipravili a následně z nich pouze vybíráme čísla, která pak násobíme. Právě výpočet komponent je realizován k trénovací fázi klasifikátoru, součin vybraných komponent se pak použije během konzultace.

Z hlediska výpočtu se tak jedná o velmi efektivní postup. Tento typ klasifikátoru, je taky jednoduše použitelný pro koncepty, které se mění v čase. Nové případy tak stačí přidat do trénovací množiny a upravit vypočtené hodnoty komponent. V důsledku přidání nových případů pak dokonce nemusí dojít k přepočtení všech komponent.

Pokud to srovnáme s konceptem „zapomínání“ používaným rozhodovacími pravidly nebo stromy (konzultujte prezentaci pokud si nevzpomínáte na přednášku) - jedná se o podstatně elegantnější řešení, které má koncept změny pevně zabudován přímo do jádra metody.

Byť výpočet není nikterak složitý, je očividné, že realizovat reálný data miningový projekt bez podpory výpočetní techniky by bylo minimálně ... nepohodlné, pokud ne extrémně nepříjemné. Jak nám tedy s naivním Bayesovým klasifikátorem může pomoci třeba R?

Výpis 9.1: Naivní Bayesůk klasifikátor pro řešení problému klasifikace klientů banky

```
1  library("e1071")
2  klienti = read.csv("cesta/klienti_banky.csv", sep = ";", header = TRUE)
3  model = naiveBayes(klienti$uver ~ klienti$prijem + klienti$konto +
4                     klienti$pohlavi + klienti$nezam, data = klienti)
5  model #vypíše natrénované podmíněné pravděpodobnosti
6  scoreMnozina = read.csv("cesta/klienti_banky_score.csv", sep = ";", header = TRUE)
7  predpoved = predict(model, scoreMnozina)
8  predpoved #zobrazí, jak byly jednotlivé případy zaklasifikovány
9  table(pred=predpoved,true=scoreMnozina$uver) #konstrukce confusion matrix
```

Naivní Bayesův klasifikátor je implementován např. v ne úplně intuitivně pojmenovaném toolkitu e1071 [53] známém také pod názvem *Misc Functions of the Department od Statistics, Probability Theory Group* Technické univerzity ve Vídni.

Způsob použití je pak stejný jako u jiných klasifikačních problémů - specifikujete funkci, která je zodpovědná za vytvoření modelu, v našem případě *naiveBayes*. Parametry jsou pak stejné jako v jiných funkcích tohoto typu - specifikace modelu a dat, ze kterých se model má natrénovat.

Předpověď je pak generována funkcí *predict*. Jejími parametry jsou natrénovaný model a data, na které se má model aplikovat. V příkladu výše jsou pak ještě vypsány vlastnosti natrénovaného modelu, kód pro načtení datasetů a confusion matice.

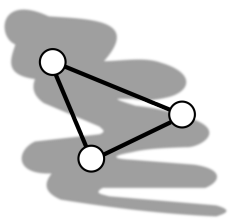

Porovnejte Bayesův klasifikátor a model stromu v R

Porovnejte způsob, jakým pracujeme s naivním Bayesovým klasifikátorem a funkce vytvářející rozhodovací strom z předchozí kapitoly.

Vidíte společné znaky obou přístupů ... a čím se liší?

Požadavky na data by Vám měly být jasné ze způsobu, jakým probíhá výpočet. Naivní Bayesův klasifikátor má problém v situacích, kdy příklady hledaného konceptu nejsou přítomny buďto vůbec, nebo nejsou přítomny v dostatečném zastoupení. V případě, že příklady nejsou zastoupeny vůbec, model nemá z čeho odvodit pravděpodobnosti. V případě malého zastoupení pak tento typ klasifikátorů má tendenci podceňovat pravděpodobnost málo zastoupených komponent.

Logickou obranou je snaha zajistit, aby trénovací množina byla dostatečně reprezentativní, vzhledem ke zkoumanému konceptu.

Příklady v R
Pokud jste ještě nevyzkoušeli realizovat příklad v R, teď je ta správná doba :-).

9.2 Případová studie

Pro případ Bayesova klasifikátoru budeme postupovat trošičku jinak než v případě rozhodovacích stromů. Jde o to, že v předchozí podkapitole představený přístup, resp. knihovna je použitelná prakticky pouze pro řešení klasifikačních problémů. AMES dataset ale vyžaduje zpracování odlišným způsobem - vyžaduje regresní model, byť by to nebyl klasický regresní model.

Existuje několik variant bayesovské regrese, které bychom mohli použít k řešení, ale použití vyžaduje poměrně značnou přípravu a zvládnutí dalšího nástroje (navíc k běžnému jazyku R). Pokud vás tato problematika zaujala, můžete podrobnosti najít v dokumentaci software Stan [21]. Konektivita k R je pak umožněna knihovnou rstan [20].

Zvládnutí tohoto nástroje ale dalece přesahuje možnosti tohoto předmětu. Proto použijeme raději tradiční dataset iris, které se používá často pro demonstrace klasifikačních problémů.

Tento dataset má pouze 5 proměnných. 4 proměnné sledují šířku a délku okvětních lístků (sepal, petal) - viz obr. 9.1 a sloupec species obsahuje druhové zatřídění kosatce (iris).

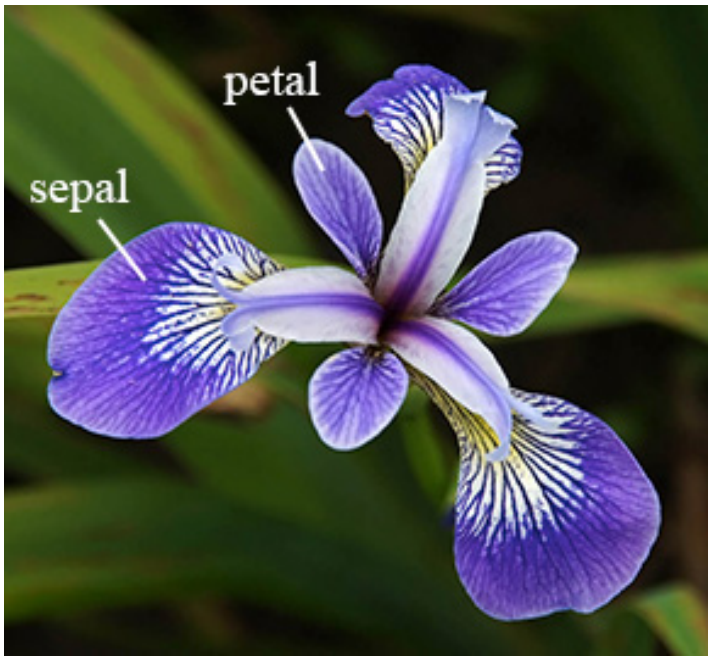

Obrázek 9.1: Kosatec (iris) - grafický popis významu sloupců (převzato z [81])

Dataset je jiný, přesto kód pro natrénování modelu pomocí knihovny caret by Vám měl připadat už poměrně známý.

Výpis 9.2: Naivní Bayesůk klasifikátor pro řešení problému klasifikace kosatců na základě vlastností jejich okvětních lístků

```
1 library("klaR")
2 library("caret")
3 library("e1071")
4
5 data("iris")
6 iris_nb <- train(
7   Species ~ .,
8   data = iris,
```

```
  method = "nb",
  trControl = trainControl(method = "cv", number = 10)
)
iris_nb
table(predict(iris_nb$finalModel,iris[,-5])$class,iris$Species) #confusion matice
```

Ve funkci train jsme provedli drobné změny. Jako metodu používáme *nb* což je zkrácené označení pro *naiveBayes* z knihovny e1071. Z funkce train vypadlo nastavení hyperparametrů, které v případě naivního bayesovského klasifikátoru postrádá smysl.

Přesnost výsledného modelu je κ okolo 94 %, což je poměrně dobrý výsledek. κ v tomto případě označuje metriku *Cohenova* κ měřící shodu mezi dvěma hodnotiteli, kteří klasifikují N případů do C vzájemně se vylučujících kategorií. V našem případě roli hodnotitelů zastupuje predikce a reálná měření.

Alternativní pohled představuje, confusion matice, viz tab. 9.1.

Tabulka 9.1: Bayesovná klasifikace pro iris dataset - confussion matice

	setosa	**versicolor**	**virginica**
setosa	50	0	0
versicolor	0	47	3
virginica	0	3	47

Iris dataset vs rozhodovací strom

Proveďte analýzu iris datasetu pomocí rozhodovacích stromů. Modifikujte příklad z předchozí kapitoly. Postupujte pomalu, samostatně a po částech. Ujistěte se, že chápete funkci jednotlivých příkazů - jak pro metodu bayesovského klasifikátoru, tak pro metodu rozhodovacích stromů.

Porovnejte confusion matice obou modelů, který z nich je lepší?

V případě, že narazíte na nepřekonatelný problém, konzultujte řešení problému dostupné v systému LMS.

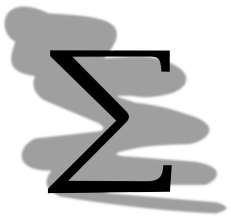

Shrnutí kapitoly

Naivní Bayesův klasifikátor je odvozován z podmíněné pravděpodobnosti. Při použití zkoumáme nakolik je pravděpodobně, že hodnocený příklad přináleží k některé cílové třídě, za předpokladu, že nastaly skutečnosti definované vstupními parametry. Pro klasifikaci je použita obvykle použita nejpravděpodobnější hypotéza.
Tento druh klasifikátoru je velmi výhodný z pohledu relativně malých nároků na data a schopnosti se rychle adaptovat v měnících se podmínkám, ve kterých realizujeme klasifikaci. Změny konceptu v čase tak lze prostě zahrnout do modelu přidáním nových příkladů do trénovací množiny a přepočtení jednotlivých komponent výpočtu.
V případě, že komponenty výpočtu jsou vytvářeny na základě neúměrně malého počtu vzorků, má klasifikátor tendenci podcenit význam takové komponenty.

Kontrolní otázky

1. Co rozumíme vztahem mezi pravděpodobností, že nastane jev A, za předpokladu, že nastal jev B a jeho inverzí?
2. Jaké jsou výhody použití Bayesova naivního klasifikátoru?
3. Jsou nějaké nevýhody použití klasifikátoru?
4. Interpretujte $\prod_{i=1}^{n} x_i$

Odpovědi

1. Existuje kvatifikovatelný a použitelný vztah mezi $P(A|B)$ a $P(B|A)$.
2. Nízké nároky na data, schopnost modelu jednoduše se adaptovat na změny v konceptu v čase.
3. Má tendenci podceňovat údaje, které nejsou v trénovací množině dostatečně zastoupeny.
4. $x_1 \cdot x_2 \cdot ... \cdot x_n$.

Kapitola 10

Neuronové sítě

Náhled kapitoly
Neuronové sítě jsou jednou z nejrychleji se rozvíjejících oblastí umělé inteligence. Zejména nástup moderních grafických karet a specializovaných Application Specific Integrated Circuit (ASIC) obvodů umožnila nasazení rozsáhlých mnohavrstevných neuronových sítí umožňujících v reálném čase řešit širokou škálu úloh od autonomního řízení automobilů, po automatizované překlady, systémů text-to-speech a dalších.

Po prostudování této kapitoly budete
vědět

- jak fungují vrstvené neuronové sítě

umět

- řešit jednoduché úlohy s použitím neuronových sítí

Čas pro studium
Pro prostudování budete potřebovat 2 - 4 hodiny.

Myšlenka umělých neuronových sítí není nikterak nová. Vlastně první model neuronu byl vytvořen podstatně dříve, než rozvoj výpočetní techniky umožnil takový model prakticky použít. Předtím než se ale vrhneme na podrobnosti, podívejme se na filozofické základy tohoto přístupu.

