

**EKONOMICKÁ UNIVERZITA V BRATISLAVE**  
**FAKULTA HOSPODÁRSKEJ INFORMATIKY**

Evidenčné číslo: 103004/I/2019/36086129768944644

**INTERPRETÁCIA ZÁVISLOSTÍ VO FUZZY**  
**KOGNITÍVNYCH MAPÁCH**

Diplomová práca

2019

Bc. Radovan Siraň

**EKONOMICKÁ UNIVERZITA V BRATISLAVE**  
**FAKULTA HOSPODÁRSKEJ INFORMATIKY**

**Interpretácia závislostí vo fuzzy kognitívnych mapách**  
Diplomová práca

**Štúdijný program:** Informačný manažment  
**Štúdijný odbor:** Kvantitatívne metódy v ekonómii  
**Školiace pracovisko:** Katedra aplikovanej informatiky FHI  
**Školiteľ:** doc. Dr. Ing. Miroslav Hudec

**Bratislava 2019**

**Bc. Radovan Siraň**

## ZADANIE ZÁVEREČNEJ PRÁCE

**Meno a priezvisko študenta:** Bc. Radovan Siraň  
**Študijný program:** Informačný manažment (Jednoodborové štúdium, inžiniersky II. st., denná forma)  
**Študijný odbor:** 3.3.24 Kvantitatívne metódy v ekonómii  
**Typ záverečnej práce:** Inžinierska záverečná práca  
**Jazyk záverečnej práce:** slovenský  
**Sekundárny jazyk:** anglický

**Názov:** Interpretácia závislostí vo fuzzy kognitívnych mapách

**Anotácia:** Vo fuzzy kognitívnych mapách uzly predstavujú pojmy a spojenia kauzálne väzby medzi nimi. Intenzita väzby medzi uzlami je bežne opísaná hodnotami z intervalu  $[-1, 1]$ . Pomocou vyvodzovacieho mechanizmu je možné zahrnúť vplyvy závislostí medzi uzlami v mape a odvodiť tak jej nový stav.

Cieľom práce je preskúmať fuzzy kognitívne mapy, ich vyvodzovací mechanizmus, formalizáciu výrazov a vzťahov a vytvoriť prostredie na interpretovanie závislostí medzi konceptmi pomocou fuzzy jazykových premenných na ilustračnom príklade.

**Vedúci:** doc. Dr. Ing. Miroslav Hudec  
**Katedra:** KAI FHI - Katedra aplikovanej informatiky FHI  
**Vedúci katedry:** Ing. Mgr. Peter Schmidt, PhD.  
**Dátum zadania:** 27.10.2017

**Dátum schválenia:** 02.11.2017

Ing. Mgr. Peter Schmidt, PhD.  
vedúci katedry

### **Čestné vyhlásenie**

**Čestne vyhlasujem, že záverečnú prácu som vypracoval samostatne a že som uviedol všetku použitú literatúru.**

**Dátum: 30.4.2019**

.....

(podpis študenta)

Pod'akovanie:

Touto cestou zároveň ďakujem doc. Dr. Ing. Miroslavovi Hudecovi za cenné odborné rady, usmernenia, poskytnutú literatúru, ako aj ústretový prístup počas tvorby diplomovej práce.

## **ABSTRAKT**

SIRAŇ, Radovan: Interpretácia závislostí vo fuzzy kognitívnych mapách. - Ekonomická univerzita v Bratislave. Fakulta hospodárskej informatiky; katedra aplikovanej informatiky. - Vedúci záverečnej práce: doc. Dr. Ing. Miroslav Hudec. Bratislava: FHI EU, 2019, 80 strán.

Cieľom záverečnej práce je navrhnúť prostredie na interpretáciu vývoja stavov vo fuzzy kognitívnej mape a demonštrovať jeho použitie na ilustračnom príklade. Práca je rozdelená do piatich kapitol. Obsahuje 28 vzorcov, 14 grafov, 14 tabuliek a 4 matice. V prvej kapitole sú predstavené fuzzy kognitívne mapy ako nástroj na modelovanie dynamických systémov. V nasledujúcej kapitole bola navrhnutá kognitívna mapa všeobecného webového spravodajského portálu. V tretej kapitole bola zostrojená mapa rozšírená o fuzzy zložku dvoma rôznymi prístupmi. Pre obidva modely prebehli simulačné behy troch scenárov. Výsledkom práce je úprava vyvodzovacieho mechanizmu fuzzy kognitívnej mapy pre výpočet so slovnými hodnotami, implementácia mechanizmu v jazyku R a porovnanie správania tohto modelu s numerickou fuzzy kognitívnou mapou.

### **Kľúčové slová:**

fuzzy kognitívne mapy, kauzalita v grafoch, fuzzy vyvodzovanie, jazykové premenné

## **ABSTRACT**

SIRAŇ, Radovan: Interpreting dependencies in fuzzy cognitive maps. - The University of Economics in Bratislava. Faculty of Business Informatics, Department of Applied Informatics - The master thesis leader: doc. Dr. Ing. Miroslav Hudec - Bratislava: FHI EU, 2019, 80 pages.

The aim of this master thesis is to design a framework for interpreting dependencies in Fuzzy Cognitive Maps and demonstrate its use on an example. The thesis is divided into 5 chapters and contains 28 formulas, 14 charts, 14 tables and 4 matrices. In the first chapter Fuzzy Cognitive Maps are introduced, as a tool for modeling dynamic and complex systems. In the following chapter a cognitive map of an online news portal is designed. The third chapter expands this cognitive map with a fuzzy element, while two different approaches are applied. For both of the models, simulations of three same scenarios had been ran. The outcome of the thesis is an inference mechanism adjusted for computation with fuzzy linguistic variables, its implementation in the R language and comparison of the proposed mechanism with a numeric model of the fuzzy cognitive map.

