

Univerzita Pardubice
Fakulta ekonomicko-správní

Modelovanie bonity obcí pomocou
fuzzy množín

Bc. Peter Kerekréty

Diplomová práca
2009

Univerzita Pardubice
Fakulta ekonomicko-správní
Ústav systémového inženýrství a informatiky
Akademický rok: 2008/2009

ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Peter KEREKRÉTY**

Studijní program: **N6209 Systémové inženýrství a informatika**

Studijní obor: **Informatika ve veřejné správě**

Název tématu: **Modelovanie bonity obcí pomocou fuzzy množín**

Z á s a d y p r o v y p r a c o v á n í :

Charakterizujte možnosti ohodnocovania obcí (stanovenie ich bonity).
Analyzujte vstupné dáta (parametre) pre nasledujúcu klasifikáciu.
Navrhните вектор параметров, ktoré характеризujú дану область.
Navrhните model na klasifikáciu параметров pomocou I fuzzy množín.
Uskutočnite analýzu výsledkov.

Rozsah grafických prací:

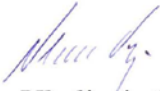
Rozsah pracovní zprávy:

Forma zpracování diplomové práce: **tištěná/elektronická**

Seznam odborné literatury:

1. FIALOVÁ, H. a kol.: Vybrané oblasti udržitelného rozvoje v Pardubickém kraji. Český statistický úřad, Oddelení regionálních analýz a informačních služeb Pardubice, Pardubice, 2007.
2. OLEJ, V.-HÁJEK, P. Air Quality Modelling by Kohonen's Self-organizing Feature Maps and Intuitionistic Fuzzy Sets. The Twelfth IASTED International Conference on Artificial Intelligence and Soft Computing, ASC 2008, September 1-3, 2008, Palma de Mallorca, Spain.
3. ATANASSOV, K.: Intuitionistic fuzzy sets, Fuzzy Sets and Systems, 20, 1986, 87-96.
4. OLEJ, V.: Modelovanie ekonomických procesov na báze výpočtovej inteligencie. [Vedecká monografia], Miloš Vognar - M&V, ISBN 80-903024-9-1, Hradec Králové, Česká republika, 2003, 160s.
5. KVASNIČKA, V. a kol.: Úvod do teórie neurónových sietí. Iris, Bratislava, 1997.

Vedoucí diplomové práce:


prof. Ing. Vladimír Olej, CSc.
Ústav systémového inženýrství a informatiky

Datum zadání diplomové práce:

6. října 2008

Termín odevzdání diplomové práce:

1. května 2009


doc. Ing. Renáta Myšková, Ph.D.

děkanka

L.S.


doc. Ing. Jiří Křupka, Ph.D.

vedoucí ústavu

V Pardubicích dne 6. října 2008

Prehlasujem:

Túto prácu som vypracoval samostatne. Všetky literárne pramene a informácie, ktoré som v práci využil, sú uvedené v zozname použitej literatúry.

Bol som oboznámený s tým, že sa na moju prácu vzťahujú práva i povinnosti vyplývajúce zo zákona č. 121/2000 Zb., autorský zákon, predovšetkým zo skutočností, že Univerzita Pardubice má právo na uzatvorenie licenčnej zmluvy o využití tejto práce ako školského diela podľa § 60 odst. 1 autorského zákona a s tým, že pokiaľ dôjde k využitiu tejto práce mnou, prípadne bude poskytnutá licencia o využití inému subjektu, je Univerzita Pardubice oprávnená odo mňa požadovať primeraný príspevok na úhradu nákladov, ktoré na vytvorenie diela vynaložila, a to podľa okolností až do ich skutočnej výšky.

Súhlasím s prezenčným sprístupnením svojej práce v Univerzitnej knižnici.

V Pardubiciach dňa 25. 06. 2009

Bc. Peter Kerekréty

Pod'akovanie

Chcel by som sa poďakovať môjmu vedúcemu diplomovej práce, pánovi prof. Ing. Vladimírovi Olejovi, CSc. za jeho podporu počas vypracovania diplomovej práce a to ako pri obsahovej, tak i formálnej stránke. Ďalej moja vďaka patrí pánovi Ing. Petrovi Hájkovi, PhD. za jeho cenné pripomienky a pomoc, ktorú mi poskytol pri praktickej časti diplomovej práce.

V neposlednom rade chcem vyjadriť veľkú vďaku mojim rodičom, ktorí mi umožnili absolvovať štúdium vysokej školy, boli a sú oporou pre mňa v celom mojom živote.

Súhrn

Diplomová práca je zameraná na problematiku modelovania bonity obcí pomocou Intuitionistic fuzzy množín.

V diplomovej práci je uvedená charakteristika základných pojmov, týkajúcich sa danej problematiky. Ďalej sú stanovené parametre potrebné na klasifikáciu a návrh vektora parametrov, ktoré charakterizujú danú oblasť. V ďalšej časti práce sú charakterizované základné pojmy z oblasti umelej inteligencie - Intuitionistic fuzzy množiny, všeobecný klasifikačný problém. Ďalšia časť diplomovej práce je zameraná na predspracovanie vstupných údajov, návrh modelu na klasifikáciu parametrov pomocou Intuitionistic fuzzy množín, stanovenie Intuitionistic fuzzy relácií $R(P \rightarrow \Omega)$, $Q(O \rightarrow P)$, kompozíciu Intuitionistic fuzzy relácií R a Q , ktorá je daná vzťahom $T = R \circ Q$. Na záver je uskutočnená analýza výsledkov, ktorá obsahuje finálne hodnotenia získané aplikovaním metód, použitých pri návrhu daných relácií R a Q .

Kľúčové slová

bonita obcí, ekonomické, finančné, dlhové parametre, Intuitionistic fuzzy množiny, Intuitionistic fuzzy relácie, klasifikácia

Title

Municipal Creditworthiness Modelling by Fuzzy Sets

Abstract

The graduation thesis is focused on Municipal Creditworthiness Modelling by Fuzzy Sets.

The thesis is referring to characteristics of basic terms that relate to the problem. Also the parameters necessary for classification are set and design vector of parameters that characterize the area. In the next section of work basic terms of artificial intelligence are characterized - Intuitionistic fuzzy sets and general classification problem. Another part of the thesis is focused on preprocessing of input data, proposal of model for the classification of parameters using Intuitionistic fuzzy sets and on setting Intuitionistic fuzzy sessions $R(P \rightarrow \Omega)$, $Q(O \rightarrow P)$, composition of Intuitionistic fuzzy relations

R and Q by term $T = R \circ Q$. Finally there is analysis of results, which includes the final evaluation obtained by applying the methods used in the proposal of the sessions R, Q .

Keywords

Quality of municipalities, economic, financial and debt parameters, Intuitionistic fuzzy sets, Intuitionistic fuzzy relations, classification

Obsah

ÚVOD.....	10
1. CHARAKTERISTIKA MOŽNOSTÍ OHODNOTENIA BONITY OBCÍ... 11	
1.1 ÚVER, ÚVEROVÉ RIZIKO, BONITA OBCE	11
1.2 METÓDY OHODNOTENIA OBCÍ	12
1.2.1 Finančná metóda hodnotenia bonity obcí v ČR	12
1.2.2 Bilančne majetková metóda	13
1.2.3 Modely ratingu	14
1.2.4 Modely zlyhania	15
1.3 ZHRNUTIE KAPITOLY	15
2. ANALÝZA A NÁVRH VSTUPNÝCH PARAMETROV PRE KLASIFIKÁCIU	16
2.1 NÁVRH EKONOMICKÝCH PARAMETROV.....	16
2.2 NÁVRH DLHOVÝCH PARAMETROV	17
2.3 NÁVRH FINANČNÝCH PARAMETROV	18
2.4 VEKTOR PARAMETROV PRE OHODNOTENIE OBCÍ	20
2.5 ZHRNUTIE KAPITOLY	20
3. ZÁKLADNÉ POJMY Z OBLASTI FUZZY LOGIKY, FUZZY MNOŽÍN, IFM A IFR	21
3.1 FUZZY MNOŽINY	21
3.2 OPERÁCIE NAD FUZZY MNOŽINAMI.....	22
3.3 FUZZY RELÁCIE	24
3.4 INTUITIONISTIC FUZZY MNOŽINY	25
3.4.1 Definície IFM.....	26
3.4.2 Definícia konceptu IFM	26
3.5 VŠEOBECNÝ KLASIFIKAČNÝ PROBLÉM	28
3.6 ROZKLAD MNOŽINY OBJEKTOV NA TRÉNOVACIU A TESTOVACIU MNOŽINU ...	30
3.7 ZHRNUTIE KAPITOLY	32
4. MODEL NA KLASIFIKÁCIU PARAMETROV POMOCOU IFR.....	33
4.1 NÁVRH MODELU NA KLASIFIKÁCIU BONITY OBCÍ POMOCOU IFR.....	33
4.2 CHARAKTERISTIKA VSTUPNÝCH DÁT.....	34

4.3	PREDSPRACOVANIE DÁT	35
4.3.1	Štandardizácia	35
4.3.2	Normalizácia	36
4.3.3	Korelácia	37
4.4	NÁVRH RELÁCIE R	37
4.4.1	Návrh relácie R pomocou experta	37
4.4.2	Návrh relácie R	38
4.5	NÁVRH RELÁCIE Q	43
4.5.1	Relácia Q simulovaných funkcií príslušnosti parametrov	43
4.5.2	Relácia Q	45
4.5.3	Stanovenie relácie Q pomocou štatistiky	46
4.6	KOMPOZÍCIA RELACÍ R A Q	48
4.6.1	Aplikácia teórie IFM	48
4.6.2	Algoritmus kompozície relácií R a Q pre modelovanie obcí	49
4.7	VÝSLEDNÁ ASOCIÁCIA	52
4.8	ZHRNUTIE KAPITOLY	53
5.	ZÁVEREČNÁ ANALÝZA	54
5.1	ASOCIÁCIA SIMULOVANÝCH OBCÍ	54
5.2	ASOCIÁCIA OBCÍ	56
5.3	ZHRNUTIE KAPITOLY	57
	ZÁVER	58
	ZOZNAM OBRÁZKOV	59
	ZOZNAM TABULIEK	60
	ZOZNAM GRAFOV	61
	ZOZNAM SKRATIEK	62
	ZOZNAM LITERATÚRY	63

Úvod

Pod pojmom bonita sa rozumie [1] schopnosť subjektu riadne plniť svoje záväzky. Ďalej je v tomto pojme zahrnutá solventnosť, ako aj úroveň podnikateľských aktivít daného subjektu. Schopnosť zákazníka splácať svoje úvery je hodnotená práve na základe bonity, ktorá má najväčší význam hlavne pre obchodných partnerov a banky. Vysoké úverové riziko je reprezentované nízkou bonitou, naopak nízke úverové riziko vysokou. Ak je obec schopná vykazovať vysokú bonitu, umožní jej to znížiť náklady, ktoré sú spojené s úverovým financovaním. V prípade, že obec preukáže nízku bonitu, úverové riziko sa zvyšuje a poskytovatelia úveru budú žiadať vyšší poplatok za úver. Na základe bonity obce trhové subjekty získavajú informácie, ktoré sa týkajú úverového rizika obce. Cieľom obcí nie je maximalizácia zisku, ale uspokojenie potrieb a požiadaviek obyvateľov obce. Týmto sa líši od cieľa, ktorý si kladie podnikateľský sektor – predovšetkým maximalizovať zisk. Z tohto vyplýva, že stanovenie ohodnotenia obcí je potrebné posudzovať odlišnými kritériami, ako je tomu v prípade súkromných podnikov.

Cieľom práce je navrhnúť klasifikátor pomocou Intuitionistic fuzzy množín (ďalej len IFM), tak aby boli jednotlivé obce čo najpresnejšie klasifikované do troch tried. Pre klasifikáciu obcí v Pardubickom kraji sú vstupom do modelu tri triedy parametrov a to ekonomické, finančné a dlhové, ktoré sa vzťahujú k počtu obcí v Pardubickom kraji, t.j. 452.

Diplomová práca je rozdelená do piatich kapitol. Prvá kapitola charakterizuje základné pojmy z oblasti bonity obcí a možnosti ohodnocovania bonity obcí. V druhej je podrobne popísaný návrh parametrov, ktoré slúžia ako vstupy do modelu. Ďalej kapitola obsahuje členenie parametrov, na základe ktorých je skúmaná bonita obcí a to parametre ekonomické, finančné a dlhové. Tieto slúžia na klasifikáciu objektov do tried a následne je navrhnutý vektor parametrov. V tretej kapitole sú charakterizované základné pojmy z oblasti fuzzy množín, fuzzy relácií, IFM a Intuitionistic fuzzy relácií (ďalej len IFR). Následne je spracovaný teoretický pohľad na všeobecný klasifikačný problém, rozklad množiny na trénovaciu a testovaciu množinu. Vo štvrtej kapitole je spracovaný návrh klasifikátora, zostavenie klasifikátora pre klasifikáciu obcí Pardubického kraja na základe jednotlivých parametrov, ktoré určujú kvalitu bonity obcí. V piatej kapitole je uskutočnená analýza výsledného modelu, ukážka najlepšieho klasifikátora, ktorý zaraďuje obce do jednotlivých tried pomocou IFR R a Q .

1. Charakteristika možností ohodnotenia bonity obcí

Hlavným zmyslom ohodnocovania bonity obcí je stanoviť úverové riziko obcí a podľa neho následne realizovať úverové financovanie obcí, ktoré je dôležité pre ekonomický vývoj. Preto sú v nasledujúcej časti diplomovej práce charakterizované pojmy ako je úver, úverové riziko a bonita obce.

1.1 Úver, úverové riziko, bonita obce

Dôležitým znakom reforiem, ktoré boli uskutočnené v 90. rokoch vo verejnej správe v ČR bol princíp decentralizácie. Vďaka tomuto princípu sa stali obce verejnoprávnymi subjektami, ktoré mali možnosť rozhodovať o finančných záležitostiach. Obce majú právo na používanie úverových nástrojov medzi ktoré patria predovšetkým bankové úvery a dlhopisy [2]. Úver je návratná forma financovania podnikových potrieb a zároveň návratná forma investovania. Ide o ekonomický a právny vzťah medzi veriteľom - poskytovateľom finančných prostriedkov a dlžníkom - príjemcom finančných prostriedkov. Úverové financovanie obcí prebieha na základe trhových pravidiel. Veriteľ poskytne obci úver za daných podmienok ako je výška úveru, úrok a iné. Tieto podmienky sú ovplyvnené rizikom, ktoré nesie veriteľ za poskytnutie úveru. Toto riziko sa nazýva úverové. Úverové riziko teda charakterizuje možnosť, že dlžník nebude schopný načas alebo vôbec plniť povinnosti vyplývajúce z úverového vzťahu k veriteľovi.

Presná definícia pojmu bonita obce nie je doposiaľ jednotne stanovená. Častokrát sa tento pojem používa ako alternatíva k pojmu rating obcí. Doslovný preklad tohto slova bonita je dobrá kvalita, hodnota, stupeň akosti či dobrá povest'. O bonite obcí možno hovoriť ako o určitom výroku o obci, no taktiež môže byť chápaná aj z pohľadu rolí, ktoré obec plní voči zainteresovaným subjektom. Môžu nimi byť napríklad investori, podnikatelia, návštevníci, ale aj samotní obyvatelia obce. Ďalšia možnosť ako chápať bonitu obce je [10] schopnosť subjektu plniť svoje záväzky voči všetkým zúčastneným, čo zahŕňa jednak úroveň podnikateľských aktivít daného subjektu, či solventnosť. Na základe bonity sú schopní obchodní partneri a banky ohodnotiť solventnosť ich klientov, teda schopnosť v stanovenom čase splatiť svoje záväzky. Vysoká bonita obcí značí malé úverové riziko, nízka potom vysoké úverové riziko. Pre obec to znamená, že vďaka vysokej bonite je schopná znížiť svoje náklady, ktoré sú spojené s financovaním z úverov. Bonita obce umožňuje trhovým subjektom získať

informácie, ktoré sú spojené s úverovým rizikom obce. Charakter verejného sektora sa líši od charakteru súkromného. Cieľom obce [10] je predovšetkým uspokojiť potreby obyvateľov pri rešpektovaní požiadaviek hospodárnosti, efektívnosti a účelnosti a nie maximalizácia zisku, ako je to v prípade súkromného sektora.

1.2 Metódy ohodnotenia obcí

Metódy (modely) ohodnocovania bonity obcí sú založené na porovnávaní vybraných obcí, napríklad porovnanie s najlepšou obcou. Pre dosiahnutie vierohodnosti porovnania obcí sú jednotlivé objekty vyberané tak, aby boli zachované podmienky zrovnateľnosti. Pre ohodnocovanie bonity obcí existujú rôzne metódy (modely), pomocou ktorých možno úspešne stanoviť bonitu obcí. V nasledujúcej časti sú podrobne rozpísané tieto:

- Finančná metóda hodnotenia bonity obcí,
- Bilančne majetková metóda,
- Rating,
- Modely zlyhania.

1.2.1 Finančná metóda hodnotenia bonity obcí v ČR

Základ finančnej metódy pre ohodnotenie bonity obcí spočíva v ohodnotení najvýznamnejších parametrov hospodárenia obcí. Prvoradým cieľom a zmyslom tejto bonity obcí je určenie dlhodobej stability, efektívnosti a kvality hospodárenia obce, veľkosti rozpočtu obce a pod. Pomocou finančnej metódy je taktiež možné zhodnotiť schopnosti obce zaistiť splatenie dlhu. Metóda využíva predovšetkým princíp porovnávania obcí (benchmarku¹) s ostatnými obcami a vďaka poznatkom získaných porovnávaním obcí, by mala viesť k skvalitneniu hospodárenia jednotlivých obcí. Avšak toto porovnanie môže byť v podmienkach ČR obtiažnejšie a to predovšetkým z dôvodu rozdielnosti funkcií, resp. tým, čo obce vykonávajú. Aby tieto obce neskreslovali hodnotenie bonity, je potrebné reagovať na tieto odlišnosti. Určovanie bonity pomocou finančnej metódy vychádza predovšetkým z druhej a funkčnej štruktúry rozpočtovej skladby. Z obsahového hľadiska sú parametre tejto metódy rozdelené do nasledujúcich okruhov ako sú príjmy, výdaje a kvalita rozpočtového

¹ Benchmarking je proces rozhodovania o tom, kto je najlepší, kto určuje štandard, a čo je štandard [15].

procesu ako aj ostatné charakteristiky hospodárenia obcí. Hodnotenie agregátnej bonity pramení z bonity týchto okruhov a ich kumuláciou do súhrnného ukazovateľa bonity. Pri hodnotení agregátnej bonity je dôležité ocenenie jednotlivých prvkov bonity a sumarizácia týchto prvkov bonity do celkového ukazovateľa. Prvky bonity sú oceňované z hľadiska štandardu, či iného prístupu [10].