Pomocí neuronových sítí se snažíme napodobit způsob jakým živé organizmy myslí a to co možná nejblíže způsobu, jakým je organizován mozek - tedy pomocí neuronů a vazeb mezi nimi. Tím se přístup neuronových sítí liší od jiných oblastí uměle inteligence, např. expertních systémů, které se snaží formalizovat logiku myšlení exportů specifikací faktů a jejich použití v problémové doméně, nebo multiagentních systémů, kde jednotliví agenti mají implementovanou nějakou „malou“ funkcionalitu a pokročilé funkčnosti je dosahováno až vzájemnou interakcí jednotlivých agentů.

Neuronové sítě, které jsou v současnosti využívány, jsou ale relativně malé - obsahují tisíce až milióny neuronů podle problému a architektury neuronové sítě zvolené pro jeho řešení. Pokud to srovnáme s počty neuronů v mozcích, pak průměrný hlodavec má v mozku 12 a člověk 86 miliard neuronů [40].

U biologických organismů ale z hlediska myšlení nezáleží pouze na počtu neuronů. Např. mozek průměrného primáta obsahuje 93 miliard neuronů, což je více než kolik obsahuje mozek průměrného člověka (viz [40]). To, co považujeme za inteligenci je pak odvozováno také z toho, jak je mozek organizován, tedy k čemu jsou neurony používány.

Umělé neuronové sítě, jak jsou používány dnes ke svému tréningu obvykle vyžadují nasazení poměrně značného množství strojového času superpočítače. Takové neuronové sítě jsou ale vždy specializované na řešení určitého konkrétního úkolu. Náš mozek oproti tomu je univerzální.

Lze také říci, že v současnosti výzkum ani nesměřuje k vytvoření plnohodnotné umělé inteligence, byť už dnes jsou úvahy o otických otázkách spojených se spuštěním a provozováním takových systémů, viz např. iniciativa OpenAI [16].

Vraťme se ale k neuronům jako takovým a jejich implementaci pomocí počítačových modelů.

10.1 Neuron

Schéma neuronu bychom mohli vizualizovat např. jako na obr. 10.1. Tato vizualizace ve skutečnosti vizuálně příliš neodpovídá realitě - srovnejte s obr. 10.2, který byl pořízen mikroskopem.

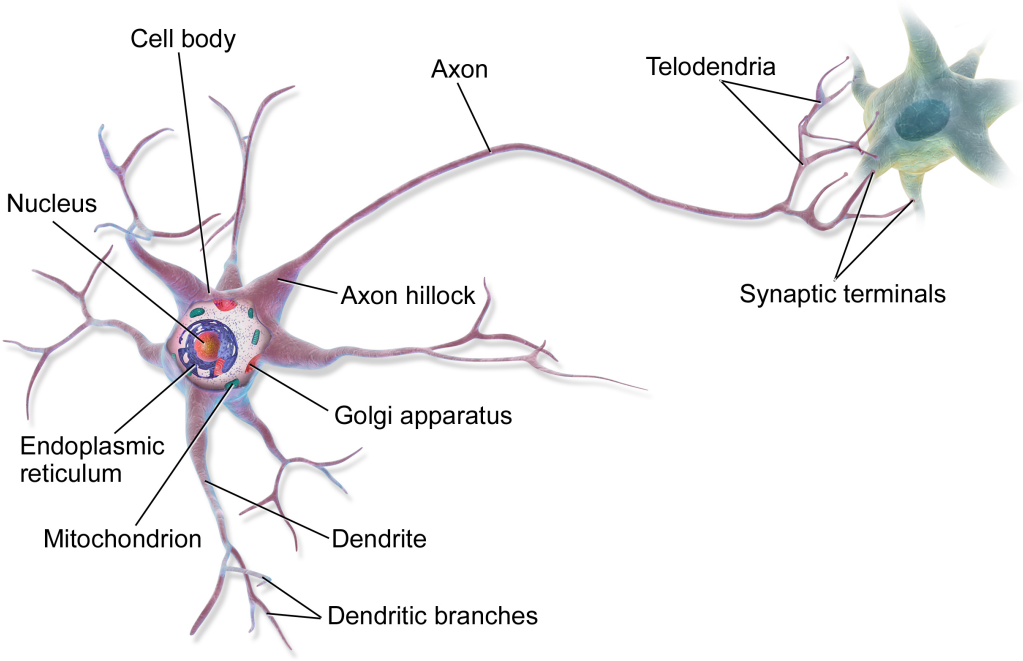

Obrázek 10.1: Schéma neuronu (převzato z [24])

Biologický neuron je buňka a proto jako každá buňka má jádro (nucleus), které pracuje jako „elektrárna“ buňky a umožňuje ji tak plnit svou funkci. Neurony mají řadu výběžků (dendritů) a jeden dlouhý výběžek označovaný jako axon (neurit). Pomocí axonu probíhá přenes tzv. nervových vzruchů. Výběžky axonu (telodendria) se pak připojují na další neurony.

Přenos nervového vzruchu do dalšího neuronu je realizován prostřednictvím synapse. Synapse má velmi důležitou úlohu tzv. *prahování*. To si lze představit tak, že synapse přijme nervový vzruch - pokud intenzita tohoto vzruchu přesáhne hodnotu prahu, pak je vzruch dojde k excitaci neuronu a vzruch se prostřednictvím jeho axonu šíří dále.

Naopak pokud intenzita nervového vzruchů nepřesáhne hodnotu prahu, dojde k utlumení vzruchu - neuron nepřejde do excitovaného stavu a nešíří vzruch dále.

Reakci neuronové sítě mozku si tak vizuálně můžeme představit tak, že v reakci na různé podněty přijímané všemi smysly se budou excitovat odlišné trajektorie spojení neuronů v mozku - a to nám umožňuje realizovat funkci myšlení.

Umělé neuronové sítě se pak snaží tyto funkce přírodních neuronů napodobit a využít k řešení problémů.

První model neuronu je byl vytvořen v roce 1943 Warrenem McCullochem a Walterem Pittsem [51] - autoři jej nazvali *perceptron*. Perceptron poměrně věrně kopíruje funkce reálného neuronu a přes své stáří je i dnes jedním z nejpopulárnějších modelů neuronů.

Funkci perceptronu si můžeme schematicky představit jako na obr. 10.3.

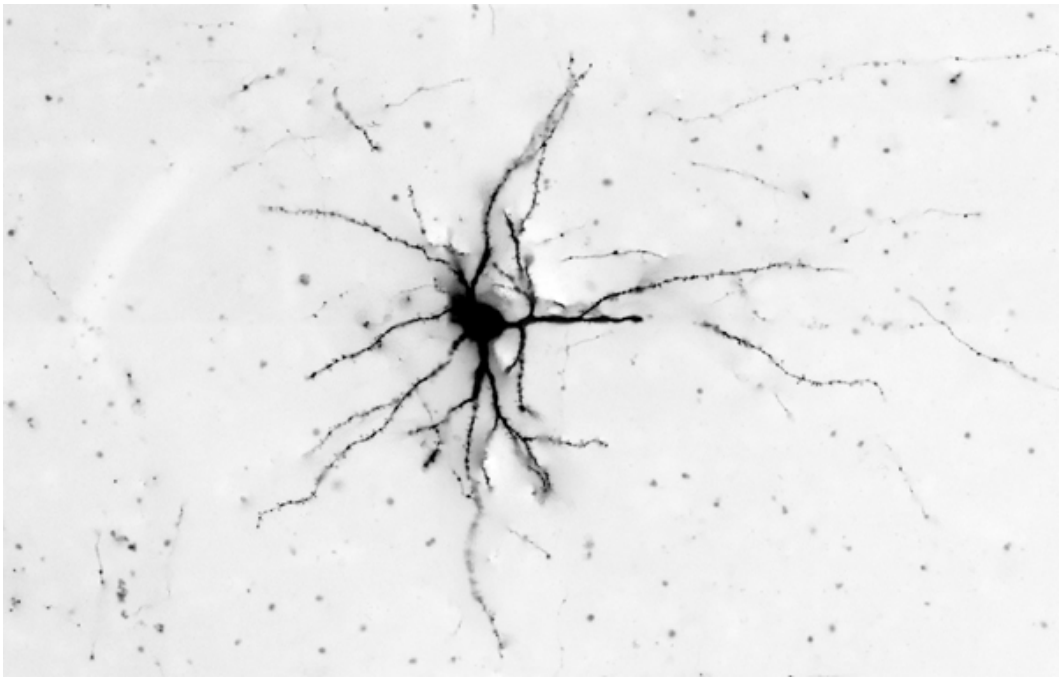

Obrázek 10.2: Neuron vizuálního kortexu (převzato z [43])

Na normované vstupy x_1 až x_n jsou aplikovány váhy w a výsledek je agregován (sečten) a podroben procesu prahování. Na výslednou hodnotu je aplikována funkce nelineárního zobrazení, která transformuje vstupní hodnotu na výstupní hodnotu y.

Matematicky lze perceptron vyjádřit následovně. Vážený vstupní signál $z(t)$ (10.1) je agregován do $u(t)$ (10.2).

$$z(t) = x(t) \cdot w(t) \tag{10.1}$$

kde z je vážený vstupní signál, x normovaný vstupní signál (obvykle v intervalu 0-1), w jsou pak váhy.

$$u(t) = \sum_{i=1}^{n} x_i(t) \cdot w_i(t) \tag{10.2}$$

Prahování se provádí tak, že se od agregovaných vstupních signálů $u(t)$ odečte hodnota prahu w_0, viz rovnice (10.3).

$$v(t) = u(t) - w_0 \tag{10.3}$$

Funkci nelineárního zobrazení volíme podle požadavků, které klademe transformaci prahované hodnoty $v(t) \rightarrow y$ na hodnotu výstupní. Jednou z nejčastěji používaných funkcí tohoto typu je tzv. *sigmoida*, kterou je možno vypočítat dle vzorce (10.4). Graficky je pak sigmoida znázorněna na obr. 10.4.

$$y(t) = \frac{1}{1 + e^{-v(t)}} \tag{10.4}$$

Všimněte si, že sigmoida je spojitou funkcí, ale lze uvažovat také o jiných modelech transformace - např. $y(t) = 0$ pro $v(t) < 0$, $y(t) = 1$ pro $v(t) \geq 0$. Taková funkce je nespojitá v $x = 0$ y skočí z 0 na 1.