### **Keywords:**

fuzzy cognitive maps, causal graphs, fuzzy inference, linguistic variables

# Obsah

Úvod.....	9
1 Súčasný stav riešenej problematiky doma a v zahraničí.....	10
1.1 Štruktúra fuzzy kognitívnej mapy.....	10
1.1.1 Koncepty (uzly).....	12
1.1.2 Závislosti (hrany).....	12
1.2 Kauzalita vo fuzzy kognitívnych mapách.....	13
1.3 Výhody použitia fuzzy kognitívnych máp.....	14
1.4 Vývoj fuzzy kognitívnej mapy.....	15
1.4.1 Výber relevantných konceptov.....	16
1.4.2 Stanovenie závislostí medzi konceptmi a ohodnotenie ich intenzity.....	16
1.4.3 Vyvodzovací mechanizmus fuzzy kognitívnej mapy.....	19
1.5 Matematické prístupy k tvorbe fuzzy kognitívnych máp.....	23
1.5.1 Hebbian algoritmy.....	23
1.5.2 Evolučné algoritmy.....	24
2 Cieľ práce, metodika práce a metódy skúmania.....	26
3 Výsledky práce.....	27
3.1 Dizajn fuzzy kognitívnej mapy spravodajského portálu.....	27
3.2 Výber konceptov a určenie závislostí medzi nimi.....	28
3.3 Model s fuzzifikovanými hodnotami konceptov a závislostí.....	30
3.3.1 Fuzzifikácia počiatkových stavov konceptov.....	30
3.3.2 Fuzzifikácia závislostí medzi konceptmi.....	31
3.4 Vyvodzovací mechanizmus pre nové hodnoty konceptov.....	32
3.4.5 Scenáre simulačného behu s fuzzifikovanými hodnotami.....	33
3.5 Model s konceptmi a závislosťami ako fuzzy jazykovými premennými.....	38
3.5.1 Rozklad konceptov do jazykovej premennej.....	38
3.5.2 Rozklad intenzity závislosti do jazykovej premennej.....	39
3.5.3 Závislosti ako jazykové premenné.....	40
3.5.4 Interpretácia vzťahov v mape so slovnými hodnotami.....	41
3.5.5 Vyvodzovací mechanizmus pre nové hodnoty konceptov.....	41
3.5.6 Scenáre simulačného behu modelu so slovnými hodnotami.....	45
4. Diskusia.....	52



4.1 Porovnanie navrhnutých modelov.....	52
4.2 Možné oblasti zlepšenia a trendy.....	53
Záver.....	55
Zoznam použitej literatúry.....	56
Prílohy.....	59
1. Algoritmus pre simulácie s fuzzifikovanými hodnotami.....	59
2. Algoritmus pre simulácie so slovnými hodnotami.....	61

# Úvod

Pre zachytenie komplexného systému matematickým modelom je nutné jednak pochopiť, analyzovať a exaktne vystihnúť jeho fungovanie, ako aj zachytiť dynamiku tohto systému v čase a všetky vonkajšie vplyvy naň pôsobiace. Čím je systém robustnejší, tým skôr sa dosiahnu limity tradičných prístupov.

Fuzzy kognitívna mapa je jednoduchý nástroj na modelovanie komplikovaných systémov. Jednoduchosť je jej najväčšou výhodou aj nevýhodou zároveň. Kognitívna mapa pozostáva len z dvoch prvkov – konceptov a závislostí medzi nimi, a vďaka zrozumiteľnej grafickej reprezentácii je pochopiteľná aj pre laika. Zároveň sa však pri jej tvorbe vo väčšine prípadov využíva práve ľudský, teda expertný vstup, preto takto zostrojená mapa modeluje reálny systém práve tak dobre, ako ho boli schopné opísať strany zúčastnené pri jej dizajne. Pri využití overených postupov zberu expertných názorov je však výsledná mapa objektívnou reprezentáciou modelovaného systému [03]. V každom prípade však môže vyvodzovací mechanizmus fuzzy kognitívnej mapy simulovať dopady navrhnutých závislostí na jednotlivé koncepty a tak potvrdiť, alebo vyvrátiť vyslovené predpoklady o správaní systému ako celku.

V tejto práci boli v prvej kapitole zhrnuté najmä základné východiská fuzzy kognitívnych máp a ich tvorby, ako aj princípy vyvodzovacieho mechanizmu simulácie vývoja dopadov závislostí v mape. V praktickej časti bola navrhnutá fuzzy kognitívna mapa webového spravodajského portálu. Simulácia vývoja v mape prebiehala najprv s fuzzifikovanými hodnotami premenných z intervalu [0,1]. Následne, z dôvodu jednak lepšej interpretácie dopadov závislostí v ktoromkoľvek kroku simulácie, ako aj vzhľadom na vágnu povahu vstupov, bol navrhnutý model s fuzzy jazykovými premennými. Správanie oboch modelov bolo porovnané na troch rôznych scenároch vývoja, pričom výsledky simulačných behov boli interpretované graficky aj slovne.