Agregácia parametrov je uskutočnená priradením váh. V prípade vyhodnotenia jednotlivých ukazovateľov bonity, sú získané hodnoty agregátnej bonity. Čím viac je bonita obce odklonená od priemernej hodnoty, tým je kvalita hospodárenia obce väčšia, resp. menšia. Agregácia parametrov môže byť realizovaná napríklad pomocou metódy váženého súčtu poradí. Výsledkom ohodnotenia jednotlivých parametrov je tzv. skóre – agregovaná hodnota bodov pre jednotlivé parametre. Táto hodnota sa potom považuje za ukazovateľ bonity ohodnocovaného objektu. Všeobecný tvar pre výpočet skóre je:

$$S = \alpha_0 + \alpha_1 X_1 + \alpha_2 X_2 + \dots + \alpha_N X_N, \quad (1.1)$$

kde : S je skóre,

: $\alpha_0, \alpha_1, \alpha_2, \dots, \alpha_N$ sú váhy parametrov,

: X_1, X_2, \dots, X_N sú parametre bonity bodovacích systémov.

1.2.2 Bilančne majetková metóda

Základom bilančne majetkovej metódy pre výpočet úrovne bonity obcí (ratingu²) je ohodnotenie troch stránok (parametrov) úrovne a finančnej situácie v obci. Tou prvou stránkou je rozpočtové hospodárenie. Ide o priamu súčasť riadenia všeobecných financií. Druhá stránka, ktorá je sledovaná bilančne majetkovou metódou je veľkosť majetku obce. Poslednú stránku, nie však z významového hľadiska, tvoria miestne podmienky obce. Týmto trom parametrom sú priradené vybrané kvantitatívne a kvalitatívne kategórie. Nasleduje obodovanie kategórií podľa stanoveného kľúča. Sumarizáciou týchto bodov možno zistiť výsledné skóre. Podľa tohto skóre sú potom obce klasifikované do tried.

² Rating je užší pojem ako bonita. Jedná sa o ocenenie schopnosti obce splatiť dlh.

1.2.3 Modely ratingu

V týchto modeloch ide o nezávislé hodnotenie, ktoré je uskutočnené nezáujatým, nestranným hodnotiteľom. Výsledky hodnotenia sú dosiahnuté na základe komplexného rozboru všetkých známych a zistiteľných rizík objektu, ktorý je hodnotený. Rating je založený na kvalitatívnych aj kvantitatívnych parametroch. Taktiež môže slúžiť ako podklad iných subjektov, pri rozhodovaní v obchodných vzťahoch voči hodnotenému objektu. Napríklad sa môže jednať o rôzne inštitúcie verejného sektora ako sú banky. Vplyv ratingového hodnotenia na výšku nákladov môže byť priaznivý, resp. nepriaznivý. Závisí to od toho, či je hodnotenie pozitívne – to vyjadruje nízku mieru rizika alebo naopak ide o negatívne. V tab. 1 [2] sú uvedené niektoré príklady ratingových stupníc.

Tab. 1 Ratingové stupnice

Fitch	Moody's	Standard & Poor's	Charakteristika
AAA	Aaa	AAA	Vysoká kvalita – najvyššia úroveň úveruschopnosti. Takmer žiadne riziko nesplnenia záväzkov. Kryté úrokové platby veľkou a stabilnou rezervou.
AA	Aa	AA	Dobry až veľmi dobrý – vysoká pravdepodobnosť plnenia záväzkov, nízke riziko platobnej neschopnosti.
A	A	A	Uspokojivý až dobrý – dostatočné krytie dlhových služieb, stále nízke riziko platobnej neschopnosti.
BBB	Baa	BBB	Uspokojivý – dostatočné krytie dlhových služieb, stredné riziko platobnej neschopnosti. Špekulatívne znaky, nedostatočná ochrana proti ekonomickým zmenám.
BB	Ba	BB	Prijateľný až uspokojivý – primerané krytie dlhových služieb, vyššie riziko platobnej neschopnosti.
B	B	B	Neadekvátny až prijateľný – nízke krytie dlhových služieb, vysoké riziko platobnej neschopnosti.
CCC CC C	Caa	CCC	Nedostatočný – úveruschopnosť je sotva primeraná, veľmi vysoké riziko platobnej neschopnosti.
DDD DD D	Ca C	CC SD/D	Neplnenie záväzkov alebo v konkurze.

Princíp metód ratingu spočíva v tom, že hodnotené objekty sú zoradené do skupín a to podľa predpokladanej pravdepodobnosti zlyhania. V ratingovej stupnici sú triedy zoradené podľa stupňa kreditného rizika. Aby bolo zaradenie objektov do tried vždy aktuálne, je potreba v priebehu času zaradenie prehodnocovať.

Z hľadiska času sa rozoznáva rating krátkodobý a dlhodobý. U krátkodobého ratingu sa berú do úvahy záväzky so splatnosťou do jedného roka. U dlhodobého ostatné záväzky, teda so splatnosťou nad jeden rok. Z pohľadu hodnotenia objektu sa rozlišuje rating banky, podniku, štátu, obce a iné. U ratingu obce sa vychádza zo štyroch základných skupín parametrov a to ekonomických, dlhových, finančných a administratívnych. Z ekonomických parametrov sú to nezamestnanosť, koncentrácia ekonomiky, počet obyvateľ. Do dlhových sú zaradené také, ktoré postihujú štruktúru a veľkosť dlhu hodnoteného objektu. Rozpočtovým hospodárením obce sa zaoberajú finančné parametre a posledná skupina, teda administratívne parametre zahŕňujú kvalitatívne parametre organizácie úradu, kvalifikácie pracovníkov a iné.

1.2.4 Modely zlyhania

Pri tejto metóde sa vychádza z predpokladu, že budúce finančné problémy bude možné predikovať sledovaním úrovne a vývoja u vybraných ukazateľov. Cieľom jednotlivých ukazateľov je načas informovať o blížiacich sa finančných problémov obce. Zlyhanie, (z angl. default) je chápané ako neschopnosť obce splácať svoje dlhy a teda splniť v riadnom čase svoje záväzky. Modely zlyhania sú odvodené zo skutočných dát. Výberový súbor objektov je triedený na tie objekty, ktoré nezlyhali a tie, ktoré zlyhali. Cieľom modelu je nájsť príčiny rozdielov medzi týmito triedami [2]. Význam týchto modelov spočíva predovšetkým v podnikateľskej a bankovej oblasti. Aplikácia pre obce je zriedkavá a to hlavne z dôvodu, že u obcí dochádza iba málokedy k možnostiam celkového zlyhania.

1.3 Zhrnutie kapitoly

Kapitola obsahuje základné pojmy z oblasti bonity obcí, ohodnocovania bonity, metódy a modely ohodnotenia bonity obcí. Z metód, pomocou ktorých možno stanoviť bonitu obcí, je podrobnejšie charakterizovaná finančná metóda hodnotenia bonity obcí a bilančne majektová. Z modelov, pomocou ktorých možno určiť bonitu obce, sú spracované dva a to modely ratingu a modely zlyhania [3].

2. Analýza a návrh vstupných parametrov pre klasifikáciu

Kapitola pojednáva o analýze a návrhu vstupných parametrov pre klasifikáciu obcí Pardubického kraja. Spoločné kategórie parametrov sú uvedené v [4] a sú to ekonomické, finančné, dlhové a administratívne. Dôležité z pohľadu stanovenia bonity obcí sú ekonomické, finančné a dlhové parametre. Jednotlivé skupiny parametrov sú bližšie charakterizované v nasledujúcej časti kapitoly [5].

2.1 Návrh ekonomických parametrov

Dlhodobé kreditné riziko je ovplyvnené ekonomickými parametrami. V prípade ekonomickej recesie sú lepšie pripravené obce s viac diverzifikovanou ekonomikou. Ďalej sú to obce, ktoré majú priaznivejšie sociálno-ekonomické podmienky. Vďaka ekonomickému rastu môže nastať situácia, že bude nutné rozšíriť verejné služby, čím môže dôjsť k nárastu zadĺženosti. Stabilita obce z hľadiska ekonomiky môže byť príznakom ekonomickej stagnácie. Parameter, na základe ktorého by bolo možné kvantifikovať úroveň ekonomiky obce, nie je. Avšak návrh ekonomických parametrov pre hodnotenie kreditného rizika možno navrhnúť nasledujúcim spôsobom [4]:

$$\text{Parameter } p_1 = PO_r, \quad (2.1)$$

kde PO_r je počet obyvateľov v r -tom roku. Pre obec vyplývajú z vyššej hodnoty parametra p_1 vyššie daňové príjmy. Daňové príjmy obce závisia na počte obyvateľov v obci a na koeficiente, ktorý znázorňuje kategóriu obce z hľadiska veľkosti. Väčší podiel na daňovom výnose zahŕňajú väčšie obce. Dôvodom je, že u obcí s vyšším počtom obyvateľov, sú vyššie výdaje na infraštruktúru a ďalšie verejné statky [4]. Vyším počtom obyvateľov vyplýva pre veriteľa záruka budúcich príjmov obce a zníženie kreditného rizika obce.

$$\text{Parameter } p_2 = \frac{PO_r}{PO_{r-s}}, \quad (2.2)$$

kde PO_{r-s} je počet obyvateľov v roku $r-s$, kde s je zvolený časový interval. Ekonomickú vitalitu obce možno dobre merať na základe zmeny počtu obyvateľov.

Ekonomický rast obce má za následok rastúci počet obyvateľov. Je potreba obozretne posúdiť nečakaný rast obyvateľov, pretože nemusí naznačovať skutočný trend.

$$\text{Parameter } p_3 = U, \quad (2.3)$$

kde U reprezentuje mieru nezamestnanosti v obci. Miera nezamestnanosti posudzuje výsledné hospodárske zdravie obce. Dôsledkom ekonomického rastu klesá nezamestnanosť v obci. Na základe nízkej miery nezamestnanosti, možno konštatovať, že obec má dobré ekonomické zdravie. U obcí s vysokou mierou nezamestnanosti, sú výdavky za sociálne služby vyššie. Zníženie ceny nehnuteľností je okrem iného spôsobené aj v dôsledku nedostatku pracovných príležitostí, čo má za následok zníženie rozpočtových príjmov z dane z nehnuteľností.

$$\text{Parameter } p_4 = \sum_{i=1}^k \left(\frac{POZ_i}{PZ} \right)^2, \quad (2.4)$$

kde POZ_i predstavuje počet obyvateľov, ktorí sú zamestnaní v i -tom odvetví ekonomiky, $i = 1, 2, \dots, k$. Celkový počet zamestnaných obyvateľov predstavuje PZ a k reprezentuje počet odvetví ekonomiky. Parameter je najdôležitejším faktorom ohodnocovania obcí. Zachycuje koncentráciu zamestnanosti v odvetviach ekonomiky, ako aj mieru koncentrácie ekonomiky obce.

2.2 Návrh dlhových parametrov

Zahrnutie výšky a štruktúry dlhu je obsiahnuté v dlhových parametroch. Používanou metódou merania dlhu obce a schopnosti obce splácať dlhovú službu sú veľakrát pomerové parametre. Efektívnosť použitia pomerových parametrov je závislá na tom, či sú k dispozícii rovnako parametre pre ostatné porovnateľné obce. Až po porovnaní parametrov s týmito obcami, sú k dispozícii informácie, ktoré prezentujú skutočnú dlhovú a finančnú situáciu obce.

Na základe uvedených faktov je realizovateľný návrh [2] týchto dlhových parametrov:

$$\text{Parameter } p_5 = \frac{DS}{OP}, \quad (2.5)$$

kde $p_5 \in \langle 0,1 \rangle$, DS je dlhová služba, OP sú opakujúce sa príjmy. Parameter p_5 je z pohľadu dlhu označovaný ako východiskový. Meria kapacitu obce pokryť DS z pravidelných rozpočtových zdrojov. Dlhová služba označuje dvanásťmesačné platby úrokov, vrátane dvanásťmesačných splátok – anuit. Opakujúce sa príjmy, sú celkové príjmy bez jednorázových a kapitálových príjmov. V prípade dosiahnutia hodnoty parametra p_5 nad 0,15 je potrebné toto považovať za signál, ktorým je naznačovaná dlhová pasca.

$$\text{Parameter } p_6 = \frac{CD}{PO}, \quad (2.6)$$

kde CD je celkový dlh v Kč. Parametrom p_6 možno zhodnotiť hrubú mieru zadĺženosti obce, t.j. podiel Kč dlhu na jedného obyvateľa obce. Absolútna hodnota parametru je sama o sebe nevytvádzajúca. Preto je potrebné skonfrontovať jeho hodnotu za danú obec s ďalšími obcami v regióne, prípadne s celým štátom.

$$\text{Parameter } p_7 = \frac{KD}{CD}, \quad (2.7)$$

kde $p_7 \in \langle 0,1 \rangle$ a KD je krátkodobý dlh. Zaoberá sa rozborom štruktúry dlhu. Funkciou krátkodobého dlhu je pokryť krátkodobé záväzky, ktoré vychádzajú z neuspokojivého peňažného toku. Krátkodobý dlh by sa mal v priebehu fiškálneho roka kompletne splatiť. V prípade, že je KD stanovený na krytie rozpočtového schodku, prípadne k financovaniu investičných projektov, ide o hrozivý signál, čo v konečnom dôsledku vedie k negatívnemu ovplyvňovaniu kreditného rizika obce. Úrokové sadzby KD bývajú pohyblivé, dochádza k zmenám, následkom čoho môže byť obec neschopná splácať dlhy.

2.3 Návrh finančných parametrov

Informácie o rozpočtovom hospodárení obcí sú sprostredkované na základe finančných parametrov, ktorých hodnoty sú získané na základe rozpočtu obce. Pre hodnotenie kreditného rizika možno stanoviť finančné parametre napríklad takto [2]:

$$\text{Parameter } p_8 = \frac{OP}{BV}, \quad (2.8)$$

kde $p_8 \in R^+$ a BV charakterizujú bežné výdaje rozpočtu. Parameter p_8 predstavuje hodnotu, ktorá vykazuje kvalitu rozpočtového hospodárenia. Finančná situácia obce je v tom prípade dobrá, keď je parameter p_8 stabilne väčší ako 1, t.j. bežný rozpočet je prebytkový (zároveň trend naznačuje, že hodnota parametra bude rásť). Dosiahnutie lepšej pozície z hľadiska dlhovej kapacity možno vďaka dobrej finančnej situácii. Aby obce mohli mať k dispozícii bežný prebytok za účelom financovania svojich záväzkov, musí byť hodnota parametra p_8 väčšia ako 1.

$$\text{Parameter } p_9 = \frac{VP}{CP}, \quad (2.9)$$

kde $p_9 \in \langle 0,1 \rangle$, VP reprezentujú vlastné príjmy a CP udávajú celkové príjmy. Vyším podielom vlastných príjmov na celkových príjmoch, je vyjadrená vyššia fiškálna autonómia obce, ktorá je ovplyvňovaná na základe rozhodovania manažmentu obce. Čím bude vyššia fiškálna autonómia obce, tým bude obec menej zadĺžená. Úlohou manažmentu obce, je okrem iných, nájsť vhodnú kombináciu medzi VP a dlhom na financovanie verejného majetku. Jednoducho povedané, čím je ich fiškálna autonómia vyššia, tým bude nižšia potreba voliť dlh ako prostriedok financovania.

$$\text{Parameter } p_{10} = \frac{KV}{CV}, \quad (2.10)$$

kde $p_{10} \in \langle 0,1 \rangle$, KV je hodnota kapitálových výdajov a CV sú celkové výdaje. Investičnú aktivitu obce, ako aj dobré hospodárenie obce, čo umožňuje budúci rozvoj, reprezentuje vyššia hodnota parametra p_{10} . Táto hypotéza je v harmónii s medzigeneračnou teóriou spravodlivosti, kde sa na kapitálových výdajoch majú zúčastňovať nielen terajší, ale aj nastávajúci užívatelia verejného majetku. [2]

$$\text{Parameter } p_{11} = \frac{IP}{CP}, \quad (2.11)$$

kde $p_{11} \in \langle 0,1 \rangle$ a IP sú investičné príjmy. Hlavnou úlohou dlhov je financovanie investičných výdajov (projektov). Keď bude hodnota parametra p_{11} vyššia, bude klesať nutnosť nasledujúceho zadlžovania z dôvodu financovania investičných projektov.

$$\text{Parameter } p_{12} = \frac{LM}{PO}, \quad (2.12)$$

kde LM značí výšku likvidného majetku obce. Obce majú k dispozícii svoj majetok, ktorý je veľakrát využitý ako zástava bankových úverov. Poskytnutie úveru bankou, možno iba v tom prípade, pokiaľ majetok, ktorý je využitý ako zástava, je značne likvidný, teda behom krátkej doby ľahko premeniteľný na peniaze. Napríklad nimi môžu byť majetky, ktoré slúžia pre podnikateľské účely, dobre situované rozsiahle pozemky, poľnohospodárske pozemky a iné.

2.4 Vektor parametrov pre ohodnotenie obcí

Parametre p_1 až p_{12} tvoria vektor \vec{p} pre ohodnotenie obcí ČR s nasledujúcim tvarom $\vec{p} = (p_1, p_2, p_3, p_4, p_5, p_6, p_7, p_8, p_9, p_{10}, p_{11}, p_{12})$. Navrhnutý vektor parametrov možno pre n obcí O_n vyjadriť v takomto tvare dátovej matice H

$$H = \begin{matrix} & p_1 & \dots & p_j & \dots & p_m \\ \begin{matrix} O_1 \\ \dots \\ O_i \\ \dots \\ O_n \end{matrix} & \left(\begin{array}{ccccc} x_{1,1} & \dots & x_{1,j} & \dots & x_{1,m} \\ \dots & \dots & \dots & \dots & \dots \\ x_{i,1} & \dots & x_{i,j} & \dots & x_{i,m} \\ \dots & \dots & \dots & \dots & \dots \\ x_{n,1} & \dots & x_{n,j} & \dots & x_{n,m} \end{array} \right) , \end{matrix} \quad (2.13)$$

kde : n je počet objektov (obcí),

: m je počet parametrov,

: $x_{i,j}$ je hodnota j -tého parametru p_j pre i -tú obec $O_i, i \in \{1, 2, \dots, 12\}$ [2].