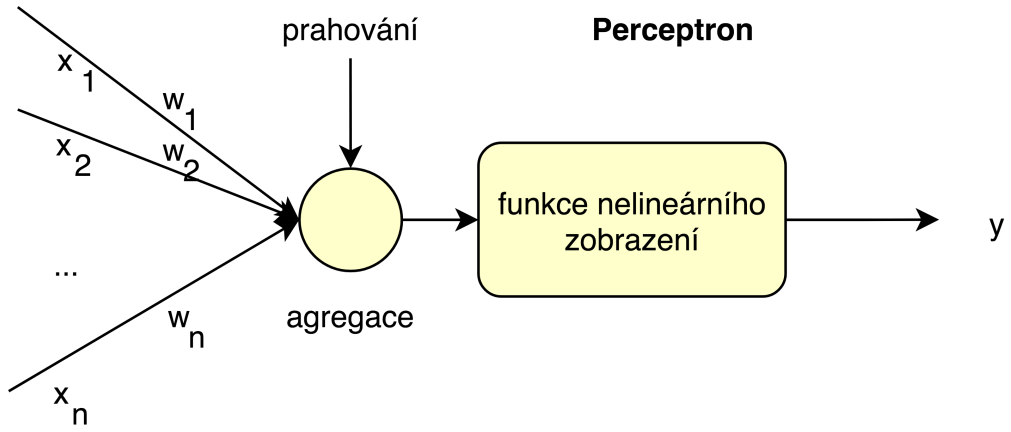

Obrázek 10.3: Schématické znázornění modelu perceptronu

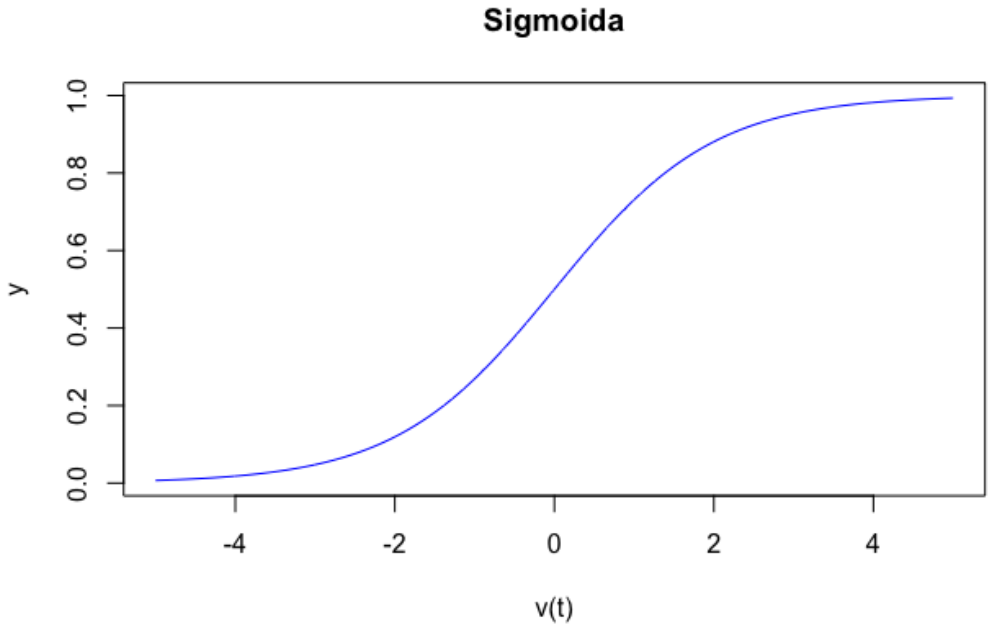

Obrázek 10.4: Graf sigmoidy

10.2 Neuronové sítě a jejich adaptace

V minulé podkapitole jsme se seznámili s modelem neuronu, jeden neuron nám ale problém nevyřeší. Řešení je možné pouze při zapojení, obvykle velkého množství, neuronů do sítě. Přitom platí, že čím je síť rozsáhlejší (s čím většího počtu neuronů se skládá) tím dokáže být při řešení problémů přesnější a tím je také z hlediska portfolia problémů řešitelných tímto způsobem univerzálnější.

V průběhu doby se objevovala celá řada typů sítí. V prvopočátcích se pracovalo pouze s jedinou vrstvou v síti. Uvažujme problém: *potřebujeme vyřešit problém rozpoznávání znaků v naskenovaném textu. Jako vstup nám slouží stav pixelu obrázku rozlišovaného znaku. Uvažujeme přitom 2 stavy reprezentované bílou a černou barvou znaku - černá znamená součást písmene, bílá znamená papír.*

Znak A pomocí jednoduché jednovrstevné sítě bychom mohli znázornit třeba jako na obr. 10.5a. Z hlediska vstupů do neuronové sítě lze místo neuronů (na obr. kolečka :-) dosadit hodnotu 0 (bílá) nebo 1 (černá). Výhodou použití neuronové sítě je pak to, že neuronová síť správně určí nejen když bude rozložení „aktivních“ neuronů přesně odpovídat písmenu, ale také případy kdy je reprezentace písmene do určité míry poškozená. Proto např. také 10.5b bude vyhodnoceno jako písmeno A.

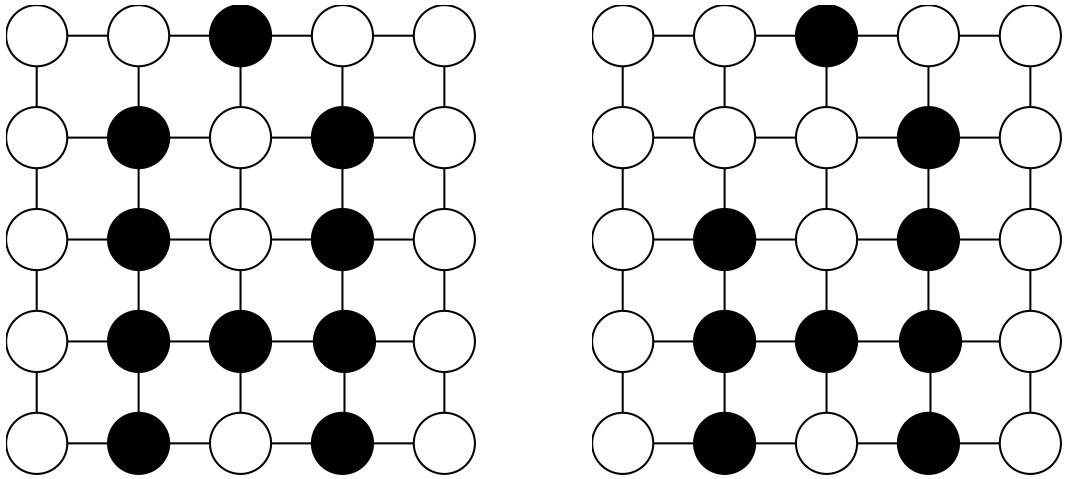

(a) znak A (b) poškozený znak A

Obrázek 10.5: Jednoduchá neuronová síť pro OCR

Jednovrstevné sítě jsou právě vhodné pro zpracování grafických informací. V moderních sítích, např. pro účely identifikace objektů v prostoru pro samořiditelná auta je ale používána celá řada takových sítí. Jejich výstup je pak integrován do komplexního modelu prostředí, který slouží jako podklad pro rozhodování řídící jednotky automobilu.

Podrobnosti lze nalézt např. v článku NVidie [26].

Více vrstevné neuronové sítě jsou z hlediska použití mnohem univerzálnější. Na obr. 10.6 je znázorněn zjednodušený příklad takové sítě.

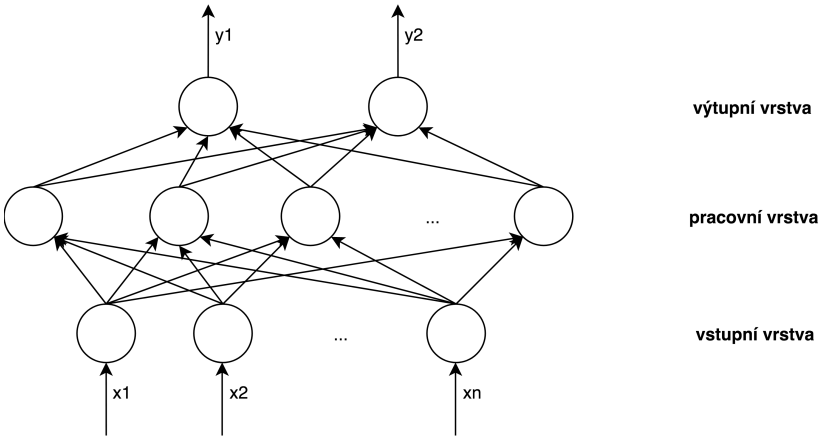

Obrázek 10.6: Schéma vícevrstevné sítě

Všimněte se, že vazby mezi neurony v síti 10.6 jsou orientované. Vstupy ve *vstupní vrstvě* x_1 až x_n procházejí v tomto případě jednou *pracovní vrstvou*, výstupní vrstvu v tomto případě tvoří dva neurony y_1 a y_2.

Pracovní vrstvy se někdy označují také jako skryté. To je dáno tím, že vstupy zadáváme a výstupy y pak odečítáme, ale uvnitř neuronová síť funguje jako černá skříňka. Pracovních vrstev v síti může být libovolné množství. Přitom počet neuronů v takové síti není nijak stanoven, vetšinou jich ale volíme více než je ve vstupní vrstvě. Předpokládáme přitom, že neuronů ve vstupní vrstvě je více než ve vrstvě vrstvě výstupní.

Volba architektury sítě tak není exaktně daná. Není tak od věci experimentovat s různou velikostí sítě apod. a porovnávat jakých výsledků bude dosaženo.

Všimněte si také, že strukturálně je každý neuron předchozí vrstvy připojen na každý neuron vrstvy následující. Prakticky to znamená, že s rostoucím počtem neuronů v síti roste počet vazeb v sítích tohoto typů exponenciálně. To pak na nás může klást jistá omezení z hlediska „vypočítatelnosti/adaptovatelnosti“

takových sítí. Složitost roste exponenciálně, ale výkon výpočetní techniky jsme obvykle schopni škálovat pouze lineárně.

Zkusme zrealizovat jednoduchou demonstrační síť pro predikci průběhu funkce, jako alternativu *lineární regrese*, se kterou jste se mohli setkat např. v předmětu Statistika.

Mějme jednoduchou funkci $y = x^2$. Řekněme, že trénovací množinu (viz tab. 10.1) budeme mít hodnoty $x \in < 0; 10 >$ po celých číslech.

Tabulka 10.1: Trénovací množina funkce $y = x^2$

input	output
0	0
1	1
2	4
3	9
4	16
5	25
6	36
7	49
8	64
9	81
10	100

Výpis 10.1: Řešení funkce druhé mocniny pomocí neuronové sítě

```
1  library("neuralnet")
2  mydata=read.csv("cesta/nn_fce_2mocnina.csv", sep=",", header=TRUE)
3  #trénink neuronové sítě
4  model=neuralnet(formula=output~input, data=mydata, hidden=10, threshold=0.01)
5  model_lm = lm(output~input, data=mydata) #pro srovnání lineární regrese
6  plot(model) #vykreslení vrstev sítě v (síťový graf)
7  #porovnání dat - skutečná a predikce
8  final_output=cbind(mydata$input, mydata$output,
9                     as.data.frame(model$net.result),
10                    as.data.frame(model_lm$fitted.values))
11 colnames(final_output) = c("Input", "Expeceted output", "NN Output", "LM Output")
12 plot(final_output$`Expeceted output`, col="red", main="Predikce vs realita",
13      xlab="cisla", ylab="druha mocnina")\
14 lines(final_output$`NN Output`, col="blue")
15 lines(final_output$`LM Output`, col="green")
16 legend(1,95, legend=c("skutecne hodnoty", "predikce NN", "predikce LM"),
17       col=c("red", "blue", "green"), lty=1:3, cex=0.8)
```

Pro demonstraci použijeme toolkit *neuralnet* [37]. Který umožňuje realizaci jednoduchých modelů neuronových sítí. (Pro pokročilejší práci je ale vhodnější použít některé pokročilejší toolkity.)

Model je načten ze souboru CSV, a natrénován pomocí funkce *neuralnet*. Počet neuronů vstupní a výstupní vrstvy je dán strukturou zvoleného modelu (parametr *formula*). V našem případě, bude mít tedy jede vstupní a jeden výstupní neuron. Počet neuronů pracovní vrstvy jsme nastavili parametrem *hidden* na 10. Pomocí parametru *threshold* nastavujeme požadovanou přesnost modelu.

Prosím všimněte si, že chyba nemůže být nastavena na nula - důvodem je tzv. problém *přeučení* neuronové sítě. K problému přeučení se ale ještě vrátíme.

Struktura neuronové sítě je pak vykreslena pomocí funkce plot, viz obr. 10.7.

Zbývající část skriptu R pak slouží pro přípravu porovnání modelu lineární regrese, neuronové sítě a skutečnosti a vykreslení do grafu na obr. 10.8.

Porovnání z obr. 10.8 jasně ukazuje, že model neuronovou sítí je přesnější než námi zvolený model lineární regrese. K tomu je potřeba dodat, že by tomu tak být nemuselo. V našem případě není důvod, abychom nebyli schopni odvodit regresní model s podobnou přesností.

Místo toho, ale tuto situaci použijeme pro zdůvodnění jedné z nejsilnějších stránek použití neuronové sítě. Lineární model totiž po nás požadoval přijmout jisté předpoklady o vzhledu modelu. V našem případě, že bude vypadat následovně: $y = a + bx$, kde koeficienty a a b budou odvozeny.

My samozřejmě víme, že správně model měl být $y = x^2$, ale informace tohoto typu obvykle není dostupná - konečně, pokud víme, jak vypadá funkce, není potřeba se snažit ji odvodit.