# 1 Súčasný stav riešenej problematiky doma a v zahraničí

Fuzzy kognitívne mapy sú nástrojom umožňujúcim modelovať komplexné systémy reálneho sveta pomocou vybraných dôležitých charakteristík – konceptov - a príčinných vzťahov medzi nimi. Obsahujú kombináciu prvkov z teórie grafov, fuzzy logiky, neurónových sietí, expertných systémov či nelineárnych dynamických systémov [02]. Fuzzy kognitívne mapy boli prvýkrát predstavené v roku 1985 Bartom Koskom [01], ktorý vychádzal z kognitívnych máp amerického politického vedca Roberta Axelroda (*Axelrod, R. - Structure of Decision The Cognitive Maps of Political Elites*). Bart Kosko označil kognitívne mapy za príliš zväzujúce pre modelovanie systémov vychádzajúcich z vedomostí, pretože tie sú častokrát „fuzzy“. Všeobecne platí, že čím viac „fuzzy“ je určitý poznatok, tým jednoduchšie je jeho pochopenie a osvojenie. Zároveň však platí, čím viac „fuzzy“ vedomosť je, tým komplikovanejšia je jej notácia a spracovanie [01].

Od predstavenia fuzzy kognitívnych máp sa tieto postupne stávajú čoraz obľúbenejším nástrojom na modelovanie systémov a riešenie problémov, v ktorých viaceré premenné spolu príčinne súvisia. pričom buď neexistujú dáta – v tom prípade vzťahy určujú experti – alebo dáta existujú a vzťahy v mape sú určene na základe učiacich algoritmov.


Pochopenie a osvojenie základných princípov fuzzy kognitívnych máp je relatívne jednoduché a zároveň následné zostrojenie fuzzy kognitívnej mapy je zvyčajne aj časovo nenáročné. Nakoľko sa dizajn fuzzy kognitívnej mapy, t.j. výber samotných konceptov a naznačenie závislostí, často a vo veľkej miere spolieha práve na vstup od expertov, resp. zainteresovaných osôb, je možnosť osvojiť si základy tejto metódy jej veľkou výhodou [03].

## 1.1 Štruktúra fuzzy kognitívnej mapy

Fuzzy kognitívna mapa je orientovaný digraf, resp. fuzzy kauzálny graf [01], ktorý reprezentuje model časti reálneho sveta. Uzly v grafe predstavujú jednotlivé koncepty – prvky modelu a ohodnotené hrany predstavujú príčinné závislosti medzi nimi. Kladné ohodnotenie hrany znázorňuje kauzálny prírastok konceptu a naopak, záporné ohodnotenie kauzálny úbytok jeho hodnoty, v smere orientácie hrany. Medzi jednotlivými uzlami môžu vznikajú pomocou hrán aj spätné väzby.

Všetky premenné vo fuzzy kognitívnej mape sú fuzzifikované, pričom hodnoty konceptov sa pohybujú v intervale  $[0,1]$ , resp.  $[-1,1]$ , ak má logický význam uvažovať aj o zápornej hodnote konceptu. Hodnoty závislostí sa pohybujú v intervale  $[-1,1]$ . Fuzzy kognitívne mapy môžu byť využité na modelovanie ako kvalitatívnych, tak aj kvantitatívnych dát [03]. Graf č. 1 zobrazuje jednoduchú fuzzy kognitívnu mapu, pozostávajúcu z piatich konceptov a šiestich hrán.

Graf č. 1 - príklad fuzzy kognitívnej mapy



Fuzzy kognitívnu mapu môžeme formálne zapísať ako štvoricu [12]:

$$FCM = (K, Z, \alpha, \beta) \quad (1)$$

v ktorej:

- $K$  je konečná množina konceptov
- $Z$  je konečná množina závislostí (hrán), spájajúcich koncepty
- $\alpha$  je funkcia príslušnosti mapujúca hodnoty uzla na fuzzy číslo
- $\beta$  je funkcia príslušnosti mapujúca hodnoty hrany na fuzzy číslo

### 1.1.1 Koncepty (uzly)

Uzol v kognitívnej mape je koncept, reprezentácia kľúčového prvku v modeli. Konceptom môžu byť udalosť, cieľ, vstup, výstup, stav, premenná, trend či akákoľvek iná dôležitá charakteristika modelovaného systému [02]. Každý koncept vo fuzzy kognitívnej mape teda reprezentuje iný pohľad na systém. Nižšie uvedená notácia zachytáva hodnoty konceptov stavového vektora fuzzy kognitívnej mapy [10].

$$K = (k_1, k_2, \dots, k_n), k \in [0, 1] \quad (2)$$

Kde  $K$  je vektor stavov konceptov a  $k_i$  predstavuje hodnotu  $i$ -teho konceptu v mape.

Koncept, teda uzol vo fuzzy kognitívnej mape, môže byť povahy [12], [15]:

1. Výstupnej – uzol má len vystupujúce hrany a absolútna hodnota súčtu hodnôt ich váh je kladná
2. Vstupnej – do uzla len vstupujú hrany a absolútna hodnota súčtu hodnôt ich váh je kladná
3. Tranzitnej – hodnota súčtu váh vstupných aj výstupných hrán je kladná.

Význam uzla v rámci fuzzy kognitívnej mapy je možné merať pomocou centrality, ktorá predstavuje sčítanie vstupného aj výstupného stupňa uzla.

### 1.1.2 Závislosti (hrany)

Orientované hrany vo fuzzy kognitívnej mape znázorňujú príčinné vzťahy medzi konceptmi, vďaka čomu je na prvý pohľad zrejmé, ktorý koncept ovplyvňuje ktorý a zároveň, aká je intenzita jeho vplyvu [02].

Pre potreby výpočtov je možné závislosti medzi konceptmi v mape zaznačiť ako maticu.