2.5 Zhrnutie kapitoly

Kapitola obsahuje popis parametrov, podľa ktorých možno vykonať rating obcí. Parametre sú rozdelené podľa zamerania do tried na ekonomické, dlhové a finančné. Každá trieda obsahuje niekoľko parametrov, ktoré sú podrobne charakterizované v kapitole 2 a to ako z teoretického hľadiska, tak z matematického formou vzťahu, podľa ktorého je určený daný parameter. V závere kapitoly je prezentovaná dátová matica H vektora \vec{p} , ktorá sa skladá z jednotlivých obcí Pardubického kraja a parametrov, pomocou ktorých možno stanoviť bonitu obcí.

3. Základné pojmy z oblasti fuzzy logiky, fuzzy množín, IFM a IFR

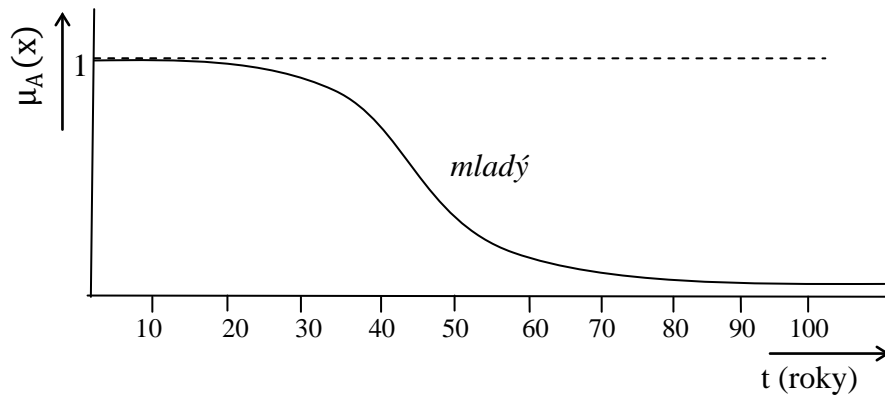
Kapitola obsahuje charakteristiku základných pojmov z oblasti fuzzy množín, fuzzy logiky, základné operácie nad fuzzy množinami, fuzzy relácie. Ďalej je predmetom kapitoly problematika IFM, definícia konceptu IFM, funkcia príslušnosti $\mu_A(x)$, respektíve funkcia nepríslušnosti $\nu_A(x)$, IFR. Záverečná kapitola obsahuje problematiku všeobecného klasifikačného problému, rozdelenie množiny objektov $O_i = \{o_1, o_2, \dots, o_p\}$ na tréningovú a testovaciu.

3.1 Fuzzy množiny

Zakladateľom fuzzy množín bol americký kybernetik Lofti A. Zadeh. V roku 1965 publikoval prácu *Fuzzy sets* do časopisu *Information and Control*. Pri rozvoji teórie fuzzy množín vznikol ako vedľajší produkt termín fuzzy logika. Vďaka prirodzenému jazyku možno pomerne dobre intuitívne narábať s nejasne ohraničenými pojmami. Nech je špecifikovaný pojem *mladý* v závislosti na subjektívnej interpretácii človeka. Je obtiažne nájsť úplnú zhodu interpretácie pojmu *mladý*, ktorú by vyslovili dvaja rôzni ľudia. A práve fuzzy množiny riešia takéto problémy. Fuzzy množiny ponúkajú teoretický aparát [6], ktorý umožňuje jednoduché modelovanie problémov takéhoto charakteru a ich implementáciu na počítačoch. Koncepcia fuzzy množín umožňuje formalizovať pojem mladosti. Nech U je univerzum tvorené prirodzenými číslami od 1 do 100, $U = \{1, 2, \dots, 100\}$. Fuzzy množina A , vyjadrujúca adjektívum *mladý*, je špecifikovaná charakteristickou funkciou s oborom funkčných hodnôt z uzavretého intervalu $[0, 1]$ [6]

$$\mu_A: U \rightarrow [0, 1] \quad (3.1)$$

s kvalitatívnym priebehom znázorneným na obr. 1. Alternatívny názov charakteristickej funkcie $\mu_A(x)$ je stupeň príslušnosti prvku – argumentu x do fuzzy množiny *mladý* [6].



Obr. 1 Fuzzy množina A *mladý*


Nech je definovaná fuzzy množina $A = \{(x, \mu_A(x)); x \in U\}$, kde U je univerzum a $\mu_A(x)$ je charakteristická funkcia (stupeň príslušnosti x do A). Pojem fuzzy množiny A splýva s pojmom jej charakteristickej funkcie $\mu_A(x)$, ktorá ju spolu s univerzom U jednoznačne určuje. Zápis $x \in A$ sa v teórii fuzzy množín interpretuje pomocou príslušnej charakteristickej funkcie $\mu_A(x)$ tak, že stupeň príslušnosti prvku x do fuzzy množiny A , je určený hodnotou $\mu_A(x)$.


3.2 Operácie nad fuzzy množinami

Nech sú dané fuzzy množiny A a B . Potom ich možno zapísať v tvare

$$A = \{(x, \mu_A(x)); x \in U\}, B = \{(x, \mu_B(x)); x \in U\} \quad (3.2)$$

a priebehy charakteristických funkcií fuzzy množín A a B znázorniť na obr. 2.





Obr. 2 Priebehy charakteristických funkcií fuzzy množín A a B


Ďalej možno zaviesť

- Doplnok fuzzy množín A a B v tvare

$$\bar{A} = \{(x, \mu_{\bar{A}}(x)); x \in U\}, \bar{B} = \{(x, \mu_{\bar{B}}(x)); x \in U\},$$

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x), \mu_{\bar{B}}(x) = 1 - \mu_B(x), \quad (3.3)$$

znázornený na obr. 3.



Obr. 3 Priebehy charakteristických funkcií komplementov fuzzy množín A a B

- zjednotenie fuzzy množín A a B nasledujúcim spôsobom

$$A \cup B = \{(x, \mu_{A \cup B}(x)); x \in U\},$$


$$\mu_{A \cup B}(x) = \max \{(\mu_A(x)), \mu_B(x)\}. \quad (3.4)$$

- Prienik fuzzy množín A a B takto

$$A \cap B = \{(x, \mu_{A \cap B}(x)); x \in U\},$$

$$\mu_{A \cap B}(x) = \min \{(\mu_A(x), \mu_B(x))\}, \quad (3.5)$$

ktoré sú znázornené na obr. 4.



Obr. 4 Priebiehy charakteristických funkcií prieniku a zjednotenia fuzzy množín A a B

- Podmnožinu fuzzy množín A a B

$$A \subseteq B = \text{def } \forall (x \in U)(\mu_A(x) \leq \mu_B(x)). \quad (3.6)$$

3.3 Fuzzy relácie


Binárna relácia je v klasickej (ostrej) teórii množín definovaná ako ľubovoľná podmnožina karteziánskeho súčinu dvoch množín $T = \{(x, y); x \in A \wedge y \in B\} \subseteq A \times B$. Ostrá relácia T je definovaná pomocou charakteristickej funkcie takto

$$T = \{(x, y); x \in A \wedge y \in B \wedge \mu_T(x, y) = 1\}. \quad (3.7)$$

Inverzná relácia T^{-1} (k relácii T) je definovaná pomocou usporiadaných dvojíc $(y, x) \in T^{-1}$, ktorých inverzia patrí do relácie $(x, y) \in T$

$$T^{-1} = \{(y, x); (x, y) \in T\} \subseteq B \times A. \quad (3.8)$$

Diagramatická reprezentácia inverznej relácie sa zostrojí jednoduchým spôsobom z diagramatickej reprezentácie pôvodnej T tak, že jednotlivé hrany (zobrazenia) zmenia svoju orientáciu, čo možno vidieť na obr. 5 [6].



Obr. 5 Diagramatická reprezentácia inverznej relácie T^{-1}

Nech sú dané ostré množiny A , B a C . Pre tieto množiny nech sú definované dve relácie v tvare $R \subseteq A \times B$ a $Q \subseteq B \times C$. (3.9)

Zložená relácia (kompozícia) $T = R \circ Q$ je definovaná ako nová relácia $T \subseteq A \times C$ takto

$$T = R \circ Q = \{(x, z); x \in A \wedge z \in C \wedge \exists y \in B: ((x, y) \in R) \wedge ((y, z) \in Q)\}. \quad (3.10)$$

Charakteristická funkcia kompozície $T = R \circ Q$ je určená vzťahom

$$\mu_{R \circ Q}(x, z) = \max_{y \in B} \min \{(\mu_R(x, y), \mu_Q(y, z))\}. \quad (3.11)$$

Význam tohto vzťahu priamo vyplýva z definície kompozície dvoch relácií R a Q [6].

3.4 Intuitionistic fuzzy množiny

V súčasnosti existuje niekoľko zovšeobecnení teórie fuzzy množín pre rôzne ciele. Intuitionistic fuzzy množiny predstavujú jednu zo zovšeobecnení teórie fuzzy množín, ktorých pojem zaviedol K. Atanasov. Teória IFM je používaná v rôznych oblastiach, ako sú napríklad logické programovanie, mnohokriteriálne rozhodovacie procesy, usudzovanie, optimalizácia v Intuitionistic fuzzy prostredí, lekárska diagnostika a pod. Intuitionistic fuzzy množiny sú vhodné na modelovanie bonity obcí, pretože poskytujú dobrý popis atribútov (parametrov) objektov (obcí) pomocou funkcie

príslušnosti resp. funkcie nepríslušnosti, taktiež slúžia na vyjadrenie neistoty. V teórii fuzzy množín sú tri základné možnosti [7] ako určiť funkcie príslušnosti a to:

- na základe poznatkov experta,
- pomocou štatistických metód,
- analyticky, podľa vhodne zvolenej funkcie (napr. pravdepodobnostné rozloženie).

V obidvoch posledne uvedených prípadoch sú spracované veľmi podobne, rovnako ako vo fuzzy množinách. Avšak tieto metódy sa v súčasnosti používajú pre odhad obidvoch stupňov a to stupňa príslušnosti, resp. nepríslušnosti daného prvku z univerza na podmnožinu toho istého univerza. Všetky uvedené možnosti určenia funkcie príslušnosti musia rešpektovať nerovnosti $0 \leq \mu_A(x) + \nu_A(x) \leq 1$. Zložitejší prípad je vtedy, keď sú funkčné hodnoty počítané na základe vedomostí – experta. Problémy vznikajú predovšetkým v súvislosti so správnosťou znaleckého odhadu.

3.4.1 Definície IFM

Teória IFM je založená na:

- rozsahu zodpovedajúcich definícií fuzzy množiny objektov,
- definícii nových objektov a ich vlastností.

Spôsob ponímania IFM je charakteristický zovšeobecnením sústavy názorov na fuzzy množiny, ktorých zakladateľ bol L.A. Zadeh. Teória IFM sa dobre hodí k riešeniu vágnosti. Práve IFM sú použité pre intuitionistic klasifikáciu modelov, ktoré môžu poskytovať nepresné informácie. Zakladateľom fuzzy relácií bol L.A. Zadeh, od ktorého prijal E. Sanchez max-min kompozíciu relácií [7].

3.4.2 Definícia konceptu IFM

Nech X je množina všetkých krajín s volenými vládami. Je známe pre každú krajinu $x \in X$ percento voličov, ktorí volili svoju príslušnú vládu. Toto percento je označené ako $M(x)$ a nech $\mu(x) = M(x)/100$. Potom $\nu(x)$ nech sa rovná $\nu(x) = 1 - \mu(x)$. Toto číslo korešponduje s tou časťou voličov, ktorí nehlasovali pre vládu. Podľa teórie fuzzy množín sa nemôže ďalej uvažovať o tomto čísle podrobnejšie. Ak sa však definuje číslo $\nu(x)$, ako číslo hlasov stranám a jednotlivcom, ktorí nie sú vo

vláde, možno zistiť, aká časť voličov vôbec nevolila, pričom toto číslo bude $1 - \mu(x) - \nu(x)$. Potom možno skonštruovať množinu $A = \{(\langle x, \mu_A(x), \nu_A(x) \rangle | x \in X)\}$, v ktorej samozrejme musí platiť $0 \leq \mu(x) + \nu(x) \leq 1$. Nech množina X je neprázdna pevná množina. Potom IFM A v X je objekt s formou [7], [16]

$$A = \{(\langle x, \mu_A(x), \nu_A(x) \rangle | x \in X)\}, \quad (3.12)$$

kde funkcia $\mu_A: X \rightarrow [0; 1]$ určuje stupeň funkcie príslušnosti a funkcia $\nu_A: X \rightarrow [0; 1]$ stupeň funkcie nepríslušnosti, resp. tohto prvku $x \in X$ do množiny A , ktorá je podmnožinou X a $A \subset X$, a navyše pre každé $x \in X$, $0 \leq \mu_A(x) + \nu_A(x) \leq 1, \forall x \in X$ musí platiť. Položka

$$\pi_A(x) = 1 - (\mu_A(x) + \nu_A(x)) \quad (3.13)$$

sa nazýva stupeň neurčitosti, resp. časť neistoty, ktorá sa môže zamerať buď na členstvo v hodnote alebo nečlenstvo hodnoty, prípadne na obidva predchádzajúce. Pre každú IFM v X , existuje číslo $\pi_A(x)$ – tzv. Intuitionistic index prvku x v množine A v tvare $\pi_A(x) = 1 - (\mu_A(x) + \nu_A(x))$. Ide o stupeň neurčitosti prvku x do množiny A . Je zrejmé, že $0 \leq \pi_A(x) \leq 1$ pre každé $x \in X$. Ak A a B sú dve IFM množiny X , potom

$$A \cap B = \{(\langle x, \min(\mu_A(x), \mu_B(x), \max(\nu_A(x), \nu_B(x))) \rangle | x \in X)\},$$

$$A \cup B = \{(\langle x, \max(\mu_A(x), \mu_B(x), \min(\nu_A(x), \nu_B(x))) \rangle | x \in X)\},$$

$$A \subset B \text{ iff } \forall x \in X, (\mu_A(x) \leq \mu_B(x) \text{ and } (\nu_A(x) \geq \nu_B(x))),$$

$$A \supset B \text{ iff if } B \subset A,$$

$$A = B \text{ iff } \forall x \in X, (\mu_A(x) = \mu_B(x) \text{ and } (\nu_A(x) = \nu_B(x))),$$

$$\bar{A} = \{(\langle x, \nu_A(x), \mu_A(x) \rangle | x \in X)\} [7], [16]. \quad (3.14)$$

Nech X a Y sú dve množiny. Potom IFR R z množiny X do Y , $R(X \rightarrow Y)$, je IFM z $(X \times Y)$ charakterizovaná funkciou príslušnosti $\mu_R(x)$ a funkciou nepríslušnosti $\nu_R(x)$.

V prípade, že A je ľubovoľná IFM z X , potom max-min kompozícia z IFR $R(X \rightarrow Y)$ z A je určitá IFM B z Y , $B = R \circ A$ a je definovaná [7], [16] funkciou príslušnosti

$$\mu_{R \circ A}(y) = \bigvee_x [\mu_A(x) \wedge \mu_R(x, y)], \quad (3.15)$$

a funkciou nepríslušnosti

$$\nu_{R \circ A}(y) = \bigwedge_x [\nu_A(x) \wedge \nu_R(x, y)], \quad (3.16)$$

$\forall y \in Y$, kde $\bigvee = \max$, $\bigwedge = \min$.

Nech $Q(X \rightarrow Y)$ a $R(Y \rightarrow Z)$ sú dve IFRs. Potom max-min kompozícia $T = R \circ Q$ je IFR z $T(X \rightarrow Z)$, definovaná funkciou príslušnosti [7], [16]

$$\mu_{R \circ Q}(x, z) = \bigvee_y [\mu_Q(x, y) \wedge \mu_R(y, z)], \quad (3.17)$$

a funkciou nepríslušnosti

$$\nu_{R \circ Q}(x, z) = \bigwedge_y [\nu_Q(x, y) \vee \nu_R(y, z)], \quad (3.18)$$

$\forall (x, z) \in (X \circ Z)$ a $\forall y \in Y$.

Ak $Q(X \rightarrow Y)$ a $R(Y \rightarrow Z)$ sú dve IFR na $(X \times Y)$ a $(Y \times Z)$, potom

$$(R^{-1})^{-1} = R \text{ a } (Q \circ R)^{-1} = R^{-1} \circ Q^{-1} \quad (3.19)$$

3.5 Všeobecný klasifikačný problém

Nech je daná všeobecná formulácia klasifikačného problému pomocou pojmu zobrazenia – funkcie definovanej nad dvomi množinami A a B . Nech $F(x)$ je funkcia definovaná nad množinou A , ktorá priradí každému prvku $x \in A$ obraz – funkčnú hodnotu z množiny B , $\hat{x} = F(x) \in B$,

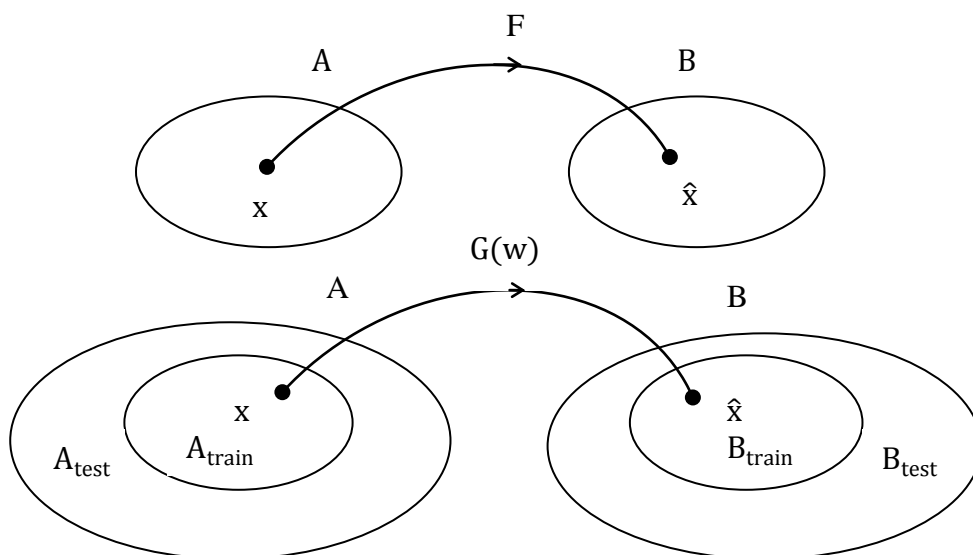
$$F: A \rightarrow B. \quad (3.20)$$

Nech $G(x, w)$ je funkcia, ktorej argumenty sú z konečnej podmnožiny $A_{train} = \{x_1, x_2, \dots, x_r\} \subset A$ (nazývanej tréningová množina) a w je parameter (alebo parametre) zobrazenia G , potom $\hat{x} = G(x, w) \in B_{train} \subset B$

$$G(w): A_{train} \rightarrow B_{train} . \quad (3.21)$$

Formálne môžno povedať, že zobrazenie $G(w)$ je reštrikcia zobrazenia $F(x)$ nad množinou $A_{train} \subset A$, vid'. obr. 6. Komplement A_{train} vzhľadom k množine A je označený A_{test} (nazývaný testovacia množina), $A_{test} = A/A_{train}$. Nech je známy pre každé $x_i \in A_{train}$ požadovaný obraz – funkčná hodnota \hat{x}_i ,

$$x_1/\hat{x}_1, x_2/\hat{x}_2, \dots, x_r/\hat{x}_r. \quad (3.22)$$



Obr. 6 Zobrazenie $F: A \rightarrow B$

Zúžením tohto zobrazenia na podmnožinu A_{train} možno dostať nové „modelové“ zobrazenie $G(w)$. Funkčný tvar tohto zobrazenia je určený parametrom, respektíve parametrami w . Požadované funkčné hodnoty

$$\hat{x}_i = F(x_i) \quad (i = 1, 2, \dots, r). \quad (3.23)$$

Cieľom formulácie klasifikačného problému je nájsť taký parameter (alebo parametre) w funkcie $G(x, w)$, aby funkčné hodnoty argumentov z tréningovej množiny A_{train} boli čo najbližšie obrazom funkcie $F(x)$, t.j. požadovaným hodnotám [9].