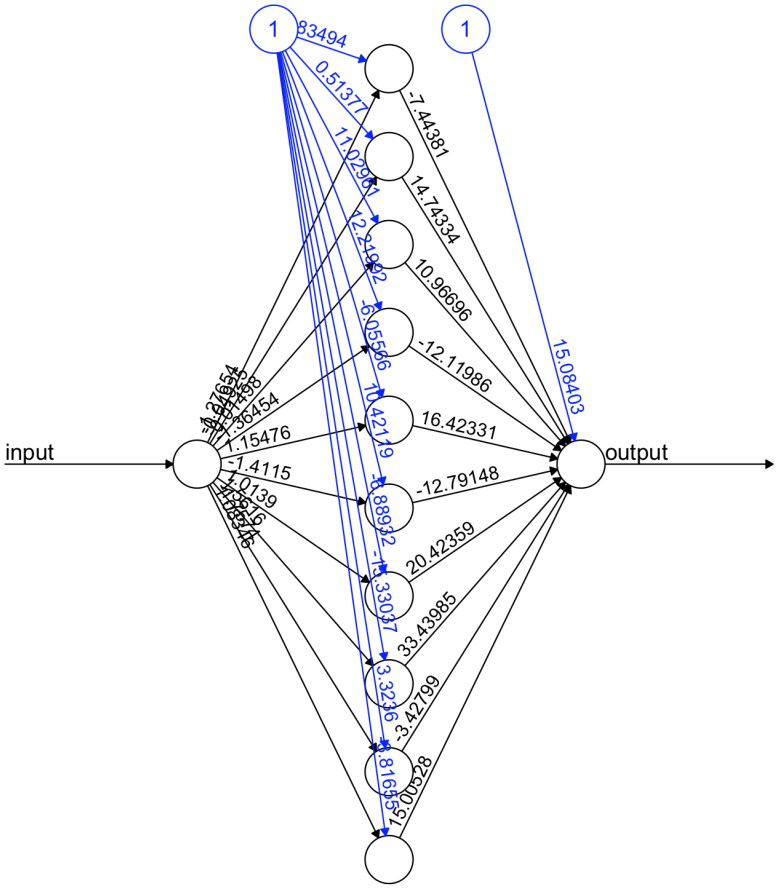

Obrázek 10.7: Neuronová síť pro predikci hodnot funkce $y = x^2$

Neuronová síť proti tomu po nás nežádala přijmout žádný předpoklad o fungování modelu. Specifikovali jsme pouze základní strukturu neuronové sítě a model se odvodil sám. Ve skutečnosti mohla být struktura neuronové sítě podstatně jednodušší - mohlo stačit možná 5 možná ještě méně neuronů. Můžete sami vyzkoušet kolik neuronů z pracovní vrstvy můžete odebrat aniž by to zanechalo následky na přesnosti modelu.

Jak se tedy vůbec neuronová síť adaptuje?

Pro adaptaci se většinou používá tzv. *učení s učitelem*. To znamená, že adaptačnímu algoritmu se předkládá trénovací množina ve formátu vstup → výstup, což umožňuje pro neuronovou síť porovnáním s jejím skutečným výstupem vypočítat chybu. Tato informace je pak použita pro další iteraci adaptace sítě.

Představit si to lze tak, že na začátku procesu adaptace je všem vazbám mezi neurony v síti přiřazena náhodná hodnota váhy w_n. Adaptací pak postupně tyto váhy měníme s cílem konvergovat postupně ke specifikované chybě.

Nejpoužívanější metodou pro tento účel je tzv. *backpropagation* - česky metoda *zpětného šíření chyb*. Matematicky je metoda založena na výpočtu globální chyby GE jako rozdílu očekávaného a skutečného výstupu sítě, viz (10.5).

$$GE = \sum_{i=1}^{n} (y_i - d_i)^2 \tag{10.5}$$

Kde GE je globální chyba (global error), y je očekávaný výsledek a d skutečný výsledek sítě.

Z matematiky víme :-), že k nalezení minima funkce potřebujeme tuto funkci derivovat (10.6).

$$\Delta w = -\eta \frac{\partial GE}{\partial w} \tag{10.6}$$

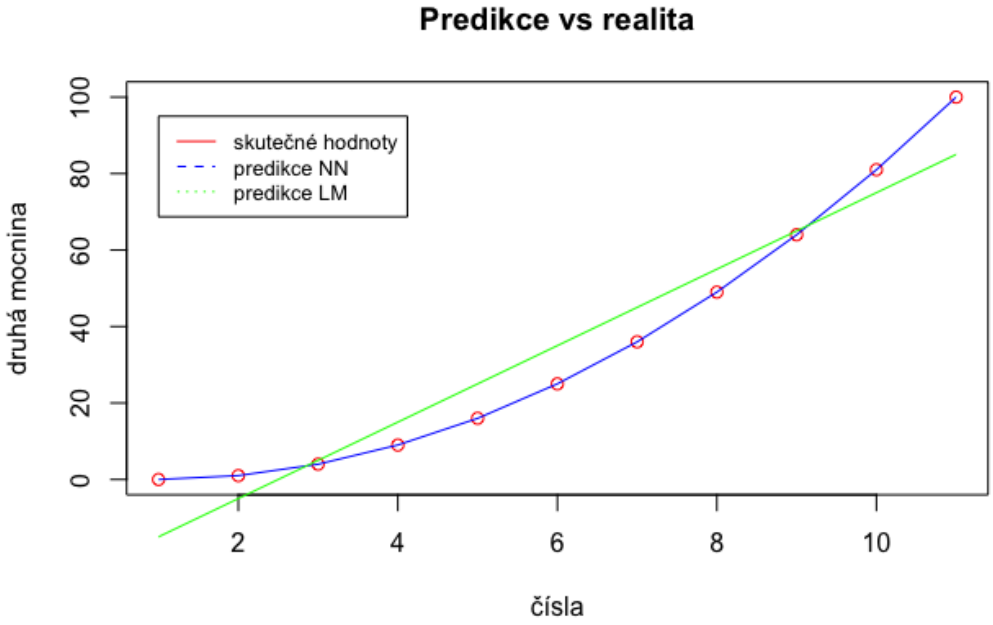

Obrázek 10.8: Funkce $y = x^2$ - srovnání modelu neuronovou sítí a lineární regresí

Proč součet čtverců?
Podívejte se na vzorec 10.5 - proč myslíte, že je pro výpočet GE použit součet čtverců a ne např. $GE = \sum y_i - d_i$?

Úkolem hodnoty η je pak zajistit, aby Δw bylo velmi malé. Zdůvodnit si to můžeme tak, že při lehkých změnách riskujeme, že budeme oscilovat okolo žádoucí hodnoty. Volbou $\eta = 0,1$ nebo $\eta = 0,01$ nebo dokonce menší zajistíme, že proces adaptace bude pomalu směřovat k cíli. To ... *pomalu* je bohužel pro rozsáhlejší sítě potřeba zdůraznit.

Minimalizace globální chyby má svá omezení. U neuronových sítí riskujeme u příliš malých chyb možnost *přeučení*. Přeučená neuronová síť u případů z trénovací množiny dosahuje minimální chyby, ale u příkladů, které nejsou v trénovací množině je chyba naopak výrazně vyšší.

Graficky si to můžeme představit podobně jako na obr. 10.9.

Vstupem pro modely vizualizované na obr. 10.9 jsou body (na obr. červená kolečka). Pro tyto body byly vytvořeny dva modely reprezentované modrou a červenou křivkou. Všimněte si, že červená křivka přesně kopíruje zadané body, zatímco modrá jde mezi nimi.

V tomto případě je modrá křivka přesnější, protože rozmístění bodů okolo této linie bylo způsobeno náhodnou chybou měření. Taková chyba se v reálu objevuje prakticky pokaždé. Přílišnou snahou o přesnost, která vedla k odvození červeného modelu, jsme tak ve skutečnosti zvětšili výrazně chybu, s jakou model pracuje.

Z tohoto důvodu je potřeba se smířit s jistou nevyhnutelnou chybou, kterou model bude obsahovat vždy a která je vynucena fyzickými charakteristikami způsobu jakým byla data pořízena.

Problém přeučení není problém čistě jen neuronových sítí - podobný problém mají třeba rozhodovací stromy - i ty lze přeučit. Řešení v takovém případě spočívá v „prořezání stromu“. Postupně odebíráme listové uzly a sledujeme, jestli dochází ke zvyšování přesnosti řešení.

Řešení klasifikačního problému probíhá vlastně stejně jako probíhalo odvození modelu funkce $y = x^2$. Pro demonstraci můžeme použít opět příklad klientů banky, viz tab. 8.1.

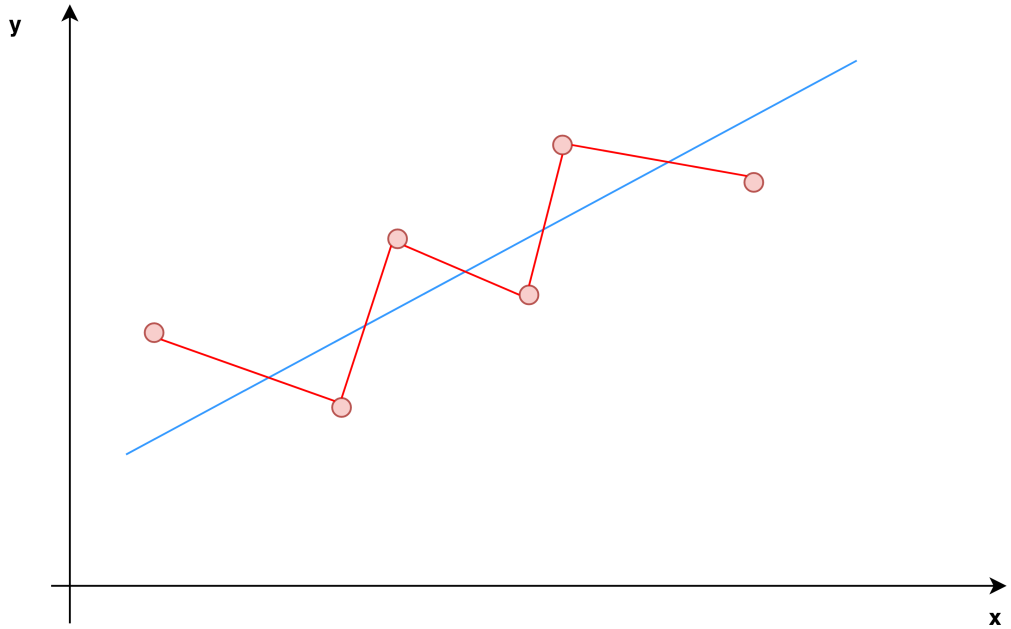

Obrázek 10.9: Přeučený model

Výpis 10.2: Klienti banky - řešení neuronovou sítí

```
1  library("neuralnet")
2  mydata=read.csv("cesta/klienti.csv", sep=",", header=TRUE)
3  model=neuralnet(formula=uver~prijem+konto+pohlavi+zam,
4                  data=mydata, hidden=20, threshold=0.01)
5  plot(model)
6  final_output=cbind(mydata$uver, as.data.frame(model$net.result))
7  colnames(final_output) = c("ocekavano", "spocteno")
8  final_output
```

Pouze v tomto případě jsem do pracovní vrstvy zvolil 20 neuronů. Vizuálně neuronová síť vypadá jako na obr. 10.10.

Modely tvořené desítkami neuronů je možno na moderních počítačích počítat prakticky v reálném čase. 20 neuronů skryté vrstvy je tak pravděpodobně nadsazený počet, ale nějaké výrazné úspory času bychom z hlediska výpočtu nedosáhli.

Výsledek sítě je znázorněn v tab. 10.2.