Matica závislostí  $Z$  je definovaná ako

$$Z = (z_{ij}), \text{ kde } z_{ij} \text{ sú váhy hrany medzi } K_i, K_j \quad (3)$$

Matica závislostí pre fuzzy kognitívnu mapu na grafe č. 1 by teda mala tvar

$$\mathbf{Z} = \begin{bmatrix} 0 & Z_{12} & 0 & 0 & 0 \\ 0 & 0 & Z_{23} & 0 & 0 \\ Z_{13} & 0 & 0 & 0 & Z_{35} \\ 0 & 0 & 0 & 0 & Z_{45} \\ 0 & 0 & 0 & Z_{54} & 0 \end{bmatrix} \quad (1)$$

Pričom každá z váh  $Z_{ij}$  má hodnotu z intervalu  $[-1,1]$ . Každá matica susedností fuzzy kognitívnej mapy má zhodný počet riadkov a stĺpcov a na diagonále sa nachádzajú nulové hodnoty.

Závislosti medzi jednotlivými konceptmi môžu znázorňovať jednu z troch uvedených pováh [02]:


1. pozitívnu kauzalitu ( $Z_{ij} > 0$ ) – nárast, resp. pokles hodnoty konceptu  $K_i$  spôsobí nárast, resp. pokles hodnoty konceptu  $K_j$
2. negatívnu kauzalitu ( $Z_{ij} < 0$ ) – nárast hodnoty konceptu  $K_i$  spôsobí pokles hodnoty konceptu  $K_j$ , resp. pokles hodnoty konceptu  $K_i$  spôsobí nárast hodnoty konceptu  $K_j$
3. žiadny vzťah medzi konceptmi ( $Z_{ij} = 0$ ) – nulová kauzalita

## 1.2 Kauzalita vo fuzzy kognitívnych mapách

Medzi dvoma konceptmi existuje príčinná súvislosť, ak zmena jedného konceptu vyvolá zmenu toho druhého [05]. Napríklad, existuje príčinná súvislosť medzi podielom vysokoškolsky vzdelaných ľudí v spoločnosti a ekonomickou úrovňou spoločnosti [19]. Zvýšenie podielu vysokoškolsky vzdelaných ľudí v spoločnosti spôsobí rast životnej úrovne. Typológia kognitívnych máp umožňuje vznik troch typov kauzálnych vzťahov [11]:


**Priamy** – ak medzi konceptom  $K_i$  a  $K_j$  existuje príčinná súvislosť, hovoríme o priamej kauzalite medzi konceptmi  $K_i$  a  $K_j$ .

Graf č. 2 – priamy kauzálny vzťah




**Nepriamy** – ak sa medzi konceptom  $K_i$  a  $K_j$  vyskytuje ďalší koncept, hovoríme o nepriamej kauzalite medzi konceptmi  $K_i$  a  $K_j$ .

Graf č. 3 - nepriamy kauzálny vzťah



**Spätná väzba** – ak medzi konceptmi  $K_i$  a  $K_j$  existuje vzájomná príčinná súvislosť, hovoríme o kauzalite so spätnou väzbou [06].

Graf č. 4 - kauzálna slučka



Spätná väzba sa vyskytuje s časovým oneskorením. Napríklad, zvýšenie podielu vysokoškolsky vzdelaných ľudí v spoločnosti spôsobí rast životnej úrovne. Rast životnej úrovne však v ďalšej generácii spätne posilňuje podiel vysokoškolsky vzdelaných ľudí v spoločnosti.

Vzhľadom na nelineárnu povahu mapy je nemožné kauzalitu otočiť smerom vzad, t.j. prehľadávanie fuzzy kognitívnej mapy je možné len smerom vpred [17].

### 1.3 Výhody použitia fuzzy kognitívnych máp

Hlavnou výhodou fuzzy kognitívnych máp je schopnosť predpovedať výsledok vzájomnej interakcie konceptov v rámci zložitého dynamického systému. Inými slovami, fuzzy kognitívna mapa pomáha potvrdiť alebo vyvrátiť zvažované rozhodnutie vzhľadom na

definovanú množinu konceptov a kauzálnych vzťahov medzi nimi. Nižšie sú v niekoľkých bodoch uvedené hlavné výhody využitia fuzzy kognitívnych máp pri rozhodovaní v dynamickom prostredí [13].

### Jednoduchosť a vizualizácia

Fuzzy kognitívna mapa ponúka intuitívny a presný postup na grafické zachytenie konceptov a vzťahov medzi nimi. Notácii ľubovoľného zložitého problému formou kauzálného grafu je jednoduché porozumieť aj nezainteresovaným osobám.

### Schopnosť modelovať kvalitatívne vplyvy

Stav konceptu a jeho vplyv môže vyjadrovať nielen ekvivalent fyzického množstva, resp. úbytku a prírastku, ale aj jeho intenzitu. Vďaka nožnej tvorbe fuzzy kognitívnej mapy len na báze expertných názorov nie je problém ani absencia historických dát.

### Schopnosť predpovedať

Pomocou vyvodzovacieho mechanizmu, resp. simulácie fuzzy kognitívnej mapy je možné určiť trend vývoja konceptov podľa daných počiatočných stavov. Vďaka jednoduchej štruktúre fuzzy kognitívnej mapy je možné ktorýkoľvek koncept vypustiť, ak prejaví ako nedôležitý alebo, naopak, zahrnúť nový koncept.

### Spolahlivé uchovanie vedomostí

Fuzzy kognitívna mapa zostrojená a otestovaná dôveryhodnými expertmi je jednak spoľahlivý nástroj na podporu rozhodovacích procesov, ale zároveň predstavuje aj možnosť trvalého zachytenia inak ťažko zaznamenateľných vedomostí do jedného celku. Najmä vďaka internetu rastie dostupnosť a prepojenie viac či menej štrukturovaných vedomostí, zaznamenaných vo forme kníh, článkov, esejí, rozhovorov a podobne. Fuzzy kognitívna mapa je vhodná aj na modelovanie nového fenoménu, známeho ako „big knowledge“ [14].