Ďalej nech je daná účelová funkcia

$$E(w) = \frac{1}{2} \sum_{i=1}^r (G(x_i, w) - \hat{x}_i)^2. \quad (3.24)$$

Táto funkcia vyjadruje sumu kvadrátov odchýlok funkcie $G(x, w)$ od požadovaných hodnôt \hat{x} braných z trénovacej množiny. Požiadavka, aby boli vypočítané hodnoty $G(x, w)$ „čo najbližšie“ k požadovaným hodnotám \hat{x} , je realizovaná pomocou požiadavky minimálnosti účelovej funkcie $E(w)$ vzhľadom k parametru w . Potom možno povedať, že funkcia $G(x, w)$ je adaptovaná, ak jej parameter w je vybraný tak, aby sa rovnal svojej optimálnej hodnote (t.j. v ktorom má účelová funkcia globálne minimum). Nech \bar{w} je optimálna hodnota parametru w , určená nasledujúcim minimalizačným problémom

$$\bar{w} = \arg \min_{w \in W} E(w), \quad (3.25)$$

kde W je množina (priestor) prípustných hodnôt parametra w . Adaptovaná funkcia $G(x, \bar{w})$ simuluje pôvodnú funkciu $F(x)$ pre hodnoty argumentov z trénovacej množiny A_{train} na základe minimalizačného kritéria. Navyše, adaptovaná funkcia $G(x, \bar{w})$ sa používa aj pre predpoveď funkčných hodnôt odpovedajúcich argumentom z testovacej množiny A_{test} , t.j. predpokladá sa, že adaptovaná funkcia dobre aproximuje pôvodnú funkciu $F(x)$ tiež mimo trénovacej množiny. Tieto úvahy môžu byť chápané ako klasický regresný problém, v ktorom parametre modelovej funkcie G sú optimalizované (adaptované) tak, aby vypočítané funkčné hodnoty boli blízke požadovaným (experimentálnym) funkčným hodnotám.

3.6 Rozklad množiny objektov na trénovaciu a testovaciu množinu

Rozklad množiny objektov na trénovaciu a testovaciu množinu $A = A_{train} \subset A_{test}$ je popísaný v nasledujúcej časti práce. Nech je daná ľubovoľná zhlukovacia metóda, napr. Kohonenova, K-means, Two-Step, atď. Táto metóda rozloží množinu A na disjunktné podmnožiny – zhluky, ktoré obsahujú „podobné“ objekty (z hľadiska metriky použitej v zhlukovacej metóde)

$$A = C_1 \cup C_2 \cup \dots \cup C_i, \quad (3.26)$$

kde i -tý zhluk C_i obsahuje n_i objektov z A


$$C_i = \{o_1^{(i)}, o_2^{(i)}, \dots, o_n^{(i)}\} \subset A, \quad (3.27)$$

pričom je predpoklad, že objekt $o_1^{(i)} \in C_i$ je ten objekt z i -tého zhluku C_i , ktorý leží „najbližšie“ k jeho centru. Tento objekt môže byť označený ako „reprezentant“ objektov zo zhluku C_i . Potom tréningová a testovacia množina je určená objektami

$$A_{train} = \{o_1^{(1)}, o_1^{(2)}, \dots, o_1^{(p)}\},$$

$$A_{test} = (C_1 \{o_1^{(1)}\}) \cup (C_2 \{o_1^{(2)}\}) \cup \dots \cup (C_p \{o_1^{(p)}\}). \quad (3.28)$$

Znamená to, že tréningová množina je zložená zo všetkých reprezentantov zhlukov a testovacia množina obsahuje zostávajúce objekty. Počet objektov v tréningovej množine je totožný s počtom zhlukov, $|A_{train}| = p$ a $|A_{test}| = |A| - p$. Na obr. 7 možno vidieť schématické znázornenie rozkladu množiny objektov A na tréningovú a testovaciu množinu pomocou rozkladu A na zhluky C_1, C_2, \dots, C_p [9]. Objekty reprezentované štvorcami odpovedajú tým objektom, ktoré ležia najbližšie k stredom príslušných zhlukov, ostatné objekty sú reprezentované krúžkami. Je dobré všimnúť si, že zhluk C_5 obsahuje iba jeden objekt, ktorý patrí do tréningovej množiny.



Obr. 7 Rozklad množiny A

3.7 Zhrnutie kapitoly

Kapitola obsahuje základné pojmy z oblasti fuzzy množín, fuzzy relácií, IFM a IFR. V jednotlivých častiach kapitoly sú spracované praktické príklady z danej problematiky ako aj teoretické základy, resp. definície z danej oblasti, potrebné k správne pochopeniu riešenej problematiky. Ďalej kapitola obsahuje problematiku všeobecného klasifikačného problému, ktorá je spracovaná ako teoreticky, tak grafickou formou. Kapitulu uzatvára problematika rozkladu množiny objektov na tréningovú a testovaciu množinu.

4. Model na klasifikáciu parametrov pomocou IFR

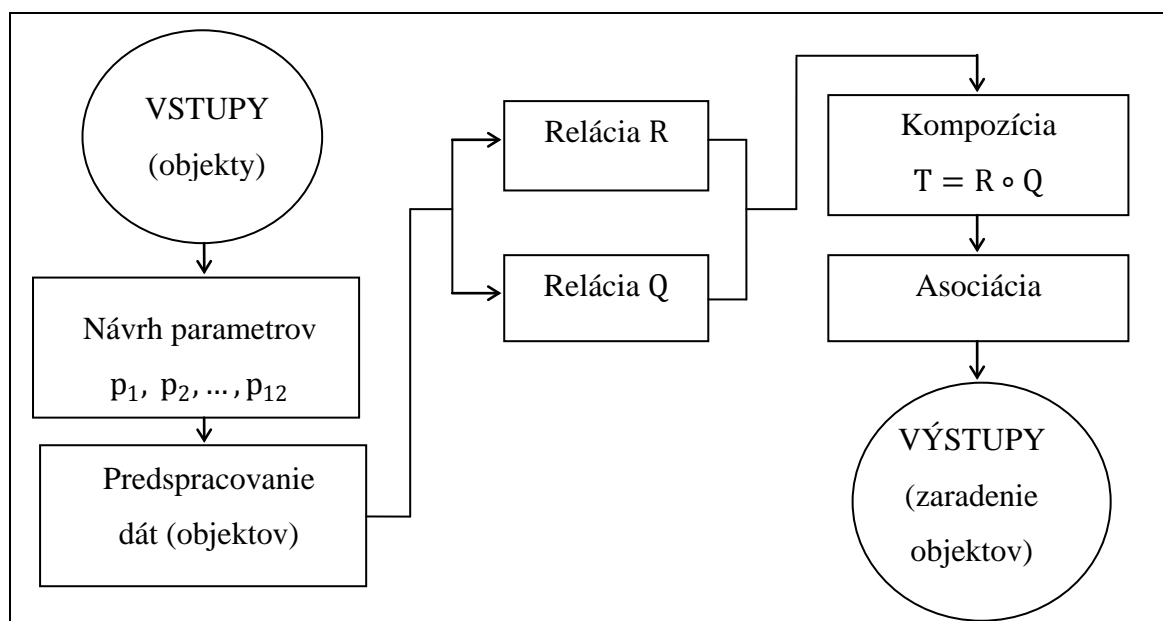
Na začiatku kapitoly sú uvedené jednotlivé kroky, potrebné pre návrh modelu na klasifikáciu parametrov určujúcich bonitu obcí pomocou IFR. Vstup do modelu tvorí 452 obcí Pardubického kraja – objekty. Parametre, ktoré sú vybrané, na základe korelácie, sú použité pri tvorbe dvoch základných IFR a to relácií R a Q . Relácia $R(P \rightarrow \Omega)$ spočíva v rozdelení parametrov do troch tried a zároveň vyjadruje funkcie príslušnosti μ , resp. funkcie nepríslušnosti ν parametrov p_1, p_2, \dots, p_{12} v rámci daných tried. Podstatou relácie $Q(O \rightarrow P)$ je zaradenie objektov podľa jednotlivých parametrov p_1, p_2, \dots, p_{12} , t.j. určenie, ako prispieva objekt O_n , kde $n = 1, 2, \dots, 452$ k parametru p_n , kde $n = 1, 2, \dots, 12$. Pred tvorbou IFR R a Q je potrebné predspracovať vstupné dáta – objekty. Ďalej nasleduje kompozícia IFR R a Q a na záver je uskutočnená výsledná asociácia IFR R a Q . Podrobnejšie sú jednotlivé časti modelu spracované v nasledujúcej časti.

4.1 Návrh modelu na klasifikáciu bonity obcí pomocou IFR

Prvým krokom návrhu modelu je určenie parametrov, ktoré vstupujú do modelu a to ekonomických, finančných a dlhových. Návrh parametrov, ako aj vhodný výber parametrov pre určenie bonity obcí, je podrobne spracovaný v kapitole 2. Ďalšou časťou návrhu modelu je predspracovanie objektov. Ďalej model obsahuje dve základné IFR a to R a Q . Operácia, ktorá je použitá s reláciami R a Q sa nazýva kompozícia $T = R \circ Q$. Vyzdvihnutie vysokých hodnôt a naopak potlačenie nízkych hodnôt je uskutočnené pomocou operácie asociácie.

V ďalšej časti kapitoly sú podrobne popísané vzniknuté relácie R a Q , spôsoby ich stanovenia a ich zdôvodnenie. Ďalej je v rámci kompozície uvedený všeobecný postup, teda v čom spočíva skladanie IFR R a Q . Ako pomôcka k uskutočneniu skladania relácií R a Q – kompozície IFR R a Q , je vytvorený algoritmus, ktorý je tiež v závere kapitoly podrobne spracovaný, spolu s operáciou asociácie, ktorej úlohou je stanoviť asociačný index pre obce Pardubického kraja.

Výstupom z modelu sú klasifikované obce do troch tried. Navrhnutý model na klasifikáciu je uvedený na obr. 8.



Obr. 8 Model klasifikátora obcí Pardubického kraja s využitím IFR R, Q

4.2 Charakteristika vstupných dát

Dátová matica sa skladá zo 452 objektov – obcí Pardubického kraja, čo predstavujú riadky matice. Stĺpce dátovej matice sú tvorené parametrami p_1, p_2, \dots, p_{12} . Návrh týchto parametrov, ako aj význam je podrobne spracovaný v kapitole 2.

Tab. 2 Ukážka dátovej matice pôvodných dát

obce	p1	p2	p3	p4	p5	p6	p7	p8	p9	p10	p11	p12
o1	296	1.260	10.256	0.124	0.069	4199.324	1.000	1.211	0.013	0.579	0.785	72578.634
o2	589	2.572	8.784	0.153	0.711	45276.859	0.033	0.813	0.010	0.120	0.388	144445.107
o3	154	1.055	6.329	0.207	0.000	140.325	1.000	1.089	0.073	0.122	0.043	66754.562
o4	239	0.860	9.924	0.196	0.000	0.000	0.000	1.636	0.016	0.560	0.273	53162.239
o5	3280	1.439	5.499	0.153	0.247	7323.969	0.061	0.257	0.028	0.154	0.764	91833.618
o6	225	1.160	10.680	0.125	0.054	1405.115	0.429	1.180	0.030	0.201	0.011	20844.773
o7	236	1.040	10.000	0.203	0.176	2157.095	0.063	1.340	0.036	0.016	0.000	34702.696
o8	936	1.051	8.958	0.196	0.119	4646.583	0.078	1.105	0.088	0.203	0.005	41666.727
o9	212	1.019	7.619	0.156	0.673	0.000	0.000	1.236	0.012	0.461	0.531	73241.868
o10	71	1.029	12.821	0.183	0.000	161.972	1.000	1.050	0.191	0.000	0.027	54296.223
o11	395	1.018	13.636	0.135	0.164	4154.724	0.032	1.224	0.142	0.015	0.026	46569.067
o12	1200	1.504	6.289	0.131	0.016	99.150	1.000	1.271	0.077	0.229	0.014	122996.673
o13	970	1.136	5.837	0.170	0.000	474.184	0.691	1.180	0.091	0.276	0.016	60099.000
o14	400	0.990	8.213	0.144	0.242	10713.119	0.011	1.247	0.076	0.153	0.057	66969.818
o15	1847	1.047	9.324	0.189	0.055	2498.992	0.112	0.970	0.063	0.104	0.113	37004.051
o16	327	0.962	6.557	0.181	0.129	12658.703	0.185	1.661	0.429	0.442	0.068	123654.323
o17	1937	1.015	9.692	0.166	0.000	139.877	1.000	1.108	0.076	0.195	0.069	46181.559
o18	788	1.012	9.406	0.190	0.140	5103.930	0.026	1.062	0.052	0.126	0.050	40618.561
o19	282	1.160	10.833	0.129	0.000	664.376	1.000	0.764	0.046	0.419	0.427	328184.278
o20	252	0.969	9.091	0.190	0.020	3613.591	0.505	1.077	0.022	0.191	0.126	66778.921
o21	6299	0.980	7.468	0.178	0.029	3500.158	0.169	0.387	0.040	0.159	0.661	75293.687
o22	1821	1.208	10.147	0.174	0.293	31229.504	0.083	1.074	0.081	0.449	0.448	158695.437
o23	811	1.056	7.254	0.180	0.128	5807.032	0.694	1.009	0.032	0.435	0.301	75296.332
o24	234	1.153	8.257	0.161	0.109	1985.655	0.053	1.300	0.051	0.149	0.000	52912.408

V predchádzajúcej tab. 2 možno vidieť ukážku dátovej matice pôvodných dát, ktorá je načítaná pomocou programu SPSS Clementine, ešte pred úpravou samotných dát. Úprava, resp. predspracovanie dát zahrňuje štandardizáciu a normalizáciu dát, koreláciu parametrov. Spôsob výpočtu jednotlivých úprav je rozpísaný v nasledujúcej časti diplomovej práce.

4.3 Predspracovanie dát

4.3.1 Štandardizácia

Úvodná dátová matica obsahuje rôzne znaky, ktoré nie sú jednotne štandardizované, teda pri vzájomnom porovnaní nemajú rovnakú váhu. Preto je nutné uskutočniť niekoľko úprav s touto maticou. Ako prvá je použitá štatistická metóda úpravy dát – štandardizácia. To znamená, že ak sa v rámci vstupnej množiny znakov vyskytujú znaky s dominantným charakterom, je dôležité, aby boli tieto znaky upravené a aby zaistovali súmernosť všetkých znakov vstupnej množiny.

Nech je daná matica dát $Z = (Z_{ij})$ typu $n \times p$, ktorej riadky sú p -rozmerné vektory čísel charakterizujúcich n objektov.

Štandardizácia dát je uskutočnená v dvoch krokoch a to

1. Vypočítaním strednej hodnoty \bar{Z}_j j -tého znaku Z_j a smerodatnej odchýlky S_j pre $j = 1, 2 \dots, p$ podľa vzťahov

$$\bar{Z}_j = \frac{1}{n} \sum_{i=1}^n Z_{ij}, \quad (4.1)$$

$$S_j = \left[\frac{1}{n} \sum_{i=1}^n (Z_{ij} - \bar{Z}_j)^2 \right]^{1/2}. \quad (4.2)$$

2. Pôvodné hodnoty Z_{ij} j -tého znaku i -tého objektu sú prepočítané na tzv. štandardizované hodnoty

$$X_{ij} = \frac{Z_{ij} - \bar{Z}_j}{S_j}. \quad (4.3)$$

Ukážku štandardizovaných dát možno vidieť prostredníctvom tab. 3.