Tabulka 10.2: Neuronová síť predikce vs realita ($y = x^2$)

	očekáváno	**spočteno**
1	1	1.0019334196327
2	1	1.0069034997006
3	0	-0.0130942067801
4	1	0.9825741850726
5	1	0.9861262522598
6	0	-0.0033695338052
7	1	1.0086557396241
8	1	0.9899790546700
9	0	-0.0002532946061
10	1	0.9844730618735
11	0	0.0380269653583
12	1	1.0135488795748

Všimněte si, že neuronová sít nespočte nikdy číslo zcela přesně, takže 1 není nikdy zcela přesně 1,

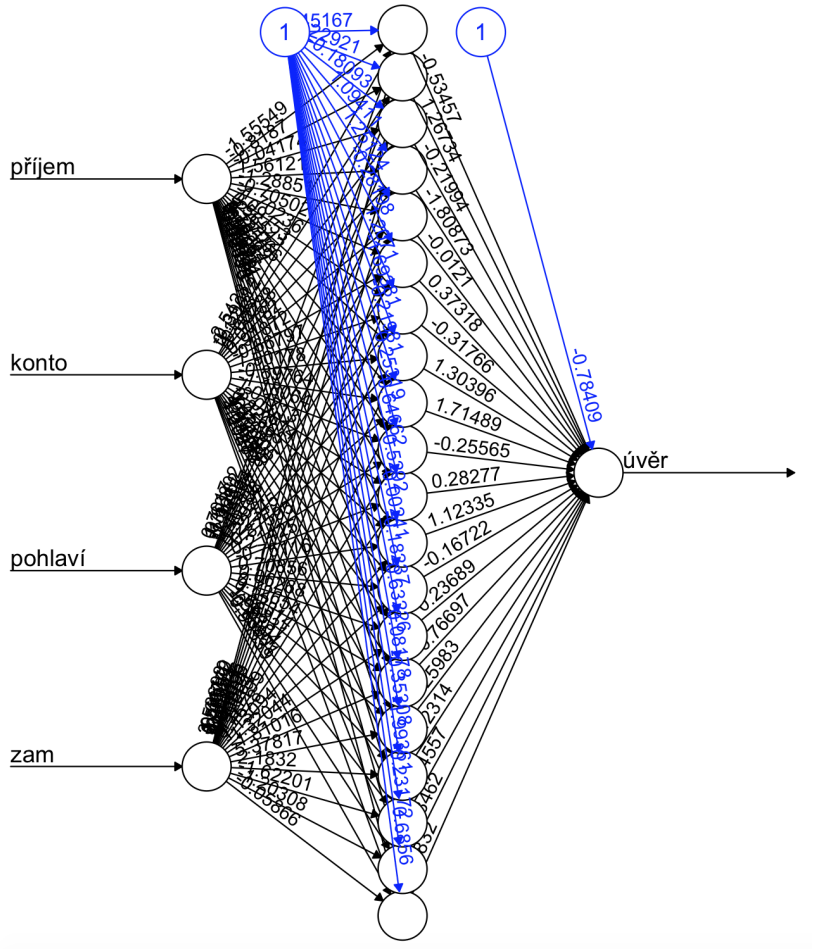

Obrázek 10.10: Klasifikace klientů banky neuronovou sítí

ale něco mezi 0,98 a 1,1 a podobně je to s nulou. Všimněte si, že přesto je výsledek poměrně přesný.

Realizace příkladů v R
Pokud jste dosud ještě nerealizovali příklady v R, teď je k tomu vhodná doba.

Úpravy skriptu modelu funkce $y = x^2$
Zajisté jste si všimli, že naše ověření kvality modelů není úplně korektní - pro ověření používáme trénovací množinu. Vzhledem k tomu, že známe funkci, kterou se modelem snažíme pokrýt můžeme jednoduše vygenerovat validační množinu novou, např. 0,5 → 0,25, 1,5 → 2,25, ... a provést ověření zcela konkrétní ... vzhůru do toho!

10.3 Případová studie

Neuronové sítě jsou schopny řešit jak regrese, tak klasifikační problémy. Pro demonstraci se vrátíme k AMES datasetu. Základní výpočet provedeme pomocí knihovny nnet. Tato knihovna má ale nevýhodu

- nepodporuje hloubkové učení a tak její schopnost adaptovat se na takový problém, jako je regresní model s 80-ti prediktory není dobrá, viz obr. 10.11. Výpis níže je minimalistickým řešením modelu - jeho přesnost tak lze přenastavením jednotlivých parametrů modelu ještě dále zlepšovat.

Výpis 10.3: AMES dataset - řešení pomocí nnet

```
1  library("AmesHousing") #obsahuje dataset AMES
2  library("nnet")
3  library("caret")
4  library("vip")
5
6  ames_train = make_ames()
7  ames_nn <- train(
8    Sale_Price ~ .,
9    data = ames_train,
10   method = "nnet",
11   trControl = trainControl(method = "cv", number = 10),
12   linout = TRUE
13 )
14 ames_nn
15 plot(ames_nn)
16 vip(ames_nn, num_features = 26, bar = FALSE)
```

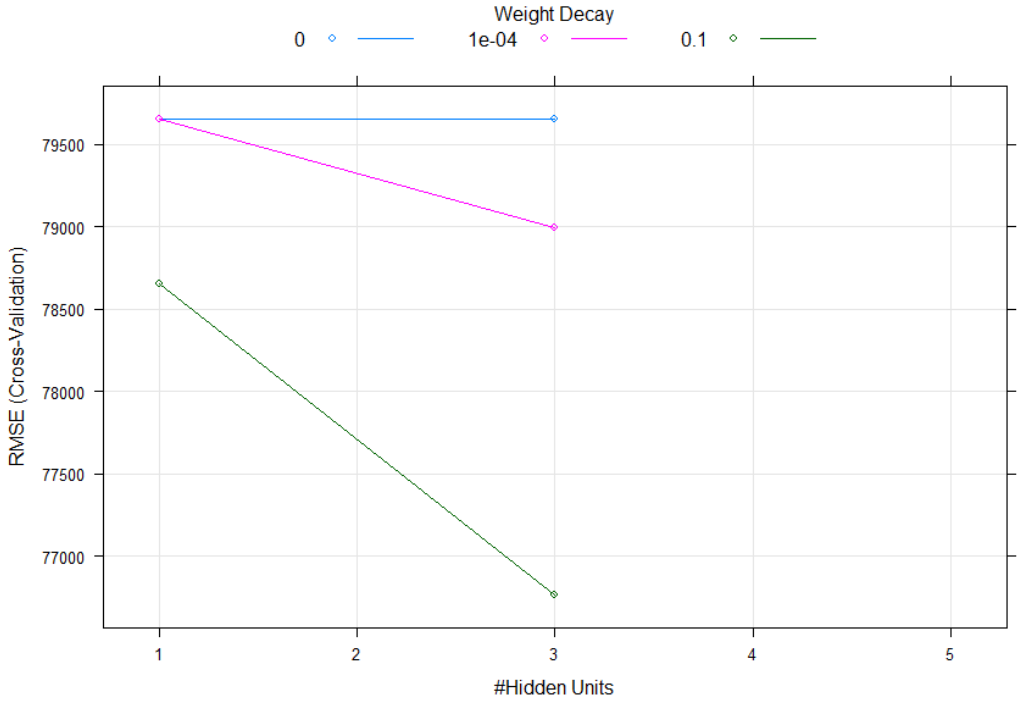

Obrázek 10.11: RMSE pro různé modely neuronové sítě datasetu AMES

Jak je vidno na obr. 10.11 optimalizuje hyperparametry caret do určité míry sám nastavením skrytých neuronů (hidden units) a weight decay - jedná se o parametr, jehož hodnota je menší než 1 a používá se tak, že se jím vynásobí hodnota vah odvozených modelem. Cílem je, aby v rámci iterace změny ve váhových koeficientech probíhaly pomalu ale jistě.

Hodnota RMSE pro nejlepší kombinaci parametrů je okolo 76 000, pokud to porovnáme s odvozeným rozhodovacím stromem, tak rozhodovací strom je ve skutečnosti mnohem přesnější (RMSE okolo 44 000).

Pokud se podíváme na preferované parametry, využívá se jich aktivně v modelu pouze relativně málo, viz obr. 10.12.

Věnujte prosím pozornost parametru linout funkce train. Nastavení na TRUE znamená, že neuronová síť má počítat s tím, že hodnoty předložené k tréningu nejsou normalizovány. Bez tohoto parametru by neproběhl výpočet - byly by vyžadovány transformace nad původními daty.

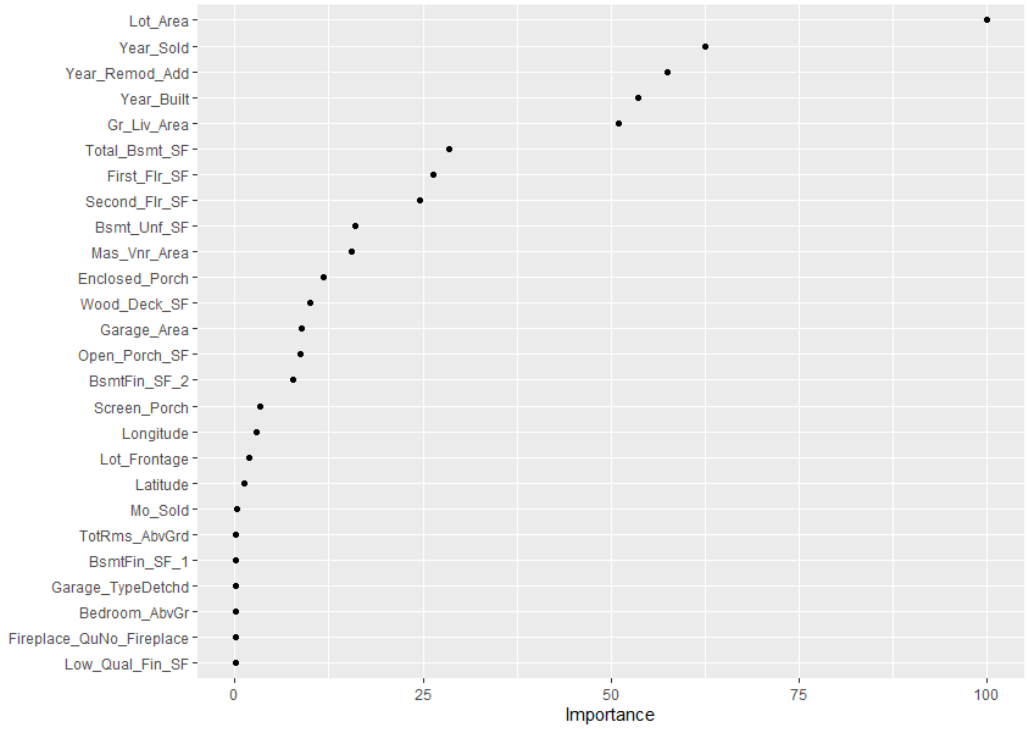

Obrázek 10.12: Relativní významnost jednotlivých parametrů modelu neuronové sítě datasetu AMES

Pro zlepšení parametrů modelu můžeme zkusit ladit hyperparamtry modelu, což jsou právě parametry hidden neurons a weight decay. Obr. 10.11 naznačuje, že model není příliš citlivý na parametr hidden neurons. Bez specifického nastavení rozsahu hyperparametrů byly testovány hodnoty 1, 3 a 5, přičemž ke zlepšení dochází pouze při přechodu z 1 na 3 skryté neurony, navýšení na 5 už žádný přínos nepřináší.

Zajímavější je situace s hyperparametrem weight decay, který se zvyšující se hodnotou poskytuje lepší předpovědi. Zkusme proto upravit funkci train přidáním instrukcí pro trénování hyperparametrů: tuneGrid=expand.grid(.size = c(3, 5, 10, 20),.decay=seq(0.1, 0.9, by=0.1)). .size odpovídá hyperparametru hidden units a je nastaven na hodnoty 3, 5, 10 a 20. Vzhledem ke zkušenostem z minulého pokusu, ale v tomto případě nelze očekávat zlepšení. .decay je nastaven jako sekvence od 0,1 do 0,9 zvětšovaná po 0,1. Zde lze očekávat zlepšení.