### Flexibilita

Fuzzy kognitívne mapy sú nástroj pre prácu aj s neúplnými a neurčitými vstupmi. V prípade potreby nie je zložitá zapracovať do existujúceho modelu nové poznatky alebo, naopak, vylúčiť už nepotrebné koncepty či zaniknuté vzťahy medzi nimi.



## 1.4 Vývoj fuzzy kognitívnej mapy

Cieľom tvorby fuzzy kognitívnej mapy je modelovať systém pomocou jeho kľúčových konceptov a tak odhaliť, resp. lepšie pochopiť jeho správanie ako celku. Vývoj fuzzy kognitívnych máp sa zvyčajne vo veľkej miere spolieha na vstup od expertov, resp. zainteresovaných osôb, ktorých vedomosti a pohľady sú prenesené do modelu [02]. Ako bolo spomenuté v úvode, vďaka grafickej reprezentácii je osvojenie si základných princípov fuzzy kognitívnej mapy jednoduché [03], čím je umožnené širšej skupine osôb prispieť svojim pohľadom k dizajnu fuzzy kognitívnej mapy, čo ju zároveň robí aj menej subjektívnou. Tvorbu fuzzy kognitívnej mapy je možné realizovať [02]:

1. ako jednu mapu na základe vstupu od jedného experta,
2. ako jednu mapu na základe zhody názorov viacčlennej skupiny expertov a
3. ako skupinu individuálnych máp expertov, na základe ktorej sa vytvorí jedna výsledná fuzzy kognitívna mapa.

Matematické prístupy pri tvorbe fuzzy kognitívnych máp, ako napríklad spresnenie ohodnotenia závislostí na základe historických dát pomocou algoritmu *Differential Hebbian Learning (DHL)*, či generovanie priamo celej matice závislostí pomocou populačných algoritmov, sú bližšie opísané v kapitole 1.5.

### 1.4.1 Výber relevantných konceptov

V prvom kroku vývoja sú expertne vybrané relevantné koncepty, ktoré pokryjú celú skúmanú tému. Ak sa procesu tvorby mapy zúčastňuje viacero expertov a nezhodnú sa na rovnakej množine konceptov, v ďalších krokoch sa uvažuje so zlúčením všetkých množín navrhnutých konceptov, t.j. žiaden z nich sa nevynecháva [02].

### 1.4.2 Stanovenie závislostí medzi konceptmi a ohodnotenie ich intenzity

V druhom kroku je nutné určiť závislosti medzi konceptmi a ich intenzitu. Tento krok je pri tvorbe máp na základe expertných znalostí náročnejší najmä pri mapách s vyšším počtom konceptov, nakoľko počet závislostí v mape s  $n$  konceptmi môže byť až  $n^2$ . Podľa

rozsahu vedomostí o problematike je pomerne náročné nielen určenie závislosti a jej smeru (kladný alebo záporný), ale najmä jej intezity.

Pomôcť môže rozklad možných hodnôt intenzity závislosti do jazykovej premennej. V prípade využitia hodnôt jazykovej premennej je tiež možné ľahšie dosiahnuť zhodu pri tvorbe mapy väčšou skupinou expertov. Určovanie závislostí v mape prebieha všeobecne v nasledujúcich krokoch [02], [03]:

1. určenie súvislostí medzi konceptmi (ich prepojenie v mape hranou),
2. určenie orientácie hrany a smeru závislosti medzi súvisiacimi konceptmi (kladný alebo záporný)
3. rozklad intenzity závislosti do jazykovej premennej, priradenie slovných hodnôt jednotlivým závislostiam a defuzzifikácia alebo priamo ohodnotenie závislostí hodnotami z intervalu  $[-1, 1]$ .

V prípade, že experti vytvorili mapy s nie zhodnými množinami konceptov, sa každá matica závislostí „umelo“ rozšíri o zlúčenie všetkých množín konceptov, pričom v jednotlivých mapách sa závislosti medzi umelo pridanými konceptmi zoznačia ako nuly (žiadny vplyv).

#### 1.4.2.1 Určenie intenzity závislostí pomocou jazykovej premennej

Predpokladané závislosti medzi konceptmi je možné ohodnotiť buď priamo numericky hodnotami z intervalu  $[-1,1]$ , alebo intenzitu závislosti rozložiť do hodnôt jazykovej premennej [03], [16]. Jazyková premenná vo fuzzy logike je definovaná štvoricou prvkov [04]:

- Názov jazykovej premennej (závislosť, resp. vplyv na koncept)
- Hodnoty jazykovej premennej (hodnoty vplyvu - vysoký, nízky, mierne záporný, ...)
- Univerzálnou množinou (v prípade závislostí  $[-1,1]$  )
- Syntaktickým a sémantickým pravidlom (funkciou príslušnosti, ktorá pridelí číselnej hodnote príslušnosť do jazykovej premennej na intervale  $[-1,1]$ ).

Hodnoty jazykovej premennej môžu byť definované napríklad nasledujúcou, tzv. trojuholníkovou funkciou príslušnosti:

$$\mu(x; a, m, b) = \begin{cases} 0, & x \leq a \\ \frac{(x-a)}{(m-a)}, & a \leq x \leq m \\ \frac{(b-x)}{(b-m)}, & m \leq x \leq b \\ 0, & b \leq x \end{cases} \quad (4)$$

Kde  $x$  je vo všeobecnosti nefuzzifikovaná hodnota – v tomto prípade teda intenzita vplyvu  $[-1,1]$  - a pre parametre platí  $a < m < b$ .