Tab. 3 Ukážka dátovej matice štandardizovaných dát

obce	p1	p2	p3	p4	p5	p6	p7	p8	p9	p10	p11	p12
o1	-0.176	1.756	-0.248	-1.405	0.004	0.002	1.169	0.009	-0.849	2.006	3.486	0.047
o2	-0.113	10.099	-0.499	-0.856	5.847	2.603	-1.140	-1.104	-0.883	-0.588	1.293	1.149
o3	-0.206	0.455	-0.916	0.155	-0.622	-0.255	1.169	-0.333	-0.111	-0.581	-0.614	-0.043
o4	-0.188	-0.785	-0.305	-0.037	-0.622	-0.264	-1.219	1.194	-0.809	1.896	0.659	-0.251
o5	0.463	2.898	-1.057	-0.848	1.622	0.199	-1.073	-2.656	-0.658	-0.398	3.371	0.342
o6	-0.191	1.122	-0.176	-1.376	-0.132	-0.175	-0.194	-0.079	-0.630	-0.131	-0.788	-0.747
o7	-0.189	0.358	-0.292	0.091	0.980	-0.128	-1.069	0.369	-0.561	-1.180	-0.849	-0.534
o8	-0.039	0.427	-0.469	-0.040	0.464	0.030	-1.032	-0.287	0.082	-0.121	-0.818	-0.427
o9	-0.194	0.229	-0.697	-0.786	5.500	-0.264	-1.219	0.077	-0.852	1.336	2.085	0.057
o10	-0.224	0.291	0.188	-0.279	-0.622	-0.254	1.169	-0.440	1.349	-1.269	-0.697	-0.234
o11	-0.155	0.221	0.327	-1.189	0.874	-0.001	-1.143	0.045	0.737	-1.187	-0.706	-0.352
o12	0.018	3.309	-0.923	-1.267	-0.478	-0.258	1.169	0.176	-0.052	0.027	-0.770	0.820
o13	-0.032	0.970	-1.000	-0.534	-0.622	-0.234	0.430	-0.079	0.113	0.292	-0.760	-0.145
o14	-0.154	0.044	-0.596	-1.028	1.579	0.414	-1.193	0.109	-0.066	-0.402	-0.533	-0.039
o15	0.156	0.406	-0.407	-0.177	-0.124	-0.106	-0.952	-0.665	-0.225	-0.682	-0.222	-0.499
o16	-0.169	-0.137	-0.877	-0.333	0.553	0.537	-0.778	1.264	4.268	1.231	-0.476	0.830
o17	0.175	0.200	-0.344	-0.607	-0.622	-0.255	1.169	-0.278	-0.074	-0.164	-0.465	-0.358
o18	-0.071	0.180	-0.393	-0.154	0.656	0.059	-1.158	-0.408	-0.366	-0.558	-0.570	-0.444
o19	-0.179	1.127	-0.150	-1.294	-0.622	-0.222	1.169	-1.241	-0.444	1.102	1.509	3.967
o20	-0.185	-0.089	-0.446	-0.154	-0.440	-0.036	-0.014	-0.367	-0.735	-0.186	-0.152	-0.042
o21	1.110	-0.022	-0.722	-0.388	-0.354	-0.043	-0.816	-2.292	-0.506	-0.369	2.805	0.088
o22	0.151	1.426	-0.267	-0.464	2.042	1.713	-1.022	-0.374	-0.002	1.272	1.625	1.367
o23	-0.066	0.462	-0.759	-0.340	0.544	0.103	0.438	-0.556	-0.616	1.191	0.815	0.088
o24	-0.189	1.077	-0.588	-0.701	0.367	-0.139	-1.092	0.256	-0.377	-0.427	-0.849	-0.255

4.3.2 Normalizácia

Ďalšou úpravou už štandardizovaných dát je normalizácia. Pod pojmom normalizácia sa rozumie transformácia hodnôt danej spojitej premennej tak, aby sa distribúcia premennej priblížila najčastejšie k normálnemu rozdeleniu. Využívajú sa k tomu rôzne transformačné funkcie, ako sú napríklad logaritmická, mocninová, inverzná funkcia a pod. V diplomovej práci je použitá mocninová transformačná funkcia. V tab. 4 je zobrazená ukážka dátovej matice s normalizovanými dátami.

Tab. 4 Vzorka dátovej matice normalizovaných dát

obec	p1	p2	p3	p4	p5	p6	p7	p8	p9	p10	p11	p12
o1	-0.007	0.075	-0.011	-0.060	0.000	0.000	0.050	0.000	-0.036	0.085	0.148	0.002
o2	-0.005	0.429	-0.021	-0.036	0.248	0.110	-0.048	-0.047	-0.037	-0.025	0.055	0.049
o3	-0.009	0.019	-0.039	0.007	-0.026	-0.011	0.050	-0.014	-0.005	-0.025	-0.026	-0.002
o4	-0.008	-0.033	-0.013	-0.002	-0.026	-0.011	-0.052	0.051	-0.034	0.080	0.028	-0.011
o5	0.020	0.123	-0.045	-0.036	0.069	0.008	-0.046	-0.113	-0.028	-0.017	0.143	0.015
o6	-0.008	0.048	-0.007	-0.058	-0.006	-0.007	-0.008	-0.003	-0.027	-0.006	-0.033	-0.032
o7	-0.008	0.015	-0.012	0.004	0.042	-0.005	-0.045	0.016	-0.024	-0.050	-0.036	-0.023
o8	-0.002	0.018	-0.020	-0.002	0.020	0.001	-0.044	-0.012	0.003	-0.005	-0.035	-0.018
o9	-0.008	0.010	-0.030	-0.033	0.233	-0.011	-0.052	0.003	-0.036	0.057	0.088	0.002
o10	-0.010	0.012	0.008	-0.012	-0.026	-0.011	0.050	-0.019	0.057	-0.054	-0.030	-0.010
o11	-0.007	0.009	0.014	-0.050	0.037	-0.000	-0.049	0.002	0.031	-0.050	-0.030	-0.015
o12	0.001	0.140	-0.039	-0.054	-0.020	-0.011	0.050	0.007	-0.002	0.001	-0.033	0.035
o13	-0.001	0.041	-0.042	-0.023	-0.026	-0.010	0.018	-0.003	0.005	0.012	-0.032	-0.006
o14	-0.007	0.002	-0.025	-0.044	0.067	0.018	-0.051	0.005	-0.003	-0.017	-0.023	-0.002
o15	0.007	0.017	-0.017	-0.008	-0.005	-0.005	-0.040	-0.028	-0.010	-0.029	-0.009	-0.021
o16	-0.007	-0.006	-0.037	-0.014	0.023	0.023	-0.033	0.054	0.181	0.052	-0.020	0.035
o17	0.007	0.008	-0.015	-0.026	-0.026	-0.011	0.050	-0.012	-0.003	-0.007	-0.020	-0.015
o18	-0.003	0.008	-0.017	-0.007	0.028	0.002	-0.049	-0.017	-0.016	-0.024	-0.024	-0.019
o19	-0.008	0.048	-0.006	-0.055	-0.026	-0.009	0.050	-0.053	-0.019	0.047	0.064	0.168
o20	-0.008	-0.004	-0.019	-0.007	-0.019	-0.002	-0.001	-0.016	-0.031	-0.008	-0.006	-0.002
o21	0.047	-0.001	-0.031	-0.016	-0.015	-0.002	-0.035	-0.097	-0.021	-0.016	0.119	0.004
o22	0.006	0.061	-0.011	-0.020	0.087	0.073	-0.043	-0.016	-0.000	0.054	0.069	0.058
o23	-0.003	0.020	-0.032	-0.014	0.023	0.004	0.019	-0.024	-0.026	0.051	0.035	0.004
o24	-0.008	0.046	-0.025	-0.030	0.016	-0.006	-0.046	0.011	-0.016	-0.018	-0.036	-0.011

4.3.3 Korelácia

Množina vstupných dát je tvorená zo 452 obcí Pardubického kraja za rok 2006, pričom bonita obce je pre každú obec reprezentovaná 12-timi vstupnými parametrami. K jednotlivým parametrom je uvedený podrobnejší rozbor v kapitole 2. Vzájomná závislosť parametrov, na základe ktorých možno určiť bonitu obcí Pardubického kraja, by nemala dosahovať významných hodnôt. Závislosť parametrov možno vyjadriť pomocou Pearsonovho korelačného koeficientu takto

$$r = \frac{\overline{xy} - \bar{x}\bar{y}}{S_x S_y}. \quad (4.4)$$

Vo vzťahu 4.4 čitateľ reprezentuje výpočet kovariancie a znázorňuje zmenu hodnoty dvoch premenných. Kladná hodnota čitateľa reprezentuje skutočnosť, že sa hodnoty dvoch premenných menia spoločne jedným smerom. Záporná hodnota čitateľa hovorí o tom, že sa hodnoty menia opačným smerom a nula, že k zmene hodnôt dvoch premenných dochádza nezávisle. Vydelením kovariancie štandardnými odchýlkami možno vypočítať korelačný koeficient r . Hodnota tohto koeficientu je v intervale $\langle -1; 1 \rangle$ [16].

4.4 Návrh relácie R

Relácia $R(P \rightarrow \Omega)$ znázorňuje klasifikáciu parametrov $p = (p_1, p_2, p_3, p_4, p_5, p_6, p_7, p_8, p_9, p_{10}, p_{11}, p_{12})$ do troch tried $(\omega_1, \omega_2, \omega_3)$, pričom ω_1 reprezentuje triedu „dobrá“, ω_2 triedu „stredná“ a ω_3 triedu „zlá“. Existuje viac možností ako určiť reláciu $R(P \rightarrow \Omega)$. V diplomovej práci sú uvedené dva spôsoby určenia relácie a to

- určenie relácie R pomocou štatistiky,
- určenie relácie R na základe experta.

4.4.1 Návrh relácie R pomocou experta

Relácia R je navrhnutá na základe poznatkov a pokusov experta. Jej zobrazenie možno vidieť v tab. 5. Stanovenie relácie je realizované na základe experimentálnych pokusov, ktoré zahrňujú generovanie Kohonenových máp v prostredí Matlab Simulink. Táto relácia je poskytnutá expertom. Relácia od experta slúži ako ukážka, ktorej úlohou

je poskytnúť orientačný prehľad jednotlivých funkcií príslušností, resp. funkcií nepríslušností parametrov (p_1, p_2, \dots, p_{12}) pre každú triedu $\omega_1, \omega_2, \omega_3$.

Tab. 5 Relácia R od experta

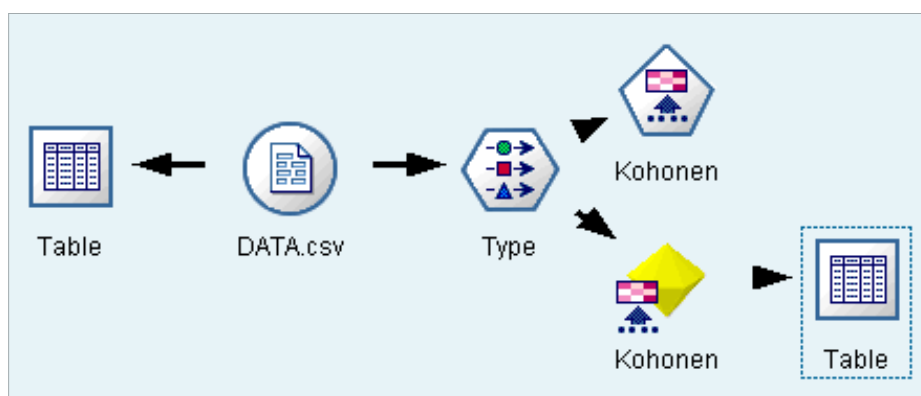
Parametre \ Trieda	dobrá		stredná		zlá	
	μ	ν	μ	ν	μ	ν
P ₁	0,60	0,31	0,40	0,51	0,20	0,71
P ₂	0,70	0,21	0,50	0,41	0,10	0,81
P ₃	0,10	0,81	0,50	0,41	0,80	0,11
P ₄	0,20	0,71	0,40	0,51	0,60	0,31
P ₅	0,10	0,81	0,50	0,41	0,80	0,11
P ₆	0,15	0,76	0,45	0,46	0,80	0,11
P ₇	0,54	0,37	0,50	0,41	0,60	0,31
P ₈	0,80	0,11	0,55	0,36	0,10	0,81
P ₉	0,60	0,31	0,40	0,51	0,20	0,71
P ₁₀	0,60	0,31	0,40	0,51	0,20	0,71
P ₁₁	0,60	0,31	0,40	0,51	0,20	0,71
P ₁₂	0,80	0,11	0,55	0,36	0,10	0,81

4.4.2 Návrh relácie R

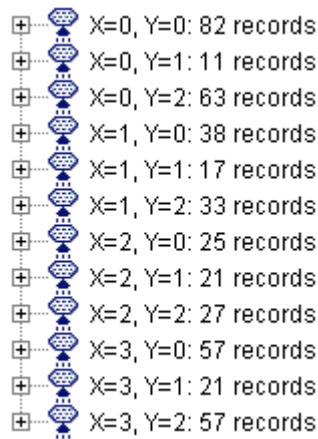
Relácia R je navrhnutá za pomoci softwarovej podpory programov SPSS Clementine a Matlab. Spôsob návrhu relácie R je v nasledujúcej časti tejto kapitoly podrobne spracovaný. Zobrazenie navrhutej relácie R možno vidieť v tab. 6. Vstupnú maticu tvoria normalizované hodnoty z pôvodnej matice o 452 obcí a 12 parametrov. Táto matica je načítaná do programu SPSS Clementine, kde sa uskutočnila kontrola správnosti načítaných údajov. Ďalej bola vytvorená Kohonenova neurónová sieť (ďalej len KNS), čo možno vidieť na obr. 9, ktorá klasifikovala množinu dát do 12 zhlukov, vid' obr. 10 .

Tab. 6 Relácia R

Parametre \ Trieda	dobrá		stredná		zlá	
	μ	ν	μ	ν	μ	ν
P ₁	0,85	0,10	0,67	0,23	0,05	0,85
P ₂	0,82	0,10	0,62	0,28	0,11	0,79
P ₃	0,19	0,71	0,39	0,51	0,94	0,00
P ₄	0,21	0,69	0,45	0,45	0,93	0,00
P ₅	0,17	0,73	0,47	0,43	0,93	0,00
P ₆	0,18	0,72	0,46	0,44	0,94	0,00
P ₇	0,21	0,69	0,44	0,46	0,92	0,00
P ₈	0,82	0,10	0,65	0,25	0,10	0,80
P ₉	0,83	0,10	0,65	0,25	0,06	0,84
P ₁₀	0,80	0,10	0,64	0,26	0,08	0,82
P ₁₁	0,82	0,10	0,64	0,26	0,11	0,79
P ₁₂	0,83	0,10	0,64	0,26	0,11	0,79

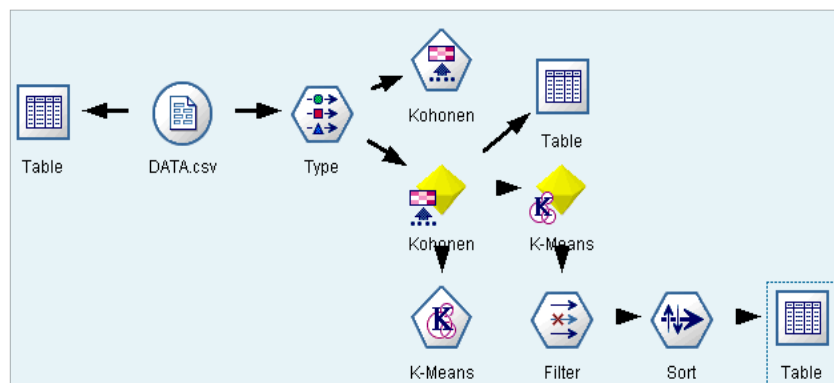


Obr. 9 Vytvorenie Kohonenovej neurónovej siete




Obr. 10 Výsledok rozdelenia množiny dát pomocou KNS

Z obr. 10 možno vidieť, že najpočetnejšie triedy sú štyri, menej početných je šesť a najmenej početné sú dve. Ako ďalší krok je použitá jedna z metód zhukovacej analýzy - algoritmus K-means (vid'. obr. 11) , kde je stanovený pevný počet zhukov 3, keďže cieľom je rozdeliť parametre do 3 tried ($\omega_1, \omega_2, \omega_3$).



Obr. 11 Rozdelenie KNS pomocou algoritmu K-means

Grafické znázornenie rozdelenia obcí do troch tried znázorňuje obr. 12, kde zhuk 1 je tvorený zo 183 záznamov, zhuk 2 zo 149 a zhuk 3 zo 120 záznamov – obcí Pardubického kraja.

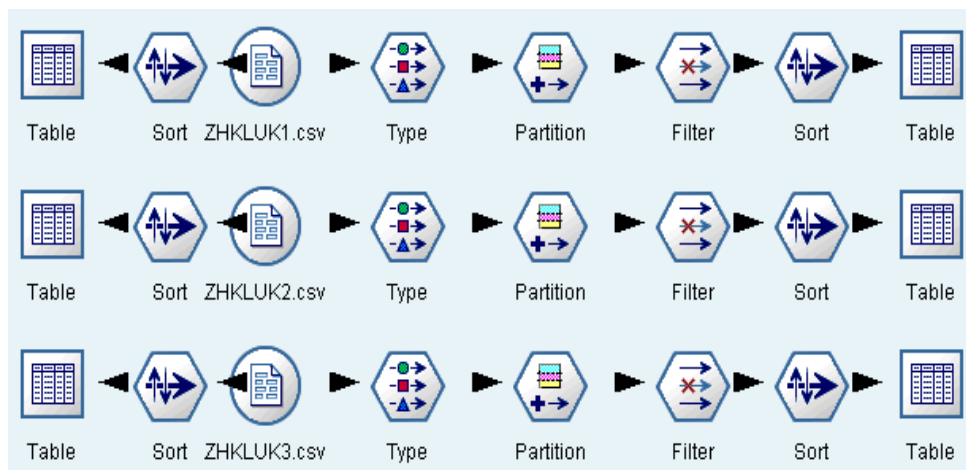


Obr. 12 Zhluky získané pomocou K-means

Algoritmus K-means je použitý z toho dôvodu, že je známy dopredu počet tried, do ktorých je potrebné dáta klasifikovať. Ide o nehierarchické zhlukovanie. Všeobecný postup algoritmu K-means je možné zhrnúť do nasledujúcich krokov

1. Rozdelenie dát do k -tého zhluku, pričom k je vopred definované.
2. Vypočítanie hodnoty centroidu pre jednotlivé zhluky.
3. Pre každý príklad X je potrebné určiť:
 - a) vzdialenosť $d(X, c_k)$, kde c_k – centroid k -tého zhluku
 - b) $d(X, c_i) = \text{MIN } d(X, c_k)$
 - c) Ak nie je X súčasťou zhluku i , kde je vzdialenosť centroidu c_i najmenšia, potom dôjde k presunu X do zhluku i .
4. V prípade, že došlo k presunu, opakuje sa krok 2, inak algoritmus končí.

Po ukončení algoritmu K-means, ktorý rozdelí množinu dát na tri triedy, slúžia tieto rozdelené dáta ďalej ako vstupná množina do programu Matlab, kde sú ďalej spracovávané v prostredí Fuzzy C-means Clustering³ (ďalej už len FCM). Ešte predtým je však nutné určiť výstup za jednotlivé zhluky, čo určujú jednotlivé čísla zhlukov 1,2,3. Následne je táto množina rozdelená na množinu dat tréningových (66%) a testovacích (34%), čo možno vidieť na obr. 13.



Obr. 13 Rozdelenie zhlukov na tréningovú a testovaciu množinu

³ Fuzzy C-means Clustering – Fuzzy zhlukovanie K-priemerov je technika zhlukovania dát, pričom každý bod dát patrí do zoskupenia, do určitej miery, ktorá je určená členstvom triedy, pôvodne zavedená Jimom BEZDĚKOM v roku 1981 [17].