Výsledek ladění hyperparametrů je na vývoji RMSE znázorněn na obr. 10.13. Jak jsme očekávali jiná hodnota size než 3, nemá pro model smysl. Pro decay je ale situace jiná. Na hodnotě 0,4 jsme dosáhli významného snížení RMSE až téměř k 70 000, což odpovídá zlepšení téměř 8 %.

Z výše uvedeného vyplývá, že optimum pro hyperparametr .decay se pohybuje někde mezi 0,3 - 0,5. Otestovat to lze např. následující úpravou výpočtu: tuneGrid=expand.grid(.size = 3,.decay=seq(0.3, 0.5, by=0.05)). Pro zrychlení výpočtu je .size zafixováno na hodnotě 3. Nakolik přesné bude natrénování neuronové sítě závisí ale také do určité míry na náhodě. Opakovaným spouštěním budou dosahovány tedy různé výsledky. Nejlepší hodnota, které jsem byl schopen dosáhnout byla RMSE 68 000 při .decay 0,4.

Dalšího zpřesnění je možno dosáhnout zvýšením počtu iterací. To je možno udělat přidáním parametru maxit = 1000 do funkce train. Maxit parametr odpovídá maximálnímu počtu iterací, které výpočet může ve fázi učení udělat. Implicitní, přednastavený počet je nastaven na. Pro takový model je potřeba mít na paměti, že délku výpočtu prodlužujeme 10x. Na běžném čtyřjádrovém notebooku se tak síť bude adaptovat desítky minut.

Z tohoto důvodu ke kroku prodloužení výpočtu přistupujeme až v okamžiku, kdy máme jasnější představy o nastavení hyperparametrů modelu a můžeme tak jejich rozsahy patřičným způsobem omezit. Tímto způsobem jsme se ale adaptací dostali na RMSE = 58 500, což je výsledek skoro o 33 % lepší, byť to stále nedosahuje kvalit rozhodovacího stromu.

Kód níže může neobsahuje už odkazy na knihovny ani příkaz pro načtení AMES dat do proměnné.

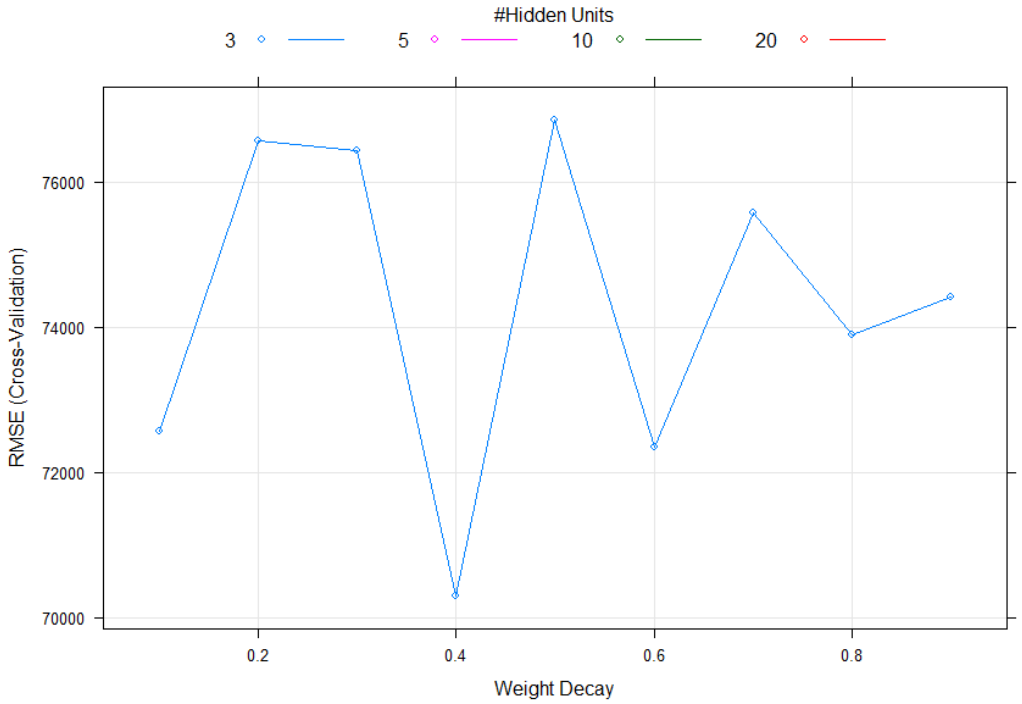

Obrázek 10.13: Ladění hyperparametrů .size (3, 5, 10, 20) a decay (0,1 - 0,9) pro AMES dataset

Výpis 10.4: AMES dataset - řešení pomocí nnet s optimalizací hyperparametrů a vyšším počtem iterací

```
ames_nn4 <- train(
  Sale_Price ~ .,
  data = ames_train,
  method = "nnet",
  trControl = trainControl(method = "cv", number = 10),
  tuneGrid=expand.grid(.size = 3,.decay=seq(0.3, 0.5, by=0.05)),
  maxit = 1000,
  linout = TRUE
)
ames_nn4
vip(ames_nn4, num_features = 26, bar = FALSE)
plot(ames_nn4)
```

To není úplně špatný výsledek - je ho ale ještě možné vylepšit? Z hlediska schopností jednoduchých vrstvených neuronových sítí se pomalu blížíme k hranici možností tohoto postupu. Další možnost zlepšení poskytují až metody tzv. hloubkového učení (deep learning). Příklady, které si v této kapitole ukazujeme odpovídají z pohledu algoritmů někdy přelomu tisíciletí. Hloubkové učení, které také využívá neuronové sítě se pak mohutně rozvijí v posledních dvou desetiletích.

Použití hloubkového učení tak může výsledek výrazně zpřesnit. Přesto i v současném postupu máme jisté rezervy. Dosud jsme totiž optimalizovali algoritmus, nemanipulovali jsme s daty samotnými. A když už jsme u toho, nezapomněli jsme na nějaký výpočetní výkon, který necháváme ladem? Podívejme se na kód níže a tentokrát se jedná o úplný výpis:

Výpis 10.5: AMES dataset - řešení pomocí nnet s optimalizací hyperparametrů; vyšším počtem iterací a preprocesingem prediktorů

```
library("AmesHousing") #obsahuje dataset AMES
library("nnet")
library("caret")
library("vip")
library("dplyr")
library("plotly")
library("doParallel")

```

```
registerDoParallel(cores = 4)

ames_train = make_ames()
ames_nzv = nearZeroVar(ames_train)
ames_train2 = ames_train[,-ames_nzv]
ames_nn5 <- train(
  Sale_Price ~ .,
  data = ames_train2,
  method = "nnet",
  preProcess = c('nzv', 'center', 'scale'),
  trControl = trainControl(method = "cv", number = 10),
  tuneGrid=expand.grid(.size = 3:9, .decay=seq(0.3, 0.5, by=0.05)),
  maxit = 100,
  linout = TRUE
)
ames_nn5
vip(ames_nn5, num_features = 26, bar = FALSE)
plot(ames_nn5)
```

Ve výpočtu nám přibila knihovna *doParallel*, která zpřístupňuje některé funkce pro paralelní zpracování modelů. Dosud jsme totiž výpočty realizovali v režimu jednovláknovém. Moderní procesory ale obsahují 2, 4, 8 nebo dokonce více jader a to i na cenově dostupných a „málo výkonných" noteboocích! Příkaz *registerDoParallel(cores = 4)* tak říká R, aby pro výpočet použil 4 jádra, což odpovídá počtu jader procesoru notebooku, na kterém jsou tvořena tato skripta.

Tímto způsobem nelze zlepšit výkon všech výpočtů, ale ty, které provádíme my v této (a předchozích) kapitolách jsou dobře paralelizovatelné a tak výkonnostní nárůst v násobcích výkonu.

Pro další zrychlení výpočtu můžeme vyloučit ze zpracovávaného datasetu sloupce, které mají nulový nebo skoro nulový rozptyl. Tyto sloupce logicky nemohou pomoci při vysvětlení analyzovaného problému. Funkce nearZeroVar(ames_train) slouží právě k tomuto účelu. Funkce vrací indexy sloupců, se skoro nulovým rozptylem. Tento údaj použijeme pro odfiltrování identifikovaných sloupců. Výsledný dataset pak obsahuje pouze 59 proměnných (z původních 81).

Tuto funkci používáme pak ještě jednou v rámci pre procesingu adaptace neuronové sítě, jedná se o parametr *nzv*. V rámci preprocesingu je možno odfiltrovat další sloupce, tentokráte na základě toho, jak vzorek datasetu je pro adaptaci vybrán. Zmenšení počtu prediktorů vede k menší neuronové síti, kterou je potřeba adaptovat a tím pádem také ke zrychlení celého výpočtu.

Zkvalitnění výpočtu samotného je možno provést ve fázi preprocesingu standardizací hodnot prediktorů - konkrétně centralizací a škálováním.

Všimněte si, že se změnila také část věnována prostoru hyperparametrů, kde size pracuje s hodnotami 3 - 9. Bez standardizace nebyla schopna síť profitovat z velikostí > 3. To se ale změnilo, jak je patrné z obr. 10.14.

Nejlepší výsledek odpovídá RMSE přibližně 50 000 při velikosti sítě 7. Z hlediska velikosti tak optimum vypadá na oblast 6 - 8. Hodnoty velikosti 10 a vyšší už nemají smysl. Tuto informaci můžeme použít pro přenastavení parametru size = 6:8. Zmenšením rozsahu zmenšíme požadovanou dobu adaptace neuronové sítě. Pro dosažení lepší přesnosti modelu lze zvýšit počet iterací maxit = 1000.

Při takových parametrech může výpočet trvat opravdu dlouho - v mém případě proběhl během 25 minut. Výsledné RMSE je ale přibližně 45 000 při velikosti sítě 8 a decay = 0,35. To je výsledek z hlediska přesnosti srovnatelný s rozhodovacím stromem. Je dokonce možné, že bychom byli schopni dosáhnout stejné nebo dokonce lepší přesnosti, pokud bychom nechali síť adaptovat déle - např. 10 000 iterací. Touto změnou by ale došlo také k desetinásobnému prodloužení délky výpočtu, což by v mém případě bylo více než 4 hodiny.

Pro zajímavost můžeme analyzovat také významnost jednotlivých prediktorů, viz obr. 10.15. Všimněte si, že to výpočtu v tomto případě vstupují všechny prediktory, které zbyly pro odstranění sloupců s nulovou variabilitou.

Možná Vás napadne otázka, proč jsme vůbec procházeli celou genezí pokusů s datasetem a to ať už z pohledu použití různých modelů tak z pohledu použití různých parametrů a hyperparametrů těchto modelů? Odpověď je jednoduchá - předem je pro složitější případy obtížné odhadnout, který z modelů, a které z nastavení bude poskytovat nejlepší výsledky. Jediným způsobem je s modely experimentovat.