#### 1.4.2.2 Výpočet matice závislostí z individuálne navrhnutých matíc

V prípade postupu tvorby mapy dizajnom individuálnych matíc jednotlivých expertov je nutné tieto matice agregovať do jedinej výslednej matice.

Ak sú hodnoty závislostí jednotlivých matíc numerické z intervalu  $[-1,1]$  a predpokladáme rovnakú váhu názoru každého experta, môžeme finálnu maticu závislostí získať pomocou jednoduchého priemeru jednotlivých matíc:

$$\mathbf{Z} = \frac{1}{k} \left( \sum_1^N z_k \right) \quad (5)$$

Kde  $k$  je počet expertov,  $z_k$  je matica závislostí  $k$ -teho experta a  $\mathbf{Z}$  je výsledná matica závislostí. Ak je názor niektorých expertov relevantnejší, je možné tento vzťah intuitívne upraviť pridaním váh  $w$  k jednotlivým názorom [02]:

$$\mathbf{Z} = \frac{1}{\left( \sum_{i=1}^k w_i \right)} \left( \sum_1^N w z_k \right) \quad (6)$$

V prípade problematického priradenia váh kredibility expertných názorov môže použitie uvedeného vzorca predchádzať algoritmus, ktorý tieto váhy vygeneruje. Na začiatku sú váhy názorov všetkých expertov rovné jednej. Skúmajú sa všetky závislosti vo všetkých maticiach. Ak sa objaví pre dané spojenie konceptov  $K_i$ ,  $K_j$  vplyv s odlišným smerom a počet takto orientovaných vplyvov je vo všetkých maticiach menších ako  $\pi * N$  a expert na názore trvá, zníži jeho váhu. [02]

V prípade využitia slovných premenných pri tvorbe individuálnych matíc je postup výpočtu výslednej matice závislosti zložitejší, nakoľko fuzzy čísla (hodnoty slovných premenných) je síce možné agregovať (operácia množinového zlúčenia týchto čísiel), avšak na získanie konečnej hodnoty závislosti ako jedného čísla je nutné výslednú fuzzy množinu defuzzifikovať napríklad centroidnou metódou.

#### 1.4.2.3 Interpretácia vzťahov v mape

Výhoda využitia fuzzy jazykových premenných je zjavná – vzťahy medzi konceptmi opisujú kvalitatívne, čím sú zrozumiteľnejšie a ohodnotenie závislostí tak môže byť konzistentnejšie. Hodnoty jazykovej premennej závislostí tiež umožňujú jednoduchú interpretáciu vzťahov v mape [03]. Intenzita vplyvu konceptu  $K_i$  na koncept  $K_j$  môže byť lingvisticky interpretovaná nasledovne:

$$\text{Vplyv závislosti konceptu } K_i \text{ na koncept } K_j \text{ má intenzitu } T\{\text{vplyv}\} \quad (7)$$

Kde  $T$  je jazyková premenná opísaná vyššie a  $\{\text{vplyv}\}$  je jej konkrétna hodnota. Tento vzťah bol v kapitole 4 ďalej rozvinutý o slovné premenné konceptov, čo spolu s navrhnutým vyvodzovacím mechanizmom pre slovné premenné umožnilo okamžitú interpretáciu stavu fuzzy kognitívnej mapy v ktoromkoľvek kroku simulácie.

#### **1.4.3 Vyvodzovací mechanizmus fuzzy kognitívnej mapy**

Každá fuzzy kognitívna mapa pozostáva zo statických a dynamických častí [12]. Koncepty a závislosti, rovnako ako aj zvolená prahová funkcia vyvodzovacieho mechanizmu sú počas vyvodzovania, teda simulačného behu statické – nemenné. Dynamickou časťou je

stavový vektor konceptov, ktorý sa mení s každou iteráciou, až kým nedosiahne ustálený stav, alternatívne sekvenciu opakujúcich sa stavov. Fuzzy kognitívna mapa, ktorá nekonverguje k ustálenému stavu vektora konceptov, sa nazýva chaotická.

Pred začiatkom simulačného behu fuzzy kognitívnej mapy je nutné najskôr určiť vektor počiatočných stavov konceptov. Každý koncept vo fuzzy kognitívnej mape má hodnotu  $A_i$  z intervalu 0 až 1, ktorá vyjadruje ekvivalent jeho fyzického množstva, prípadne intenzitu domnelého kvalitatívneho vplyvu. V prípadoch, ak je logické uvažovať aj so zápornými hodnotami konceptov, sú hodnoty z intervalu -1 až +1. Hodnotu jednotlivých konceptov je možné určiť, podobne ako pri závislostiach, buď priamo numerickým ohodnotením alebo definíciou slovných premenných pre jednotlivé koncepty a následnou fuzzifikáciou reálnych vstupných hodnôt.

Stavový vektor konceptov sa mení každou iteráciou vyvodzovacieho mechanizmu, pričom každá iterácia predstavuje posun v čase. Vývoj fuzzy kognitívnej mapy je možné zaznačiť aj ako hyperkocku [03]:

$$S(t)=[S_1(t), S_2(t), \dots, S_n(t)] \quad (8)$$

Pričom  $S_n(t)$  reprezentuje jeden z vektorov stavov konceptov. Simulačný beh je teda vlastne posun po stavoch tejto kocky. Akou postupnosťou stavov dosiahne mapa konvergovaný stav, závisí od vstupného vektora konceptov.