V ďalšej časti tejto kapitoly je popísaná práca v prostredí Matlab, konkrétne v prostredí FCM. Po načítaní tréningových dát dátovej matice za zhluk 1 je zahájený proces učenia – generovania Fuzzy inferenčného systému (ďalej už len FIS), ktorého správnosť učenia je v zápatí pomocou testovacích dát dátovej matice za zhluk 1 otestovaná. Po vygenerovaní FIS nasleduje optimalizácia FIS, a to do tej doby, kým nie je vygenerované iba jedno pravidlo IF→THEN, resp. jedna funkcia príslušnosti. Po vygenerovaní a optimalizácii FIS nasleduje samotné generovanie funkcie príslušnosti pre každý parameter zvlášť. Proces generovania FIS je uskutočnený iteračným spôsobom celkom trikrát, za každý zhluk zvlášť, keďže sú tri triedy, do ktorých má klasifikačný model klasifikovať jednotlivé obce. Konečná podoba funkcií príslušnosti jednotlivých parametrov za všetky obce Pardubického kraja je vykonaná pomocou softwaru Microsoft Excel. Avšak s vygenerovanými jednotlivými funkciami príslušnosti z daných FIS je treba ešte experimentovať a to z hľadiska toho, že samotné generovanie funkcií príslušnosti nedáva odpoveď na otázku, ktorý z FIS 1,2,3 reprezentuje triedu „dobrá“, „stredná“ a ktorý „zlá“, resp. na základe čoho možno povedať, že daný FIS reprezentuje jednu z troch kategórií obcí. Ako prvé sú určené quartily q_0, q_1, q_2, q_3 a q_4 zo všetkých obcí pre každý parameter p_1, p_2, \dots, p_{12} pre každý FIS zvlášť. Avšak problém je v tom, že toto rozdelenie je veľmi zkršľujúce, nakoľko rozdiel funkcie príslušnosti, resp. funkcie nepríslušnosti parametrov medzi strednou a dobrou triedou je takmer zanedbateľný. Je za potreby prehodnotiť stanovenie FIS do troch kategórií. V tomto prípade sú takiež stanovené vyššie uvedené quartily, s rozdielom, že tieto quartily sú určené na celej dátovej matici jednotlivých obcí, teda neberú sa do úvahy jednotlivé zhluky, resp. FIS1, 2 a 3. Ďalej sa vychádza z toho, že interval, v ktorom sa nachádzajú jednotlivé funkcie príslušnosti je $\langle 0;1 \rangle$ a teda jednotlivé quartily reprezentujú $q_0 = 0$, interval $\langle 0; 0,25 \rangle$, $q_1 = 0,25$, interval $\langle 0,25; 0,5 \rangle$, $q_2 = 0,5$, interval $\langle 0,5; 0,75 \rangle$, $q_3 = 0,75$, interval $\langle 0,75; 1 \rangle$ a $q_4 = 1$. Následne je stanovené rozhodnutie, že tie obce, resp. funkcie príslušnosti daných obcí, ktoré budú menšie ako hodnota 0,25 reprezentujú triedu „zlú“, obce v intervale $\langle 0,25; 0,75 \rangle$ reprezentujú triedu „strednú“ a obce, ktorých hodnota funkcie príslušnosti je viac ako 0,75, reprezentujú triedu „dobrú“. Výsledné hodnoty funkcie príslušnosti sú vypočítané ako aritmetický priemer z hodnôt za jednotlivé triedy a sú použité na stanovenie relácie R . Takto sú vypočítané stupne príslušnosti μ relácie R . Jednoduchým doplnkom sú stanovené stupne nepríslušnosti ν relácie R , resp. podľa nasledujúceho vzťahu $\pi = 1 - (\mu + \nu)$; $\nu = 1 - (\mu + \pi)$, kde π predstavuje Intuitionistic index. Jeho hodnota je pevne

daná na $\pi = 0,09$. Popritom je potrebné brať do úvahy, ktoré parametre sú pozitívne, ktoré negatívne. Podľa toho sú totiž prispôsobené aj funkcie príslušnosti, resp. nepríslušnosti za jednotlivé parametre. Pri pozitívnych parametroch je najvyššia hodnota funkcie príslušnosti reprezentovaná v triede „dobrá“, nižšia hodnota v triede „stredná“ a najnižšia v triede „zlá“. Toto neplatí v prípade negatívnych parametrov. V tomto prípade sú parametre stanovené presne opačne, teda najnižšia hodnota funkcie príslušnosti reprezentuje triedu „dobrá“, vyššia, triedu „stredná“ a najvyššia, triedu „zlá“.

4.5 Návrh relácie Q

4.5.1 Relácia Q simulovaných funkcií príslušnosti parametrov

Určenie relácie Q je uskutočnené niekoľkými spôsobmi. V nasledujúcej časti kapitoly diplomovej práce je uvedený spôsob navrhnutia relácie Q , ktorá reprezentuje hodnoty funkcie príslušnosti μ (viď. tab. 7), respektíve hodnoty funkcie nepríslušnosti ν (viď. tab. 8) parametrov obcí, určujúcich bonitu obcí Padubického kraja. Táto relácia Q slúži ako kontrola klasifikačného modelu, či model dokáže urobiť klasifikáciu obcí do troch tried, na základe funkcií príslušnosti, resp. funkcií nepríslušnosti parametrov obcí. Ide o reláciu Q , v ktorej sú hodnoty funkcie príslušnosti, resp. funkcie nepríslušnosti za jednotlivé parametre simulované. To znamená, že jednotlivé obce sú vopred zaradené do triedy „dobrá“, „stredná“ a „zlá“ podľa stupňa príslušnosti, resp. nepríslušnosti. Teda v tomto prípade nejde o skutočné hodnoty funkcie príslušnosti relácie Q , resp. funkcie nepríslušnosti. Ide o overenie, či je daný model schopný správne zaradiť vybrané obce do tried aj po uskutočnení kompozície $T = R \circ Q$. IFR R a Q .

Tab. 7 Relácia $Q(\mu)$ simulovaných funkcií príslušnosti parametrov obcí

Parametre Obce	p_1	p_2	p_3	p_4	p_5	p_6	p_7	p_8	p_9	p_{10}	p_{11}	p_{12}
O_1	0,88	0,92	0,12	0,01	0,08	0,06	0,13	0,86	0,88	0,91	0,89	0,86
O_2	0,51	0,58	0,37	0,29	0,44	0,43	0,36	0,53	0,6	0,57	0,52	0,50
O_3	0,58	0,51	0,37	0,29	0,38	0,41	0,36	0,48	0,6	0,47	0,52	0,57
O_4	0,14	0,18	0,75	0,8	0,84	0,88	0,83	0,15	0,11	0,06	0,09	0,13
O_5	0,62	0,52	0,33	0,37	0,44	0,31	0,36	0,53	0,48	0,57	0,51	0,50
O_6	0,13	0,14	0,73	0,83	0,75	0,88	0,76	0,11	0,09	0,07	0,11	0,06
O_7	0,50	0,53	0,31	0,34	0,44	0,43	0,36	0,52	0,58	0,54	0,62	0,51
O_8	0,78	0,83	0,01	0,02	0,05	0,06	0,03	0,88	0,86	0,91	0,79	0,92
O_9	0,57	0,52	0,43	0,36	0,41	0,38	0,31	0,58	0,54	0,62	0,47	0,51
O_{10}	0,14	0,18	0,75	0,8	0,85	0,82	0,84	0,03	0,13	0,08	0,15	0,11
O_{11}	0,09	0,13	0,77	0,85	0,84	0,75	0,80	0,18	0,08	0,15	0,11	0,03
O_{12}	0,89	0,88	0,08	0,12	0,00	0,05	0,06	0,88	0,78	0,91	0,90	0,86
O_{13}	0,57	0,52	0,41	0,36	0,38	0,31	0,29	0,47	0,48	0,51	0,58	0,54

Legenda

	<i>dobrá</i>
	<i>stredná</i>
	<i>zlá</i>

Tab. 8 Relácia $Q(\nu)$ simulovaných funkcií nepríslušnosti parametrov obcí

Parametre Obce	p_1	p_2	p_3	p_4	p_5	p_6	p_7	p_8	p_9	p_{10}	p_{11}	p_{12}
O_1	0,03	0,00	0,79	0,90	0,83	0,85	0,78	0,05	0,03	0,00	0,02	0,05
O_2	0,40	0,33	0,54	0,62	0,47	0,48	0,55	0,38	0,31	0,34	0,39	0,41
O_3	0,33	0,40	0,54	0,62	0,53	0,50	0,55	0,43	0,31	0,44	0,39	0,34
O_4	0,77	0,73	0,16	0,11	0,07	0,03	0,08	0,76	0,80	0,85	0,82	0,78
O_5	0,29	0,39	0,58	0,54	0,47	0,60	0,55	0,38	0,43	0,34	0,40	0,41
O_6	0,78	0,77	0,18	0,08	0,16	0,03	0,15	0,80	0,82	0,84	0,80	0,85
O_7	0,41	0,38	0,60	0,57	0,47	0,48	0,55	0,39	0,33	0,37	0,29	0,40
O_8	0,13	0,08	0,90	0,89	0,86	0,85	0,88	0,03	0,05	0,00	0,12	0,00
O_9	0,34	0,39	0,48	0,55	0,50	0,53	0,60	0,33	0,37	0,29	0,44	0,40
O_{10}	0,77	0,73	0,16	0,11	0,06	0,09	0,07	0,88	0,78	0,83	0,76	0,80
O_{11}	0,82	0,78	0,14	0,06	0,07	0,16	0,11	0,73	0,83	0,76	0,80	0,88
O_{12}	0,02	0,03	0,83	0,79	0,92	0,86	0,85	0,03	0,13	0,00	0,01	0,05
O_{13}	0,34	0,39	0,50	0,55	0,53	0,60	0,62	0,44	0,43	0,40	0,33	0,37

Legenda

	<i>dobrá</i>
	<i>stredná</i>
	<i>zlá</i>

4.5.2 Relácia Q

Spôsob určenia je analogický ako v prípade určenia relácie R . Aj v prípade určenia relácie Q je základom vytvorenie FIS. Ešte pred samotnou tvorbou FIS je dátová matica normalizovaných dát, reprezentujúcich obce Pardubického kraja a parametre určujúce bonitu obcí, klasifikovaná pomocou KNS. Výsledkom klasifikácie pomocou KNS je počet zhlukov, ktorých je presne toľko, koľko je parametrov, teda 12. Po tomto procese je použitá metóda z oblasti zhlukovej analýzy - zhlukovací algoritmus K-means, kde je nastavený pevný počet zhlukov – tri, pre reprezentáciu jednotlivých tried „dobrá“, „stredná“, „zlá“. Takto pripravené 3 triedy sú použité v Matlabe v prostredí Fuzzy clustering a postupne sú za jednotlivé zhluky (triedy) určené jednotlivé FIS. Tieto sú ďalej upravované dovedty, kým nie je vygenerované iba jedno pravidlo, resp. jedna funkcia príslušnosti. Výsledné funkcie príslušnosti sú tak isto ako v prípade relácie R spracované pomocou softwaru Microsoft Excel. V tab. 9 a v tab. 10 sú zobrazené výsledné hodnoty funkcie príslušnosti, resp. hodnoty funkcie nepríslušnosti.

Tab. 9 Relácia $Q(\mu)$

Parametre Obce	p_1	p_2	p_3	p_4	p_5	p_6	p_7	p_8	p_9	p_{10}	p_{11}	p_{12}
O_1	0,99	0,00	0,37	0,67	0,00	0,00	0,00	0,48	0,97	0,26	0,81	0,99
O_2	0,99	1,00	0,00	0,00	0,00	0,00	0,00	0,94	1,00	0,87	0,98	1,00
O_3	1,00	0,84	0,00	0,00	0,00	0,26	0,07	0,86	1,00	0,95	0,68	0,85
O_4	0,37	0,61	0,67	0,23	0,00	0,56	0,88	0,44	0,99	0,66	0,00	0,35
O_5	0,00	0,26	0,00	0,74	0,00	0,00	0,00	0,53	0,17	0,21	0,44	0,84
O_6	0,92	0,25	0,00	0,56	0,03	0,02	0,10	0,89	0,89	0,06	0,91	0,66
O_7	1,00	0,94	0,03	0,15	0,00	0,09	0,39	0,74	0,99	0,76	0,86	0,80
O_8	0,99	1,00	0,00	0,00	0,00	0,00	0,00	0,86	1,00	0,91	1,00	1,00
O_9	1,00	1,00	0,00	0,00	0,00	0,00	0,00	1,00	1,00	1,00	1,00	1,00
O_{10}	1,00	0,91	0,00	0,00	0,12	0,00	0,03	0,96	1,00	1,00	0,99	0,99
O_{11}	1,00	1,00	0,00	0,00	0,00	0,00	0,00	1,00	0,99	0,89	0,88	1,00
O_{12}	1,00	0,88	0,18	0,08	0,12	0,00	0,00	0,80	0,99	0,99	0,59	1,00
O_{13}	0,88	0,58	0,00	0,87	0,09	0,09	0,78	0,93	0,07	0,00	0,82	0,21

Tab. 10 Relácia Q(v)

Parametre Obce	p ₁	p ₂	p ₃	p ₄	p ₅	p ₆	p ₇	p ₈	p ₉	p ₁₀	p ₁₁	p ₁₂
O ₁	0,00	0,91	0,54	0,24	0,96	0,98	0,95	0,43	0,00	0,65	0,10	0,00
O ₂	0,00	0,0	1,00	0,99	0,96	1,00	0,95	0,00	0,00	0,04	0,00	0,00
O ₃	0,00	0,07	0,93	0,94	1,00	0,65	0,84	0,05	0,00	0,00	0,23	0,06
O ₄	0,54	0,30	0,24	0,68	0,98	0,35	0,03	0,47	0,00	0,25	0,91	0,56
O ₅	0,91	0,65	0,99	0,17	1,00	0,99	1,00	0,38	0,74	0,70	0,47	0,07
O ₆	0,00	0,66	0,96	0,35	0,88	0,89	0,81	0,02	0,02	0,85	0,00	0,25
O ₇	0,00	0,00	0,88	0,76	1,00	0,82	0,52	0,17	0,00	0,15	0,05	0,11
O ₈	0,00	0,00	0,99	1,00	1,00	1,00	0,95	0,05	0,00	0,00	0,00	0,00
O ₉	0,00	0,00	1,00	1,00	1,00	1,00	1,00	0,00	0,00	0,00	0,00	0,00
O ₁₀	0,00	0,00	0,94	0,99	0,79	0,99	0,88	0,00	0,00	0,00	0,00	0,00
O ₁₁	0,00	0,00	1,00	0,97	0,97	0,99	0,97	0,00	0,00	0,02	0,03	0,00
O ₁₂	0,00	0,03	0,73	0,83	0,79	1,00	0,95	0,00	0,00	0,00	0,32	0,00
O ₁₃	0,03	0,03	0,95	0,04	0,82	0,82	0,13	0,00	0,84	0,91	0,09	0,70

Rozdiel stanovenia relácie Q oproti stanoveniu relácie R , je v tom, že v prípade relácie R , je potrebné nájsť jeden ukazovateľ, ktorý by reprezentoval všetky funkcie príslušnosti za daný parameter. V tomto prípade stačia vygenerované jednotlivé funkcie príslušnosti za každý parameter zvlášť u každého FIS. Opäť sú jednoduchým spôsobom – doplnkom vypočítané hodnoty funkcie nepríslušnosti. Aj v tomto prípade je potrebné brať do úvahy nasledujúci vzťah $\pi = 1 - (\mu + \nu)$; $\nu = 1 - (\mu + \pi)$, z ktorého sú vypočítané hodnoty funkcie nepríslušnosti. V záverečnej kapitole 5 sú porovnané jednotlivé relácie, spôsob stanovenia ich funkcií príslušnosti, resp. funkcií nepríslušnosti. Ďalej sú analyzované dosiahnuté výsledky klasifikátora obcí Pardubického kraja, ktoré sú prezentované grafickou formou.

4.5.3 Stanovenie relácie Q pomocou štatistiky

Relácia Q pomocou štatistiky je určená tak, že najprv sú vypočítané štatistické ukazovatele ako sú minimum, maximum, variačné rozpätie a absolútna hodnota z minima za každý parameter a to podľa vzorca:

$$Q_{\mu} = \frac{\text{hodnota parametru za jednotlivú obec} - \text{absMIN za každý parameter}}{\text{variačné rozpätie hodnoty parametru}}, \quad (4.5)$$

je určený stupeň funkcie príslušnosti, resp. funkcie nepríslušnosti pre danú obec za každý parameter p_1, p_2, \dots, p_{12} . Intuitionistic index π je opäť stanovený ako pevná hodnota $\pi = 0,09$. Jednoduchým doplnkom sú vypočítané funkcie nepríslušnosti ν podľa

existujúceho vzťahu $\pi = 1 - (\mu + \nu)$; $\nu = 1 - (\mu + \pi)$. Tie parametre, ktoré sú negatívne t.j. p_3, p_4, p_5, p_6 a p_7 , majú zamenené hodnoty $Q(\mu)$, μ za ν a naopak pri $Q(\nu)$ ν za μ . Ukážku výsledných hodnôt funkcie príslušnosti μ , resp. funkcie nepríslušnosti ν možno vidieť prostredníctvom tab. 11, tab. 12.