To jsme prováděli např. v této kapitole, když jsme nejprve procházeli široké oblasti možných nastavení hyperparametrů size a decay, ale v „nízkém rozlišení" (počtem iterací), abychom získali

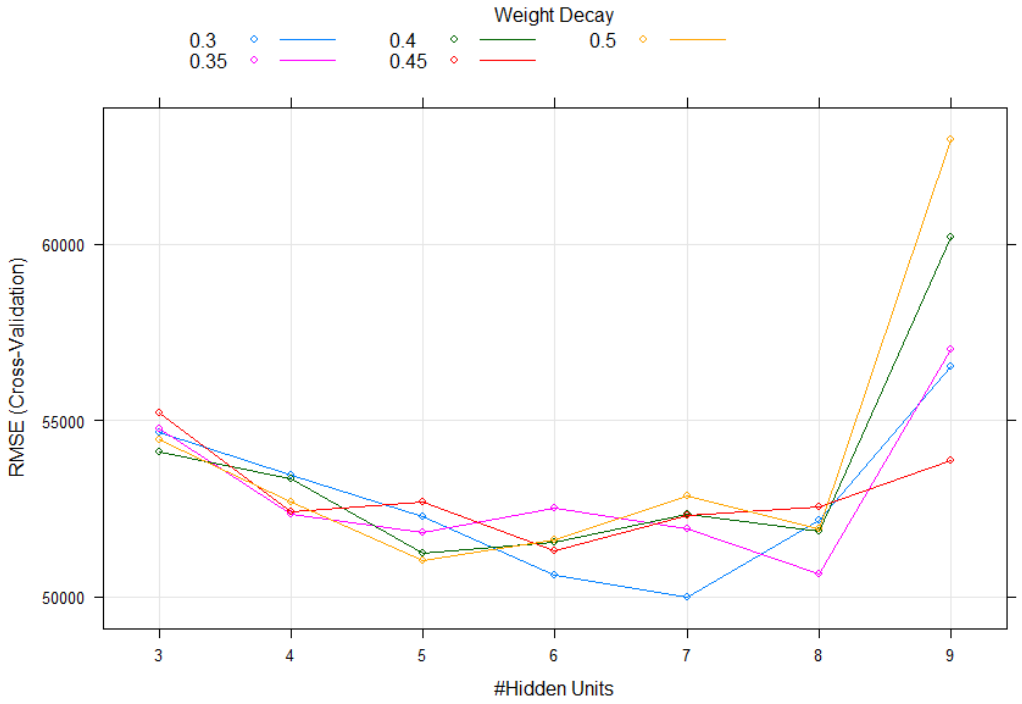

Obrázek 10.14: Ladění hyperparametrů .size 3-9 pro standardizované prediktory AMES dataset

představu, jaká nastavení fungují lépe pro zpracovávaný dataset. Následně jsme omezili prohledávaný prostor hyperparametrů a zvýšili rozlišovací schopnost modelu navýšením počtu iterací.

Obdobným procesem musíme projít pro jakýkoliv řešený problém a také jakýkoliv algoritmu používaný pro jeho řešení.

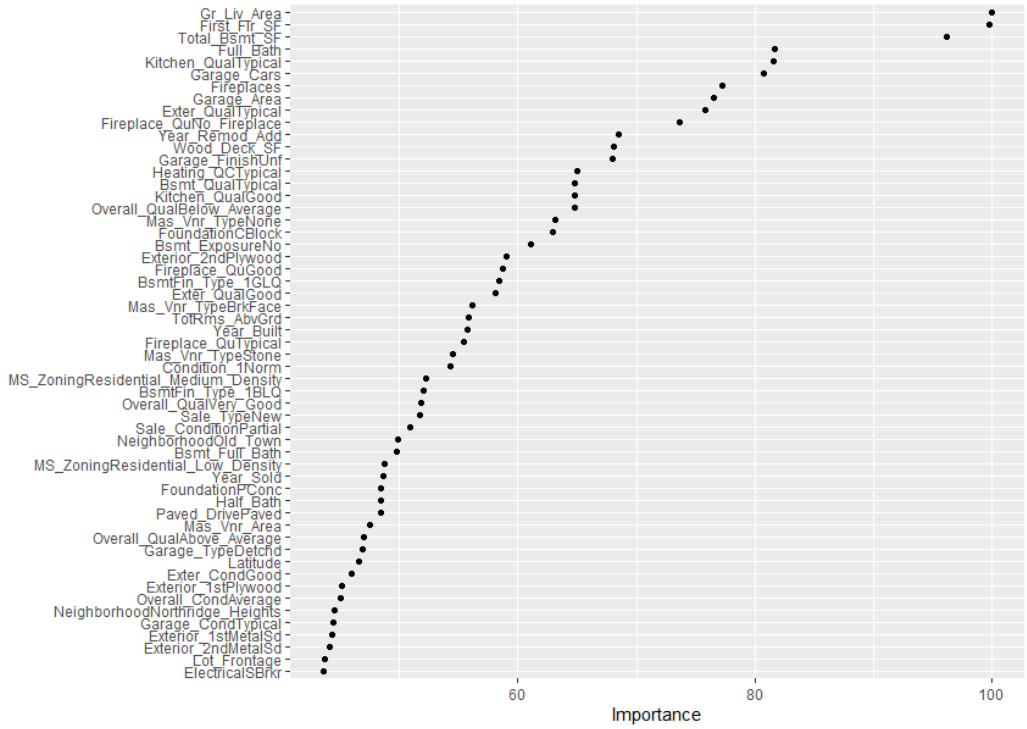

Obrázek 10.15: Srovnání významnosti prediktorů pro nnet síť s normalizovanými prediktory po 1000 iterací (AMES dataset)

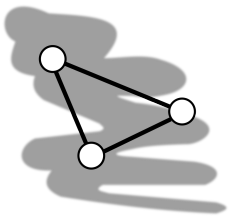

Caret - dostupnost modelů
Možná Vás zajímá, jaké modely vlastně knihovna caret podporuje. V současnosti knihovna podporuje 238 modelů, viz přehled: https://topepo.github.io/caret/available-models.html.

Neuronová síť - dataset iris
Použijte nabyté znalosti k vytvoření a adaptaci neuronové sítě pro klasifikaci kosatců. Porovnejte přesnost výpočtu pomocí parametru κ s ostatními modely, které jsme pro tento dataset používali. Výsledek by měl být lepší i pro relativně malý počet iterací (100).

V případě problémů můžete konzultovat vyřešený příklad v systému LMS.

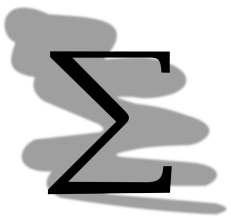

Shrnutí kapitoly
Neuronové sítě jsou v současnosti jednou z nejpopulárnějších a také nejuniverzálnějších metod pro provádění analýz všeho druhu. Neuronové sítě jsou tvořeny neurony a váženými vazbami mezi nimi. Tento typ modelů se tak snaží napodobovat funkci mozku vyšších organismů.
Univerzálnější vícevrstevné sítě obsahují, vstupní, výstupní a jednu nebo více pracovních vrstev. Síť pak funguje jako černá skříňka - hodnoty můžeme odečítat na vstupu a výstupu, ale dovnitř již „nevidíme“.
Pro správné fungování se musí síť tzv. adaptovat. Nejpoužívanější metodou adaptace je pak *backpropagation*, která využívá kvantifikace chyby sítě k odvození změny vah vazeb mezi neurony, které k této chybě vedly.
Neuronové sítě jsou primárně použitelné pro řešení problémů klasifikace, popř. predikce.

Kontrolní otázky

1. Vysvětlete funkci perceptronu.
2. kolik skrytých vrstev musí být ve vícevrstvé síti?
3. vysvětlete backpropagation

Správné odpovědi

1. Perceptron umožňuje prahované agregované vstupy x transformovat funkcí nelineárního zobrazení na výstup y.
2. minimálně jedna.
3. metoda učení s učitelem - založená na zpětné šíření chyb v síti. (váhy v síti se upravují směrem od výstupní vrstvy zpět ke vstupní).

Literatura

[1] ISO/IEC 27001:2013 Information technology - Security techniques - Information security management systems - Requirements.

[2] ISO/IEC 27002:2013 Information technology - Security techniques - Code of practice for information security management.

[3] Zákon 365/2000 Sb. O informačních systémech veřejné správy.

[4] zákon č. 181/2014 Sb., o kybernetické bezpečnosti a o změně souvisejících zákonů (zákon o kybernetické bezpečnosti).

[5] zákon č. 239/2000 Sb., o integrovaném záchranném systému a o změně některých zákonů.

[6] ČSN ISO/IEC 27005 Informační technologie - Bezpečnostní techniky - Řízení rizik bezpečnosti informací.

[7] Zákon č. 480/2004 Sb. - Zákon o některých službách informační společnosti a o změně některých zákonů (zákon o některých službách informační společnosti), 2004.

[8] Zákon č. 127/2005 Sb. - Zákon o elektronických komunikacích a o změně některých souvisejících zákonů (zákon o elektronických komunikacích), 2005.

[9] Zákon č. 412/2005 Sb. - Zákon o ochraně utajovaných informací a o bezpečnostní způsobilosti, 2005.

[10] Control panel with PLC, 2007.

[11] Mutual Recognition Agreement of Information Technology Security EvaluationCertificates V3.0, 2010.

[12] Nařízení vlády č. 432/2010 Sb. - Nařízení vlády o kritériích pro určení prvku kritické infrastruktury, 2010.

[13] Vyhláška č. 317/2014 Sb. o významných informačních systémech a jejich určujících kritériích, 2014.

[14] Směrnice Evropského parlamentu a Rady (EU) 2016/1148 ze dne 6. července 2016 o opatřeních k zajištění vysoké společné úrovně bezpečnosti sítí a informačních systémů v Unii, July 2016.

[15] Vyhláška č. 437/2017 Sb. - Vyhláška o kritériích pro určení provozovatele základní služby, 2017.

[16] OpenAI, 2018.

[17] R: The R Project for Statistical Computing, 2018.

[18] Vyhláška č. 82/2018 Sb. o bezpečnostních opatřeních, kybernetických bezpečnostních incidentech, reaktivních opatřeních, náležitostech podání v oblasti kybernetické bezpečnosti a likvidaci dat (vyhláška o kybernetické bezpečnosti), 2018.

[19] Nařízením Evropského parlamentu a rady 2019/881 o agentuře ENISA („Agentuře Evropské unie pro kybernetickou bezpečnost“), o certifikaci kybernetické bezpečnosti informačních a komunikačních technologií a o zrušení nařízení (EU) č. 526/2013 („akt o kybernetické bezpečnosti“), 2019.

[20] *Package 'rstan'*. 2020.

[21] Stan, 2020.

[22] Rakesh Agrawal, Tomasz Imieliński, and Arun Swami. Mining Association Rules Between Sets of Items in Large Databases. In *Proceedings of the 1993 ACM SIGMOD International Conference on Management of Data*, SIGMOD '93, pages 207–216, New York, NY, USA, 1993. ACM.

[23] Petr Berka. *Dobýváni znalostí z databází*. ACADEMIA, Praha, 2005.

[24] Bruce Blaus. Neuron schéma, 2013. Page Version ID: 860153584.

[25] Brad Boehmke and Brandon M. Greenwell. *Hands-On Machine Learning with R*. Chapman and Hall/CRC, Boca Raton, 2019.

[26] Mariusz Bojarski, Ben Firner, Beat Flepp, Larry Jacker, Urs Muller, Karol Zieba, and Davide Del Tesla. End-to-End Deep Learning for Self-Driving Cars, August 2016.

[27] Paul Boutin. Slammed! *Wired*, July 2003.

[28] Comodo. Comodo Firewall | Get Best Free Personal Firewall Software, 2018.

[29] CSIRT.CZ. Národní CSIRT České republiky, 2018.

[30] Dean De Cock. Ames, Iowa: Alternative to the Boston Housing Data as an End of Semester Regression Project. *Journal of Statistics Education*, 19(3):1–15, 2011.

[31] DECCI. Servis FVE.

[32] ENISA. ENISA - homepage, 2018.

[33] Evropská komise. Nařízení Evropského parlamentu a Rady (ES) č. 526/2013 o Agentuře Evropské unie pro bezpečnost sítí a informací (ENISA) a o zrušení nařízení (ES) č. 460/2004, 2013.

[34] Nicolas Falliere, Liam O. Murchu, and Eric Chien. *W32.Stuxnet Dossier*. Symantec Corporation, Cupertino, 2011.

[35] FIRST. Vision and Mission Statement, 2018.

[36] Evan Gilman and Doug Barth. *Zero Trust Networks: Building Secure Systems in Untrusted Networks*. O'Reilly Media, Sebastopol, CA, 2017.

[37] Frauke Guenther. *Package 'neuralnet'*. 2016.

[38] GÉANT Assoc. Trusted Introducer : Home, 2018.

[39] Michael Hahsler, Christian Buchta, Bettina Gruen, and Kurt Hornik. *Package 'arules'*. 2018.