### 1.4.3.1 Vyvodzovacie pravidlá

Na výpočet nového vektora stavov konceptov existuje niekoľko vyvodzovacích mechanizmov a prahových funkcií [13], [12]. Najčastejšie využívanými vyvodzovacími pravidlami vo fuzzy kognitívnych mapách je vyvodzovacie pravidlo navrhnuté Bartom Koskom [12], resp. jeho modifikovaný alebo škálovaný variant. Základné Koskovo vyvodzovacie pravidlo má tvar:

$$A_i(k+1)=f\left(\sum_{j=1, j \neq i}^N z_{ij} \times A_j(k)\right) \quad (9)$$

Kde  $A_i(k+1)$  je hodnota stavu  $i$ -teho konceptu v  $k+1$  kroku simulácie,  $A_j(k)$  je hodnota stavu  $j$ -teho konceptu vplyvajúceho na  $A_i$ -ty koncept v  $k$ -tom kroku simulácie,  $z$  je ohodnotenie hrany (intenzity závislosti) medzi  $i$ -tym a  $j$ -tym konceptom a  $f$  je prahová funkcia, ktorá transformuje hodnoty do požadovaného intervalu  $[0,1]$ .

Slovne interpretované, novú hodnotu konceptu vypočítame ako sumu produktu všetkých vplyvov na koncept a hodnôt stavov konceptov, z ktorých tieto vplyvy vychádzajú, pričom prahová funkcia  $f$  zabezpečí normovanie výslednej hodnoty do požadovaného intervalu.

Modifikované Koskovo vyvodzovacie pravidlo má tvar:

$$A_i(k+1) = f\left(A_i(k) + \sum_{j=1, j \neq i}^n z_{ij} * A_j(k)\right) \quad (10)$$

Pričom zahrnutie aj stavu konceptu, ktorého nová hodnota sa vyvodzuje zabezpečuje „hladší“ priebeh každej iterácie. Vyššie uvedené pravidlá však nemusia fungovať v prípade špecifických počiatočných stavov konceptov rovných 0 (nie je dostupná informácia o stave konceptu), resp. rovných 0.5, vzhľadom na povahu sigmoidnej prahovej funkcie (opísaná v ďalej kapitole, vzťah č. x). Na odstránenie tohto problému bol navrhnutý škálovaný vyvodzovací mechanizmus [12], [03]:

$$A_i(k+1) = f\left(2x(A_i(k) - 1) + \sum_{j=1, j \neq i}^n z_{ij} * (2xA_j(k) - 1)\right) \quad (11)$$

### 1.4.3.2 Prahové funkcie

Nakoľko hodnoty konceptov musia byť v intervale  $[0,1]$  (resp.  $[-1,1]$  tam, kde má logické opodstatnenie uvažovať o záporných hodnotách konceptov), na ich transformáciu je nutné použiť niektorú z prahových funkcií. Najčastejšie aplikovanou prahovou funkciou je sigmoidná funkcia, nakoľko táto normuje výsledok vyvodzovacieho mechanizmu do spojitého intervalu  $[0,1]$ , čím ponúka najväčšiu škálu hodnôt stavu konceptu. Transformácia do intervalu

[0,1] síce zamedzuje kvantitatívnej analýze výsledkov, ale stále umožňuje kvalitatívne porovnanie stavov konceptov v mape [03].

$$f(x) = \frac{1}{1 + e^{(-\lambda * x)}} \quad (12)$$

Ďalšími často používanými prahovými funkciami, ktoré sú zároveň aj voliteľné vo vyvodzovacom mechanizme knižnice *fc*m v jazyku *R*, sú:

Bivalentná prahová funkcia, ktorá mapuje výsledné hodnoty vyvodzovacieho mechanizmu na 0 alebo 1:

$$f(x) = \begin{cases} 0, & \text{ak } x \leq 0 \\ 1, & \text{ak } x > 0 \end{cases} \quad (13)$$

Trivalentná prahová funkcia, ktorá mapuje hodnoty na -1, 0 alebo 1:

$$f(x) = \begin{cases} -1, & \text{ak } x \leq -0.5 \\ 0, & \text{ak } -0.5 < x < 0.5 \\ 1, & \text{ak } x \geq 0.5 \end{cases} \quad (14)$$

Hyperbolická tangens funkcia, ktorá mapuje hodnoty konceptov do intervalu [-1,1] a využíva sa len v prípade, ak má logický význam uvažovať aj so zápornými hodnotami konceptov:

$$f(x) = \tanh(x) \quad (15)$$

### 1.4.3.3 Simulačný beh

Po ohodnotení počítačových stavov konceptov a výbere vyvodzovacieho mechanizmu v simulačnom behu už koncepty ďalej voľne interagujú. Hodnota konceptu rovná nule predstavuje jeho neprítomnosť v modelovanom systéme a naopak, hodnota rovná jednej jeho

prítomnosť v najvyššej možnej miere. Simulačný beh môže skončiť troma možnými závermi [03]:

1. hodnoty konceptov sa ustália, t.j. hodnoty v každom kroku  $k+1$  sú rovnaké ako v  $k$ -tom kroku
1. dosiahne sa maximálny povolený počet iterácií simulácie
2. je spozorované chaotické (divergentné) správanie

Vo väčšine praktických prípadov simulácia končí v momente, keď zmena každého z konceptov je menšia ako zvolené rezíduum, väčšinou z intervalu 0.01 až 0.0001. Dosiahnutý vektor stavov konceptov je považovaný za ustálený.

## 1.5 Matematické prístupy k tvorbe fuzzy kognitívnych máp

Zostrojiť presný model dynamického systému pomocou fuzzy kognitívnej mapy je výzva, ktorú v niektorých prípadoch nie je možné splniť len za pomoci expertných znalostí. Dôvodom môže byť potenciálna zaujatosť, resp. strata objektívneho pohľadu experta na problém, či robustnosť problematiky. Napriek tomu, z dôvodu nedostatku či náročnosti automatizovaných či poloautomatizovaných metód, ktoré by v dizajne máp nahradili expertov, sú práve expertné metódy najčastejšie aplikované [02].