Tab. 11 Stanovenie relácie $Q(\mu)$ pomocou štatistiky

Parametre Obce	p_1	p_2	p_3	p_4	p_5	p_6	p_7	p_8	p_9	p_{10}	p_{11}	p_{12}
O_1	0,18	0,71	0,48	0,59	0,52	0,68	0,57	0,41	0,56	0,18	0,41	0,28
O_2	0,25	0,58	0,51	0,47	0,30	0,58	0,42	0,45	0,62	0,40	0,57	0,38
O_3	0,21	0,73	0,60	0,61	0,39	0,27	0,18	0,74	0,59	0,45	0,32	0,22
O_4	0,24	0,37	0,55	0,45	0,51	0,50	0,91	0,72	0,55	0,44	0,04	0,14
O_5	0,28	0,67	0,67	0,64	0,53	0,68	0,20	0,41	0,74	0,34	0,41	0,36
O_6	0,18	0,68	0,69	0,57	0,60	0,73	0,12	0,62	0,58	0,41	0,21	0,22
O_7	0,24	0,47	0,33	0,30	0,35	0,37	0,64	0,81	0,56	0,70	0,44	0,53
O_8	0,26	0,54	0,52	0,51	0,39	0,58	0,42	0,39	0,62	0,42	0,65	0,38
O_9	0,21	0,57	0,48	0,51	0,38	0,59	0,34	0,56	0,60	0,53	0,63	0,36
O_{10}	0,22	0,69	0,59	0,55	0,20	0,63	0,47	0,48	0,59	0,52	0,58	0,40
O_{11}	0,22	0,55	0,48	0,45	0,32	0,55	0,40	0,55	0,63	0,41	0,45	0,37
O_{12}	0,23	0,71	0,72	0,68	0,19	0,61	0,42	0,77	0,62	0,49	0,27	0,34
O_{13}	0,15	0,22	0,60	0,74	0,61	0,74	0,40	0,60	0,79	0,55	0,18	0,15

Tab. 12 Stanovenie relácie $Q(\nu)$ pomocou štatistiky

Parametre Obce	p_1	p_2	p_3	p_4	p_5	p_6	p_7	p_8	p_9	p_{10}	p_{11}	p_{12}
O_1	0,73	0,20	0,43	0,32	0,39	0,23	0,34	0,50	0,35	0,73	0,50	0,63
O_2	0,66	0,33	0,40	0,44	0,61	0,33	0,49	0,46	0,29	0,51	0,34	0,53
O_3	0,70	0,18	0,31	0,30	0,52	0,64	0,73	0,17	0,32	0,46	0,59	0,69
O_4	0,67	0,54	0,36	0,46	0,40	0,41	0,00	0,19	0,36	0,47	0,87	0,77
O_5	0,63	0,24	0,24	0,27	0,38	0,23	0,71	0,50	0,17	0,57	0,50	0,55
O_6	0,73	0,23	0,22	0,34	0,31	0,18	0,79	0,29	0,33	0,50	0,70	0,69
O_7	0,67	0,44	0,58	0,61	0,56	0,54	0,27	0,10	0,35	0,21	0,47	0,38
O_8	0,65	0,37	0,39	0,40	0,52	0,33	0,49	0,52	0,29	0,49	0,26	0,53
O_9	0,70	0,34	0,43	0,40	0,53	0,32	0,57	0,35	0,31	0,38	0,28	0,55
O_{10}	0,69	0,22	0,32	0,36	0,71	0,28	0,44	0,43	0,32	0,39	0,33	0,51
O_{11}	0,69	0,36	0,43	0,46	0,59	0,36	0,51	0,36	0,28	0,50	0,46	0,54
O_{12}	0,68	0,20	0,19	0,23	0,72	0,30	0,49	0,14	0,29	0,42	0,64	0,57
O_{13}	0,76	0,69	0,31	0,17	0,30	0,17	0,51	0,31	0,12	0,36	0,73	0,76

4.6 Kompozícia relácií R a Q

4.6.1 Aplikácia teórie IFM

Princíp kompozície relácií R a Q je uvedený na základe aplikácie teórie IFM v [12],[13] a to vo vzťahu k modelovaniu bonity obcí pomocou klasifikátora. Klasifikácia obcí môže byť definovaná takto:

Nech $o_i^t \in O$ je i -tý objekt, $P = \{p_1^t, p_2^t, \dots, p_k^t, \dots, p_m^t\}$ sú parametre a $\omega_{i,j}^t \in \Omega$ je j -tá trieda zaradená do i -tého objektu $o_i^t \in O$. Potom možno definovať Intuitionistic bázu znalostí bonity obcí pre klasifikáciu ako IFR [14].

Nech A je IFM parametrov P a R je IFR, $R(P \rightarrow \Omega)$. Potom max-min-max kompozícia B IFM A s IFR $R(P \rightarrow \Omega)$ označená ako $B = A \circ R$ znamená stav objektu $o_i^t \in O$ vo vzťahu k triede ako IFM B $\omega_{i,j}^t \in \Omega$ s funkciou príslušnosti, ktorá dáva nasledujúci vzťah

$$\mu_B(\omega_{i,j}^t) = \bigvee_{p_k^t \in P} [\mu_A(p_k^t) \wedge \mu_R(p_k^t, \omega_{i,j}^t)], \quad (4.6)$$

a funkciou nepríslušnosti

$$\nu_B(\omega_{i,j}^t) = \bigwedge_{p_k^t \in P} [\nu_A(p_k^t) \vee \nu_R(p_k^t, \omega_{i,j}^t)], \quad \forall \omega_{i,j}^t \in \Omega. \quad (4.7)$$

Ak je stav daného objektu $o_i^t \in O$ popísaný ako IFM A parametrov $P = \{p_1^t, p_2^t, \dots, p_k^t, \dots, p_m^t\}$, potom je predpoklad, že objekt $o_i^t \in O$ je pridelený do tried $\omega_{i,j}^t \in \Omega$ IFM B , prostredníctvom IFR R Intuitionistic báze modelovania obcí z P do Ω , $R(P \rightarrow \Omega)$. Ďalej nech je daný počet n objektov $o_i^t \in O$, $i = 1, 2, \dots, n$ a nech R je IFR $R(P \rightarrow \Omega)$. Potom IFR Q je vytvorená z množiny objektov $o_i^t \in O$ na množinu parametrov P , $Q(O \rightarrow P)$. Kompozícia T z IFR R a Q , $T = R \circ Q$ opisuje situáciu v oblasti $o_i^t \in O$ z hľadiska tried $\omega_{i,j}^t \in \Omega$ ako IFR z O do Ω , $T(O \rightarrow \Omega)$, ktorá je daná funkciou príslušnosti

$$\mu_T(o_i^t, \omega_{i,j}^t) = \bigvee_{p_k^t} [\mu_Q(o_i^t, p_k^t) \wedge \mu_R(p_k^t, \omega_{i,j}^t)], \quad (4.8)$$

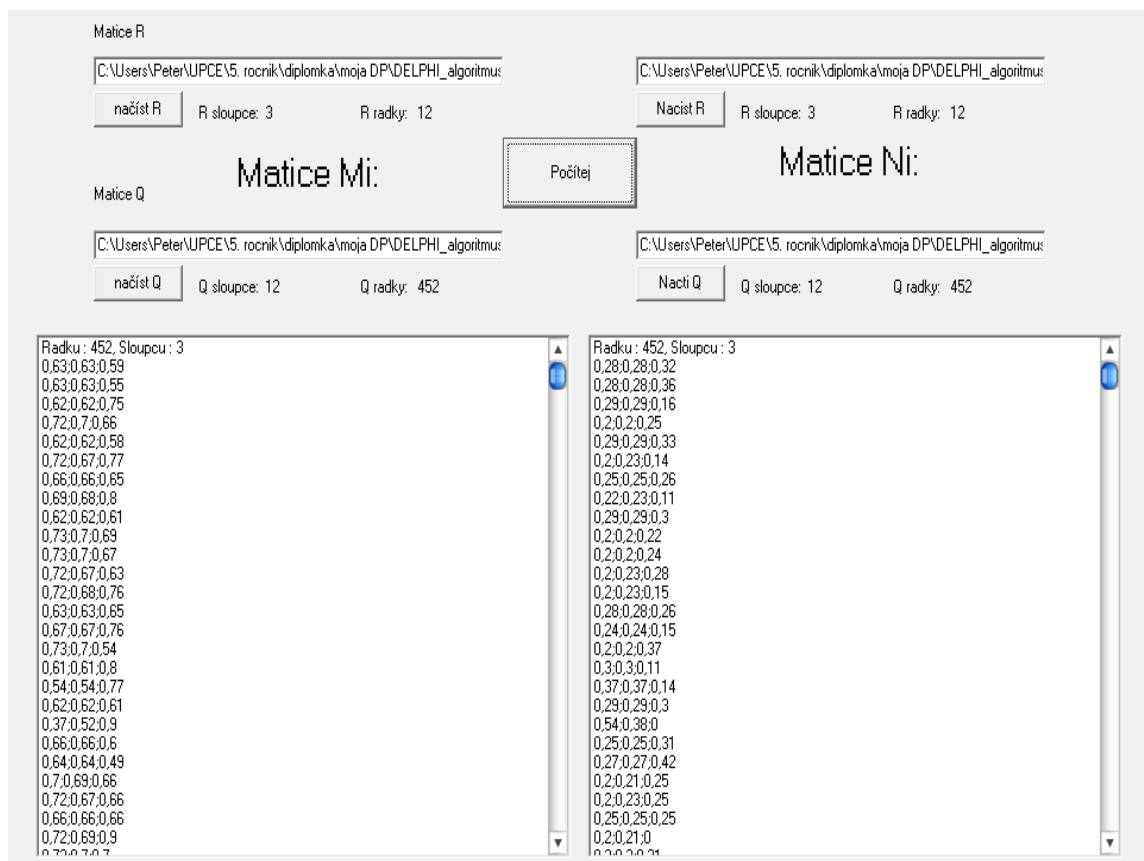
a funkciou nepríslušnosti

$$\nu_T(o_i^t, \omega_{i,j}^t) = \bigwedge_{p_k^t} [\nu_Q(o_i^t, p_k^t) \vee \nu_R(p_k^t, \omega_{i,j}^t)], \quad (4.9)$$

$$\forall o_i^t \in O \text{ a } \omega_{i,j}^t \in \Omega.$$

4.6.2 Algoritmus kompozície relácií R a Q pre modelovanie obcí

Kompozícia relácií R a Q je vytvorená v integrovanom grafickom vývojovom prostredí Delfi od firmy Borland v jazyku Object Pascal. Táto kompozícia je opakovaná iteračným spôsobom dovtedy, kým sa nedosiahne najlepší výsledok klasifikácie obcí do troch tried, to znamená, že klasifikátor bude schopný jednoznačne zaradiť jednotlivé obce do tried „dobrá“, „stredná“ a „zlá“ na základe kompozície dvoch IFR R a Q . Grafické prostredie, v ktorom je uskutočnená kompozícia relácií R a Q je zobrazené na obr. 14. Aj napriek iteračným pokusom, ktoré sú uskutočnené, nie je možné dosiahnuť „najlepšie“ zaradenie do tried. Na základe expertného posudku je udaný ako hlavný dôvod nedostačujúci počet tried. V prípade, že by bola klasifikácia realizovaná do väčšieho počtu tried, klasifikátor by mal byť schopný zaradiť jednotlivé obce do tried. Na obr. 15 je zobrazený zdrojový kód, podľa ktorého je iteračným spôsobom uskutočňovaný proces kompozície.



Obr. 14 Grafické prostredie pre výpočet kompozície

```

for cntrX := 1 to MaticeR.sloupce do
for cntrZ := 1 to MaticeQ.radky do
  begin
    for cntrY := 1 to MaticeR.radky do
      begin
        s1 := floattostr(MaticeR.value[cntrY,cntrX]);
        s2 := floattostr(MaticeQ.value[cntrZ,cntrY]);
        if s1 < s2 then begin
          minima[pocetMinim]:=MaticeR.value[cntrY,cntrX];
        end else begin
          minima[pocetMinim]:=MaticeQ.value[cntrZ,cntrY];
        end;

        s1 := floattostr(MaticeRni.value[cntrY,cntrX]);
        s2 := floattostr(MaticeQni.value[cntrZ,cntrY]);
        if s1 < s2 then begin
          maxima[pocetMaxim]:=MaticeQni.value[cntrZ,cntrY];
        end else begin
          maxima[pocetMaxim]:=MaticeRni.value[cntrY,cntrX];
        end;
        inc(pocetMinim); //zvysi sa hodnota o jedna
        inc(pocetMaxim);
      end;
      maximum := -maxint;
      minimum := maxint;

      // vyber maxima z minim
      for cntrMin := 1 to pocetMinim-1 do
        if maximum<minima[cntrMin] then maximum := minima[cntrMin];
        // vyber minima z maxim
      for cntrMax := 1 to pocetMaxim-1 do
        if minimum>maxima[cntrMax] then minimum := maxima[cntrMax];

```

```

//zapis maxima do matice minim
MaticeV.value[ctrZ,ctrX] := maximum;
MaticeV.radky := ctrZ;
MaticeV.sloupce := ctrX;

//zapis minima do matice maxim
MaticeVni.value[ctrZ,ctrX] := minimum;
MaticeVni.radky := ctrZ;
MaticeVni.sloupce := ctrX;

//Vymazani minim a maxim
for ctrMin := 1 to MaxMat do minima[ctrMin]:=0;
pocetMinim:=1;
for ctrMax := 1 to MaxMat do maxima[ctrMax]:=0;
pocetMaxim:=1;

end;

```

Obr. 15 Zdrojový kód algoritmu kompozície

Ukážku kompozície možno vidieť prostredníctvom tab. 13. V záverečnej kapitole diplomovej práce je graficky aj slovne zhodnotená ako kompozícia relácií R a Q , tak aj asociácia týchto relácií, na základe nie niekoľkých iteračných pokusoch.

Tab. 13 Kompozícia $T = R \circ Q$ z relácie R a Q simulovaných funkcií

Triedy Obce	dobrá		stredná		zlá	
	μ	ν	μ	ν	μ	ν
O_1	0,92	0,00	0,57	0,33	0,13	0,78
O_2	0,60	0,31	0,55	0,35	0,44	0,47
O_3	0,60	0,31	0,57	0,33	0,41	0,50
O_4	0,18	0,73	0,57	0,33	0,88	0,03
O_5	0,62	0,29	0,57	0,33	0,44	0,47
O_6	0,14	0,77	0,57	0,33	0,88	0,03
O_7	0,62	0,29	0,55	0,35	0,44	0,47
O_8	0,92	0,00	0,57	0,33	0,11	0,79
O_9	0,62	0,29	0,57	0,34	0,43	0,48
O_{10}	0,18	0,73	0,57	0,33	0,85	0,06
O_{11}	0,18	0,73	0,57	0,33	0,85	0,06
O_{12}	0,90	0,00	0,57	0,33	0,12	0,79
O_{13}	0,58	0,33	0,57	0,34	0,41	0,50

4.7 Výsledná asociácia

Záverečným bodom celej kompozície relácií R a Q , $T = R \circ Q$ je vyzdvihnutie vysokých hodnôt a potlačenie nízkych hodnôt, teda stanovenie asocičného indexu podľa vzťahu [14]

$$\xi_T = \mu_T(O_i^t, \omega_{i,j}^t) - \nu_T(O_i^t, \omega_{i,j}^t) \times \pi_T(O_i^t, \omega_{i,j}^t) \quad (4.10)$$

pre jednotlivé obce Pardubického kraja. Asocičný index podáva komplexné zhodnotenie jednotlivých funkcií príslušností μ , resp. funkcií nepríslušností ν po vykonaní kompozície relácií R a Q . Ukážku výslednej asociácie pre vybrané obce Pardubického kraja možno vidieť prostredníctvom tab. 14. Proces kompozície a asociácie je uskutočnený niekoľko krát iteračným spôsobom, pričom hlavným cieľom je nájsť vyhovujúce riešenie, t.j. také, ktoré jednoznačne dokáže, že klasifikátor je schopný zaradiť obce Pardubického kraja do troch tried.

Tab. 14 Asociácia kompozície T

Obce \ Triedy	dobrá	stredná	zlá
O_1	0,92	0,54	0,06
O_2	0,57	0,52	0,40
O_3	0,57	0,54	0,37
O_4	0,11	0,54	0,88
O_5	0,59	0,54	0,40
O_6	0,07	0,54	0,88
O_7	0,59	0,52	0,40
O_8	0,92	0,54	0,04
O_9	0,59	0,54	0,39
O_{10}	0,11	0,54	0,84
O_{11}	0,11	0,54	0,84
O_{12}	0,90	0,54	0,05
O_{13}	0,55	0,54	0,37

Legenda

	<i>dobrá</i>
	<i>stredná</i>
	<i>zlá</i>

Z tab. 14. možno povedať, že klasifikátor roztriedil obce (O_1, O_2, \dots, O_{13}) do jednotlivých tried „dobrá“, „stredná“ a „zlá“ na základe parametrov, ktoré vplývajú na danú obec, či už pozitívne, resp. negatívne.

4.8 Zhrnutie kapitoly

Kapitola je zameraná na návrh klasifikátora, pomocou ktorého možno klasifikovať obce Pardubického kraja do troch tried. Metóda, ktorá je použitá pre modelovanie bonity obcí vychádza z teórie fuzzy množín. Jedná sa o špecifickú fuzzy množinu – IFM. Základom použitia tejto metódy je stanovenie IFR R a Q . Následne je vykonaná kompozícia $T = R \circ Q$ relácií R a Q a výsledné hodnoty sú vyzdvihnuté, resp. potlačené pomocou asociačného indexu ξ_T . V každej podkapitole je uvedená daná problematika ako na základe teoretických poznatkov a vzťahov, tak aj praktickou ukážkou, formou tabuliek. Pokusov, ktoré sú vykonané s IFR R a Q je niekoľko, z nich najlepší je v poslednej kapitole diplomovej práce prezentovaný a to opäť ako slovne, tak aj graficky.

5. Závěrečná analýza

Cieľom tejto kapitoly je urobiť záverečný rozbor výsledkov, ktoré sú dosiahnuté počas niekoľkých pokusov s reláciami R a Q . Úlohou je klasifikovať jednotlivé obce Pardubického kraja do troch tried. Návrh klasifikátora je uskutočnený pomocou IFR R a Q . Správne zostavenie IFR R a Q možno posúdiť, až po vykonaní algoritmu – kompozície týchto relácií, teda po klasifikovaní obcí do troch tried. Pokusy sú opakované dovtedy, kým klasifikátor nie je schopný zaradiť obce do tried. V ďalšej časti diplomovej práce sú grafickou formou prezentované výsledky pokusov. Klasifikácia obcí do jednotlivých tried je nakoniec realizovaná pomocou relácie R , vid'. tab. 6, a Q , vid'. tab. 11, tab. 12. Tieto relácie sa osvedčili v procese klasifikácie ako najlepšie. Grafické zobrazenie záverečných výsledkov ponúka obrázová reprezentácia, ktorej výsledky sú spracované v nasledujúcej časti.

5.1 Asociácia simulovaných obcí

Spôsob určenia ako aj návrh a zdôvodnenie návrhu daných relácií je charakterizovaný v predchádzajúcej kapitole 4. Cieľom záverečnej kapitoly je podať súhrnný prehľad výsledných asociácií, graficky znázorniť klasifikované obce podľa navrhnutého klasifikátora pomocou využitia fuzzy množín – IFM.