[40] Suzana Herculano-Houzel. The Human Brain in Numbers: A Linearly Scaled-up Primate Brain. *Frontiers in Human Neuroscience*, 3, November 2009.

[41] IBM. *IBM SPSS Modeler CRISP-DM Guide*. IBM, Armonk, NY, USA, 2016.

[42] IBM. IBM SPSS Software | IBM Analytics, 2018.

[43] Brian William Jones. Visual Cortex Neuron – Webvision, 2013.

[44] Petr Kladivo. *Základy statistiky*. Univerzita Palackého v Olomouci, Olomouc, 2013.

[45] Paul Kocher, Jann Horn, Anders Fogh, and Daniel Genkin, Daniel Gruss, Werner Haas, Mike Hamburg, Moritz Lipp, Stefan Mangard, Thomas Prescher, Michael Schwarz, and Yuval Yarom. Spectre Attacks: Exploiting Speculative Execution. In *40th IEEE Symposium on Security and Privacy (S&P'19)*, pages 1–16, 2019.

[46] Koordinační rada ministra dopravy pro kosmické aktivity. ITS v silniční dopravě - Český Kosmický Portál - Odbor ITS, kosmických aktivit a VaVaI.

[47] Max Kuhn. *Package AmesHousing*. 2020.

[48] Mohit Kumar. TSMC Chip Maker Blames WannaCry Malware for Production Halt, 2018.

[49] Ted G. Lewis. *Critical Infrastructure Protection in Homeland Security*. Wiley, New Jersey, 2 edition, 2015.

[50] Moritz Lipp, Michael Schwarz, Daniel Gruss, Thomas Prescher, Werner Haas, Anders Fogh, Jann Horn, Stefan Mangard, Paul Kocher, Daniel Genkin, Yuval Yarom, and Mike Hamburg. Meltdown: Reading Kernel Memory from User Space. In *27th USENIX Security Symposium (USENIX Security 18)*, pages 1–16, 2018.

[51] Warren S. McCulloch and Walter Pitts. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133, December 1943.

[52] Merriam-Webster. Definition of WAR, 2018.

[53] David Meyer, Evgenia Dimitriadou, Kurt Hornik, Andreas Weingessel, and Friedrich Leisch. *Package 'e1071'*. 2018.

[54] Microsoft. Differences Between OLAP, ROLAP, MOLAP, and HOLAP - TechNet Articles - United States (English) - TechNet Wiki, 2018.

[55] Microsys. SCADA/HMI systém PROMOTIC.

[56] Stephen Milborrow. *Package 'rpart.plot'*. 2020.

[57] MV ČR. Počty ISVS | Informační systém o informačních systémech veřejné správy, 2018.

[58] NAO. *Investigation: WannaCry cyber attack and the NHS*. NAO, Londýn, 2018.

[59] NÚKIB. NÚKIB - homepage, 2018.

[60] NÚKIB. Poskytované služby, 2018.

[61] Národní úřad pro kybernetickou a informační bezpečnost. GovCERT.CZ, 2018.

[62] Dale Peterson. Offensive Cyber Weapons: Construction, Development, and Employment. *Journal of Strategic Studies*, 36(1):120–124, February 2013.

[63] R Project. Ubuntu Packages for R, 2018.

[64] Thomas Rid. *Cyber War Will Not Take Place*. C Hurst & Co Publishers Ltd, London, 2013.

[65] Brian Ripley. *Package Tree*. 2018.

[66] RISI. Slammer Impact on Ohio Nuclear Plant, 2003.

[67] RISI. Browns Ferry Nuclear Plant Scrammed (Shut Down), 2006.

[68] Paul F. Roberts. Zotob, PnP Worms Slam 13 DaimlerChrysler Plants, 2005.

[69] SAS. *Data Mining Using SAS® Enterprise Miner™: A Case Study Approach*. SAS Institute Inc., Cary, NC, USA, 3 edition, 2013.

[70] SAS. Analytics, Business Intelligence and Data Management, 2018.

[71] Secunia. Secunia Research Community - Advisories, 2018.

[72] Tony Smith. Hacker jailed for revenge sewage attacks, 2001.

[73] Darlene Storm. Gauss malware: Nation-state cyber-espionage banking Trojan related to Flame, Stuxnet, August 2012.

[74] Symantec. W32.SQLExp.Worm, 2003.

[75] Symantec. *W32.Duqu: The precursor to the next Stuxnet*. Symantec Corporation, Cupertino, 2011.

[76] Symantec. W32.Flamer, 2012.

[77] Symantec. Ransom.Wannacry, 2017.

[78] Terry Therneau, Beth Atkinson, and Brian Ripley. *Package 'rpart'*. 2019.

[79] Twitter. Twitter API Docs, 2018.

[80] VARS. Národní dopravní a informační centrum, 2018.

[81] Tobias von Petersdorff. Example for Principal Component Analysis (PCA): Iris data, 2019.

[82] W3Schools. SQL Tutorial.

[83] Kim Zetter. *Countdown to Zero Day: Stuxnet and the Launch of the World's First Digital Weapon*. Broadway Books, New York, 2015.

[84] Pavel Šenovský. *Bezpečnostní informatika 1*. VŠB-TU Ostrava, Fakulta bezpečnostního inženýrství, Ostrava, 8 edition, 2017.

[85] Pavel Šenovský. *Bezpečnostní informatika 1 - Návody do cvičení*. VŠB-TU Ostrava, Fakulta bezpečnostního inženýrství, Ostrava, 2017.

Slovník

AJAX Asynchronous JavaScript and XML.

ANOVA Analsis of Variance.

ASIC Application Specific Integrated Circuit.

ASUM-DM Analytics Solutions Unified Method for Data Mining/Predictive Analytics.

CC Common Criteria.

CERT Computer Emergency Response Team.

CRISP-DM Cross-industry standard process for data mining.

CRM Customer Relationship Management.

CSIRT Computer Security Incident Response Team.

CSS Cascading Style Sheets.

CSV Comma Separated Values.

CV Cross Validation.

DMZ demilitarizovaná zóna.

DoS Denial of Services.

DTP Desktop Publishing.

EDGE Enhanced Data Rates for GSM Evolution.

ENISA European Union Agency for Network and Information Security.

ERD Entity Relationship Diagram.

ERP Enterprise Resource Planning.

EUCC European Cybersecurity Certification Scheme.

FIRST Forum of Incident Response and Security Teams.

GPRS General Packet Radio Service.

GUI Graphical User Interface.

HIPS Host Intruder Prevention System.

HMI Human Machine Interface.

HOLAP Hybrid Online Analytical Processing.

HTML Hypertext Markup Language.

ICS Industrial Control System.

IDS Intruder Detection System.

IO Input-Output.

IoT Internet of Things.

IPS Intruder Prevention System.

ISMS Information Security Management System.

ISVS Informační Systém Veřejné Správy.

IT informační technologie.

ITSEC InformationTechnology Security Evaluation Criteria.

JDBC Java Database Connect.

KDD Knowledge Discovery in Databases.

KII Kritická informační infrastruktura.

MIS Management Information System.

MOLAP Multidimensional Online Analytical Processing.

NAO National Audit Office.

NBÚ Národní bezpečnostní úřad.

NCKB Národní centrum kybernetické bezpečnosti.

NDIC Národní dopravní a informační centrum.

NHS National Health System.

NÚKIB Národní úřad pro kybernetickou a informační bezpečnost.

ODBC Open Database Connect.

OLAP Online Analytical Processing.

PDF Portable Document Format.

PLC Programmable Logic Controller.

RMSE Root-mean-square error.

ROLAP Relational Online Analytical Processing.

RTU Remote Terminal Unit.

SCADA Supervisory Control and Data Acquisition.

SCM Supply Chain Management.

SLA Service Level Assurance.

SQL Structured Query Language.

TDIDT Top Down Induction of Decision Trees.

TI Trusted Introducer.

TSMC Taiwan Semiconductor Manufacturing Company.

VIS Veřejný informační systém.

ČR Česká republika.

[title=Seznam zkratek]

Rejstřík

air gap, 69
aplikace bezpečnostních záplat, 65
asociační pravidla, 136
automatizace, 17

Bayesův theorém, 143
bezpečnost přípojných bodů, 64
bezpečnostní opatření, 83
    organizační, 83
    technická, 83

C & C, 81
CERT, 77
certifikační rámec kyberbezpečnosti EU, 80
Cohenova κ, 148
CSIRT, 78
CSIRT.CZ, 78

data historian, 29, 71
data mining, 87
    deskripce, 90
    hledání nugetů, 90
    klasifikace, 90
    predikce, 90
databáze
    realtimová, 29
    relační, 29
    transakce, 31
dataset
    iris, 147
datová krychle
    hyperkrychle, 97
    multikrychle, 97
datové typy
    BLOB, 34
    DATETIME, 34
    DOUBLE, 34
    INT, 34
    TEXT, 34
    VARCHAR, 34
datový sklad, 96
dispečerské pracoviště, 20
DMZ, 74
dohledové pracoviště, 20
dolování dat, 87
DoS, 72, 78
dual home computer, 70
dual home server, 71

ENISA, 79
ERD, 95
EUCC, 80

FIRST, 79

ginni index, 125

HIPS, 72
HMI, 24
honeypot, 81

informační entropie, 122
Informační systém veřejné správy, 85
insider, 64
IS
    EIS, 95
    ERP, 96
    MIS, 96
ISMS, 84
ISVS, 85

klastr, 30
kritéria
    dopadová, 84
    oblastní, 84
kybernetická bezpečnostní událost, 83
kybernetická válka, 67
kybernetický bezpečnostní incident, 83

load balancer, 30

management rizik, 65
metodologie
    5A, 92
    CRISP-DM, 93
    SEMMA, 92
model
    hyperparametry, 134
    parametry, 134

naivní bayesovský klasifikátor, 145
NDIC, 21
nervový vzruch, 152
neuronová síť, 151
NoSQL, 97
NUKIB, 80
národní CERT, 78
Národní úřad pro kybernetickou a informační bezpečnost, 80

OLAP, 96
    MOLAP, 97
    ROLAP, 97

perceptron, 152
perimetr organizace, 69
PLC, 18
Promotic
    instalace, 41
    PmData, 47
    PmFolder, 47
    PmNumber, 47
    PmRoot, 45
    PmString, 47
    PmTimer, 49
    PmWorkspace, 46
proměnná
    nominální, 105
    ordinální, 105
Průmysl 4.0, 20
přeučení, 158

R
    Data.Frame, 104
    export dat, 106
    faktor, 105
    import dat, 106
    instalace balíků, 126
    operátory, 103
    vektory, 103
    vykreslování grafů, 107
    základní funkce, 103
    základní statistické funkce, 107
real-timová databáze, 20
regulační soustava, 17
relační databáze, 30, 95
replikace dat, 31
router, 73
rozděl a panuj, 122
rozhodovací pravidla, 119, 133
rozhodovací seznam, 124
rozhodovací strom, 158
rozhodovací stromy, 119
RTU, 22

sandbox, 72
SCADA, 20
senzor, 17
sigmoida, 153
skoro reálný čas, 30
služby elektronických komunikací, 82
SQL, 33
    ALTER, 34
    CREATE, 34
    DELETE, 36
    INSERT, 35
    SELECT, 35
    UPDATE, 36
stav kybernetického nebezpečí, 84
Stuxnet, 66
switch, 73

tansakce
    ACID, 37
TCP/IP, 69
TDIDT, 122
TI, 79
transakce, 37
Trusted Introducer, 79
trénovací množina, 120

učení s učitelem, 157

validační množina, 120
Visual Basic
    deklarace proměnných, 55
    dim, 55
    if, 55
    komentář, 55
    objektová notace, 56
    Pm, 55
    podmínka, 55
    rnd, 55
    set, 55
vrcholový CERT, 78
vrcholový CSIRT, 78
Vyhláška o kybernetické bezpečnosti, 84
vzorkování, 120
významná síť, 82
významné informační systémy, 82
významný informační systém, 84

zero trust
    architecture, 74
    network, 74
základní služba, 83

řešení
    optimální, 135
    suboptimální, 135