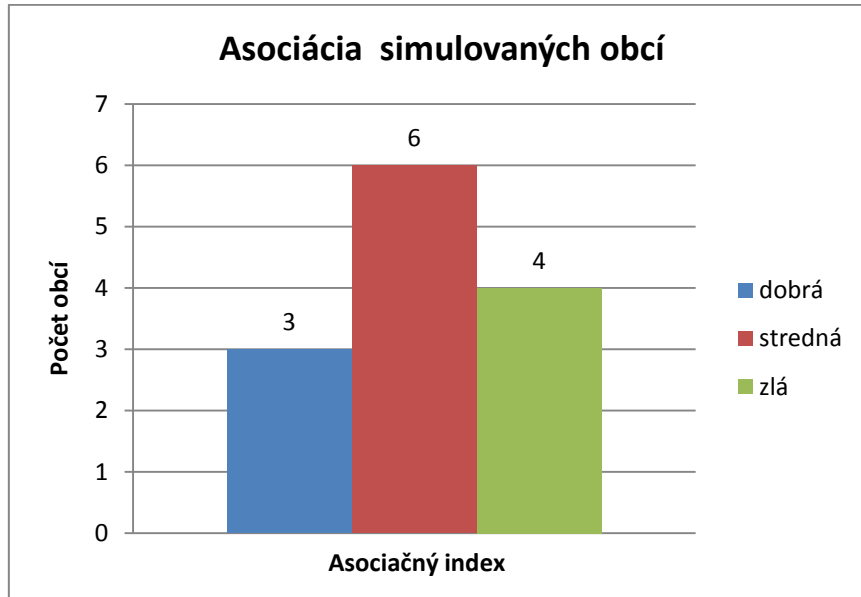
V tab. 15 je vidieť, že klasifikátor klasifikoval obce do príslušných tried tak ako sú stanovené v tab. 7, tab. 8. Ďalej je zrejmé, že obce O_1, O_8 a O_{12} patria do „dobrej“ triedy. Tento výsledok klasifikácie však nie je zapríčinený vplyvom jednotlivých parametrov p_1, p_2, \dots, p_{12} . Už z názvu podkapitoly – *Asociácia simulovaných obcí* je evidentné, že sa jedná iba o nástrel funkcií príslušnosti, resp. nepríslušnosti parametrov v rámci relácie Q . Čo sa týka relácie R , je použitá už v práci uvedená relácia, vid'. tab. 6. To isté platí aj o ďalších obciach, ktorých funkcie príslušností, resp. funkcie nepríslušností sú tiež výsledkom nástrelu, ktorý slúži k overeniu, či navrhnutý klasifikátor je schopný zaradiť tieto obce do daných tried. Výsledky zobrazuje tab. 15, graf 1.

Tab. 15 Asociácia nasimulovaných obcí

Triedy Obce	dobrá	stredná	zlá
O ₁	0,84	0,65	0,06
O ₂	0,57	0,57	0,40
O ₃	0,57	0,57	0,37
O ₄	0,15	0,43	0,88
O ₅	0,59	0,59	0,40
O ₆	0,15	0,43	0,88
O ₇	0,59	0,59	0,40
O ₈	0,82	0,65	0,04
O ₉	0,59	0,59	0,39
O ₁₀	0,15	0,43	0,84
O ₁₁	0,15	0,43	0,84
O ₁₂	0,84	0,65	0,05
O ₁₃	0,55	0,55	0,37

Legenda

	<i>dobrá</i>
	<i>stredná</i>
	<i>zlá</i>



Graf 1 Asociácia simulovaných obcí

5.2 Asociácia obcí

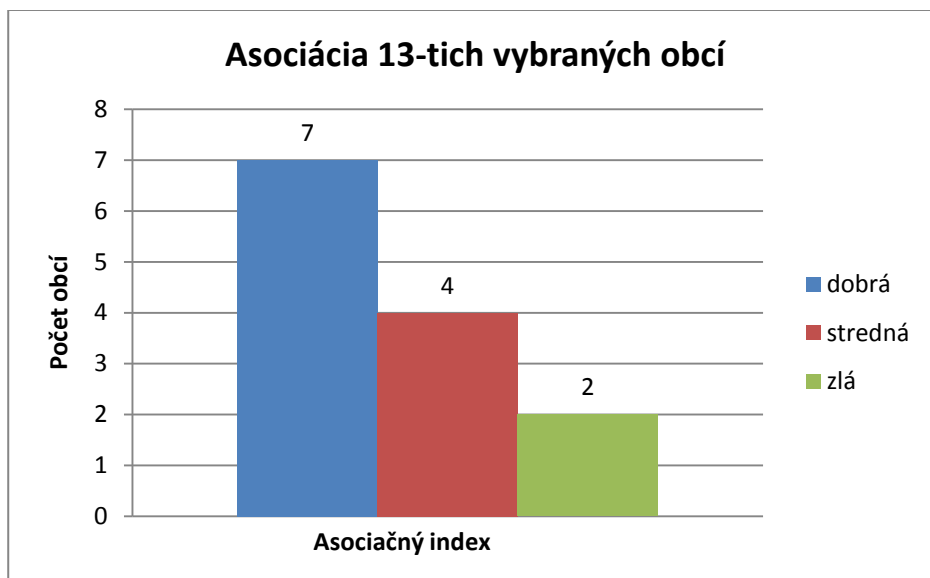
Hodnoty, ktoré poskytuje tab. 16, sú výsledkami viacerých pokusov s reláciami R a Q . Podrobnejšie sú jednotlivé relácie charakterizované v kapitole 4 diplomovej práce. Cieľom záverečnej asociácie je prezentovať výsledky klasifikátora, ktorý je navrhnutý za pomoci využitia poznatkov IFM a aplikáciou IFR. Z tab. 16 je zrejmé, že klasifikátor je schopný klasifikovať obce do troch tried „dobrá“, „stredná“ a „zlá“ a to na základe kompozície relácií R , vid'. tab. 6 a relácie Q , vid'. tab. 11, tab. 12. V tomto prípade sa však nejedná o reláciu Q *simulovaných funkcií príslušnosti parametrov*. Ide o reláciu Q , vid'. tab. 11, tab. 12, ktorá je určená pomocou štatistiky, teda výsledky zaradenia jednotlivých obcí do tried sú závislé na parametroch, ktoré na ne pôsobia, či už pozitívne alebo negatívne. Výsledky sú opäť prezentované ako formou tabuľky (tab. 16), tak graficky (graf 2).

Tab. 16 Asociácia obcí

Triedy Obce	dobrá	stredná	zlá
O_1	0,69	0,59	0,66
O_2	0,59	0,59	0,55
O_3	0,72	0,63	0,58
O_4	0,70	0,63	0,91
O_5	0,72	0,63	0,66
O_6	0,66	0,59	0,71
O_7	0,80	0,63	0,62
O_8	0,63	0,63	0,55
O_9	0,60	0,60	0,56
O_{10}	0,67	0,59	0,60
O_{11}	0,60	0,60	0,52
O_{12}	0,76	0,63	0,70
O_{13}	0,78	0,63	0,72

Legenda

	<i>dobrá</i>
	<i>stredná</i>
	<i>zlá</i>



Graf 2 Asociácia 13-tich vybraných obcí

5.3 Zhrnutie kapitoly

Cieľom záverečnej kapitoly je prezentovať výsledky, ktoré sú dosiahnuté pomocou navrhnutého klasifikátora na modelovanie bonity obcí Pardubického kraja. Kapitola je členená na dve časti, z nich v prvej je ukážka klasifikácie obcí Pardubického kraja získaná aplikáciou relácie R (tab. 6) a relácie Q (tab. 7, tab. 8). Druhá časť kapitoly je zameraná na výslednú klasifikáciu obcí Pardubického kraja, ktorá je prezentovaná ako najlepšia. Táto klasifikácia dokáže najlepšie klasifikovať obce do príslušných tried. V tomto prípade nejde o klasifikáciu obcí za pomoci autorom nastavených funkcií príslušnosti, resp. funkcií nepríslušnosti, ako je to v prvej ukážke klasifikácie (tab. 15, graf 1), ale o klasifikáciu obcí aplikovaním relácie R , (tab. 6) a relácie Q (tab. 11 a tab. 12), ktorá je prezentovaná (tab. 16 a graf 2).

Záver

V diplomovej práci je riešená problematika určovania bonity obcí Pardubického kraja. Pojem bonity obce nie je možné jednoznačne špecifikovať. Význam ohodnotenia bonity obcí spočíva predovšetkým v určení úverového rizika, týkajúce sa jednotlivých obcí a podľa neho vykonávať úverové financovanie obcí.

Cieľom diplomovej práce je navrhnúť klasifikátor na modelovanie bonity obcí Pardubického kraja. Navrhnutý klasifikátor klasifikuje obce do troch tried na základe parametrov, ktoré ovplyvňujú pozitívne, resp. negatívne dané obce. Pre vytvorenie klasifikátora je navrhnutý vektor parametrov ohodnocovania bonity obcí Pardubického kraja. Vektor je zložený z ekonomických, dlhových a finančných parametrov. Klasifikátor je navrhnutý s využitím Intuitionistic fuzzy množín a Intuitionistic fuzzy relácií. Klasifikácia obcí Pardubického kraja je uskutočnená pomocou operácií kompozície Intuitionistic fuzzy relácií R a Q , ktorých hodnoty sú na záver celého klasifikačného procesu upravené asociačným indexom. Vytvorenie relácií, charakteristika ako aj tabuľková interpretácia sú uvedené v diplomovej práci v kapitole 4. Taktiež sú prezentované grafické výstupy, ktoré znázorňujú klasifikáciu obcí do troch tried, pomocou navrhnutého klasifikátora. Na základe iteračných pokusov sa podarilo vytvoriť klasifikátor, ktorý zaraďuje obce do troch tried. Avšak výsledky kompozície sú zobrazené iba pre 13 vybraných obcí Pardubického kraja, teda na základe tohto nemožno jednoznačne povedať, že klasifikátor je schopný klasifikovať všetky obce, t.j. 452 do tried podľa ich stupňa funkcie príslušnosti, resp. funkcie nepríslušnosti. V prípade simulácií obcí klasifikátor klasifikoval obce presne tak, ako sú navrhnuté funkcie príslušnosti, resp. funkcie nepríslušnosti parametrov obcí. Z toho vyplýva záver, že klasifikátor je navrhnutý správne a dokáže správne vykonať klasifikáciu obcí Pardubického kraja.

Diplomová práca ponúka nové možnosti z pohľadu riešenia problematiky klasifikácie obcí a určenia bonity obcí metódou, ktorá je založená na využití fuzzy množín, resp. Intuitionistic fuzzy množín a Intuitionistic fuzzy relácií.

Zoznam obrázkov

OBR. 1 FUZZY MNOŽINA A <i>MLADÝ</i>	22
OBR. 2 PRIEBEHY CHARAKTERISTICKÝCH FUNKCIÍ FUZZY MNOŽÍN A A B	23
OBR. 3 PRIEBEHY CHARAKTERISTICKÝCH FUNKCIÍ KOMPLEMENTOV FUZZY MNOŽÍN A A B	23
OBR. 4 PRIEBEHY CHARAKTERISTICKÝCH FUNKCIÍ PRIENIKU A ZJEDNOTENIA FUZZY MNOŽÍN A A B	24
OBR. 5 DIAGRAMATICKÁ REPREZENTÁCIA INVERZNEJ RELÁCIE T^{-1}	25
OBR. 6 ZOBRAZENIE $F: A \rightarrow B$	29
OBR. 7 ROZKLAD MNOŽINY A	31
OBR. 8 MODEL KLASIFIKÁTORA OBCÍ PARDUBICKÉHO KRAJA S VYUŽITÍM IFR R, Q	34
OBR. 9 VYTVORENIE KOHONENOVEJ NEURÓNOVEJ SIETE	39
OBR. 10 VÝSLEDOK ROZDELENIA MNOŽINY DÁT POMOCOU KNS	40
OBR. 12 ZHLUKY ZÍSKANÉ POMOCOU K-MEANS	40
OBR. 11 ROZDELENIE KNS POMOCOU ALGORITMU K-MEANS	40
OBR. 13 ROZDELENIE ZKLUKOV NA TRÉNOVACIU A TESTOVACIU MNOŽINU	41
OBR. 14 GRAFICKÉ PROSTREDIE PRE VÝPOČET KOMPOZÍCIE	49
OBR. 15 ZDROJOVÝ KÓD ALGORITMU KOMPOZÍCIE	51

Zoznam tabuliek

TAB. 1 RATINGOVÉ STUPNICE	14
TAB. 2 UKÁŽKA DÁTOVEJ MATICE PÔVODNÝCH DÁT	34
TAB. 3 UKÁŽKA DÁTOVEJ MATICE ŠTANDARDIZOVANÝCH DÁT	36
TAB. 4 VZORKA DÁTOVEJ MATICE NORMALIZOVANÝCH DÁT.....	36
TAB. 5 RELÁCIA R OD EXPERTA	38
TAB. 6 RELÁCIA R	39
TAB. 7 RELÁCIA $Q(\mu)$ SIMULOVANÝCH FUNKCIÍ PRÍSLUŠNOSTI PARAMETROV OBCÍ	44
TAB. 8 RELÁCIA $Q(v)$ SIMULOVANÝCH FUNKCIÍ NEPRÍSLUŠNOSTI PARAMETROV OBCÍ ...	44
TAB. 9 RELÁCIA $Q(\mu)$	45
TAB. 10 RELÁCIA $Q(v)$	46
TAB. 11 STANOVENIE RELÁCIE $Q(\mu)$ POMOCOU ŠTATISTIKY	47
TAB. 12 STANOVENIE RELÁCIE $Q(v)$ POMOCOU ŠTATISTIKY	47
TAB. 13 KOMPOZÍCIA $T = R \circ Q$ Z RELÁCIE R A Q SIMULOVANÝCH FUNKCIÍ	51
TAB. 14 ASOCIÁCIA KOMPOZÍCIE T.....	52
TAB. 15 ASOCIÁCIA NASIMULOVANÝCH OBCÍ.....	55
TAB. 16 ASOCIÁCIA OBCÍ.....	56

Zoznam grafov

GRAF 1 ASOCIÁCIA SIMULOVANÝCH OBCÍ	55
GRAF 2 ASOCIÁCIA 13-TICH VYBRANÝCH OBCÍ	57

Zoznam skratiek

BV	bežné výdaje
CD	celkový dlh
CP	celkové príjmy
CV	celkové výdaje
DS	dlhová služba
FCM	Fuzzy C-means Clustering
FIS	Fuzzy inferenčný systém
IFM	Intuitionistic fuzzy množina
IFR	Intuitionistic fuzzy relácia
IP	investičné príjmy
KD	krátkodobý dlh
KNS	Kohonenova neurónová sieť
KV	kapitálové výdaje
LM	likvidný majetok
OP	opakujúce sa príjmy
POr	počet obyvateľov v r-tom roku
POr-s	počet obyvateľov v roku r-s
POZ _i	počet obyvateľov zamestnaných v i-tom odvetví ekonomiky
PZ	počet zamestnaných celkovo
U	miera nezamestnanosti
VP	vlastné príjmy

Zoznam literatúry

- [1] VOMOČIL, M., HÁJEK, P., OLEJ, V. Modelování bonity obcí pomocí dopředných neuronových sítí. *Modelování bonity obcí pomocí dopředných neuronových sítí*. 2007, s. 1-10.
- [2] HÁJEK, P. *Modelování bonity obcí metodami výpočetní inteligence.*, 2006. 171s. Univerzita Pardubice. Fakulta ekonomicko-správní. Ústav Systémového inženýrství. Vedoucí diplomové práce Prof. Ing. Vladimír Olej, CSc. Dostupný z WWW: <<http://hdl.handle.net/10195/24184>>.
- [3] SYROVÁTKA, M. *Modelování bonity obcí pomocí Kohonenových neuronových sítí.*, 2007. 81 s. Univerzita Pardubice. Fakulta ekonomicko-správní. Vedoucí diplomové práce Prof. Ing. Vladimír Olej, CSc. Dostupný z WWW: <<http://hdl.handle.net/10195/25663>>.
- [4] HÁJEK, P., OLEJ, V. *Modelling Municipal Rating by Cluster Analysis and Neural Networks*. In Proc. of the 7-th WSEAS International Conference on Neural Networks, NN 2006, (s. 73-78), Cavtat, 2006, ISBN 1790-5109.
- [5] LIPNICK, L.H., RATTNER, Y., EBRAHIM, L. The Determinants of Municipal Credit Quality. *The Determinants of Municipal Credit Quality* [online]. 1999 [cit. 2009-07-03], s. 35-41. Government Finance Review.
- [6] KVASNIČKA, V., POSPÍCHAL, J. *Matematická logika*. Bratislava : STU vydavateľstvo, 2006. 389 s. ISBN 8022724491.
- [7] ATANASSOV, K.T. *Intuitionistic Fuzzy Sets : Theory and Applications*. Heidelberg : Springer Science+Business Media, 1999. 323 s. ISBN 978-3-7908-1228-2.
- [8] KAZAKOV, D.A. *Fuzzy sets for ADA* [online]. 2005 [cit. 2009-03-15]. Dostupný z WWW: <http://www.dmitry-kazakov.de/ada/fuzzy.htm#intuitionistic_set.html>.
- [9] KVASNIČKA, V. a kol.: *Úvod do teórie neuronových sietí*. Bratislava: IRIS, 1997. 285 s. ISBN 80 – 88778 – 30 -1.
- [10] HALÁSEK, D., PILNÝ, J., TOMÁNEK, P. *Určování bonity obcí*. Ostrava: Technická Univerzita Ostrava, 2002, 130 s. ISBN 80-248-0159-0.

- [11] LOVISCEK, A.L., CROWLEY F. *Municipal Bond Ratings and Municipal Debt Management*. In Handbook of Debt Management, Gerald Miller, ed. Marcel Dekker, New York 1996. s. 475-514.
- [12] SANCHEZ, E. *Resolution of composition fuzzy relation equation, Application to medical diagnosis in Brouwerian logic*, M.M. Gupta, G.N. Saridis, B.R. Gaines (Eds.): Fuzzy Automata and Decision Process, Elsevier, North-Holland, 1977.
- [13] SANCHEZ, E. Resolution of composition fuzzy relation equations, *Inform. Control*, 30, 1976, s 38-48.
- [14] OLEJ, V., HÁJEK, P. *Air Quality Modelling by Kohonen's Self-organizing Feature Maps and Intuitionistic Fuzzy Sets*. Proc. of the 12th IASTED International Conference on Artificial Intelligence and Soft Computing, ASC 2008, September 1-3, 2008, Pobil, A.P., Eds., Palma de Mallorca, Spain, ACTA Press, Calgary, Alberta, Canada, pp. 22-27, ISBN 978-088986-7.
- [15] REH, J.F. *How to use Benchmarking in Business*, [online]. [cit. 2009-15-06]. Dostupné z www: <<http://management.about.com/cs/benchmarking/a/Benchmarking.htm> >.
- [16] RIMARČÍK, M. *Štatistika pre prax*. 1. vyd. 2007. 200 s. ISBN 978-80-969813-1-1.
- [17] BEZDEC, J.C. *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York, 1981.