Cieľom matematických metód, resp. učiacich algoritmov, je „naučiť sa“ na základe historických dát maticu závislostí medzi konceptmi. Niektoré z nich vyžadujú počiatočný expertný vstup a slúžia len na korekciu expertnej matice, iné generujú celú maticu závislostí samostatne. Genetické algoritmy boli úspešne aplikované aj pre potrebu ohodnotenia vektora počiatočných stavov konceptov. Výber vhodnej metódy závisí ako od dostupných dát (niektoré algoritmy vyžadujú viacero sád stavov konceptov, iným postačuje aj jedna), tak aj od časového hľadiska či obmedzení, ktoré nie je možné formulovať matematicky [02]. Na základe štúdie [09] boli skúmané viaceré prístupy učiacich algoritmov pre fuzzy kognitívne mapy, pričom boli hodnotené z hľadiska cieľa učenia, potreby expertnej korekcie, požiadavky na rozsah dát či výpočtovej kapacity. Výsledkom štúdie bolo favorizovanie Hebbian metód a populačných algoritmov, ktoré sú ďalej bližšie predstavené v nasledujúcich podkapitolách.



### 1.5.1 Hebbian algoritmy

Častým problémom pri tvorbe fuzzy kognitívnej mapy je ohodnotenie jej hrán závislostí tak, aby ich dopady čo najpresnejšie zodpovedali správaniu skutočného systému. V závislosti od povahy modelovaného systému môže byť výsledok veľmi subjektívny [12]. Možné riešenie predstavuje algoritmus *DHL* (*Differential Hebbian Learning*). Počas behu učenia sú váhy závislostí upravované podľa zmien hodnôt konceptov, až kým sa nenájde ustálený stav alebo nedosiahne povolený počet iterácií [13]. Algoritmus upravuje len nenulové hodnoty závislostí.

Ak stav dvojice konceptov počas iterácie narastie, *DHL* kladne zvýši hodnotu závislosti medzi nimi a vice versa. Na výpočet derivácie závislosti medzi dvoma konceptmi bol navrhnutý nižšie uvedený vzťah [02].

$$z'_{ji} = -z_{ji} + f(S_j^{nové})f(S_i^{starý}) + f'(S_j^{nový})f'(S_i^{starý}) \quad (16)$$

Kde  $z$  je hodnota závislosti medzi dvoma konceptmi,  $S$  predstavuje stav konceptu a  $f$  sigmoidnú prahovú funkciu.

Výhodou aj nevýhodou tohto prístupu je nutnosť ohodnotenia počiatočného určenia stavov, ako aj závislostí expertmi. Samotný algoritmus *DHL* následne na základe historických dát skôr len mierne koriguje hodnoty závislosti, ich smer nedokáže meniť. Nie je preto použiteľný na plne automatizovanú tvorbu matice závislostí, avšak na základe historických dát dokáže upraviť expertne navrhnuté vzťahy relatívne jednoducho a časovo nenáročne. Algoritmus bol ďalej upravený do nelineárnej podoby (*Nonlinear Hebbian Learning*, Papageorgiou, E. I., 2003), pričom si ale zachováva kľúčové vlastnosti - potreba expertného vstupu na začiatku, resp. schopnosť upravovať len už existujúce závislosti.

### 1.5.2 Evolučné algoritmy

V prípade evolučných algoritmov sú názory expertov v plnej miere nahradené historickými dátami, na ktoré sú aplikované učiace algoritmy, resp. optimalizačné metódy. Úlohou evolučného algoritmu je teda vlastne vytvoriť maticu závislostí takú, ktorej dopady vplyvov na koncepty budú napodobňovať vývoj z poskytnutých historických dát [14].

### 1.5.2.1 Tvorba matice závislostí metódou RCGA

*RCGA*, resp. reálne kódované genetické algoritmy (angl. „*real-coded genetic algorithms*“), nevyžadujú žiadny expertný zásah a poskytujú výsledné matice závislostí vysokej kvality [09]. Hlavný rozdiel medzi binárnym genetickým algoritmom a reálne kódovaným genetickým algoritmom je v reprezentácii jednotlivých bitov chromozómu. Kým v binárnom genetickom algoritme je chromozóm reprezentovaný výhradne sekvenciou hodnôt 0 a 1, pri reálne kódovanom algoritme je obor hodnôt rozšírený o všetky hodnoty na intervale 0 až 1. Na základe experimentu bolo zistené, že aplikácia *RCGA* dosahuje presnejšie výsledky pri využití vždy len predchádzajúcej sady stavov konceptov, nie kompletnej sady historických dát. V tom prípade teda *k*-ty stav mapy vlastne predstavuje stimul a nasledujúci stav mapy jej odozvu na tento stimul. Tieto dvojice stavov sú nosičom informácie o dynamike v skúmanom systéme a sú zahrnuté v definícii fitness funkcie *RCGA*.

### 1.5.2.2 Optimalizácia matice závislostí kolóniou mravcov

Je vhodným algoritmom na optimalizáciu závislostí v mape na báze historických dát s aspoň 40 konceptmi. Inšpirácia algoritmu siaha ku skutočnému správaniu kolónie mravcov vo voľnej prírode. Mravec hľadá potravu a prehľadáva náhodne lokality najskôr v blízkosti mraveniska. Ak nájde potravu, vyhodnotí jej kvalitu, kvantitu a cestu označí feromónmi. Ostatné mravce tak dokážu na základe vytvorenej stopy objaviť najkratšiu cestu medzi mraveniskom a zdrojom potravy.

Cieľom účelovej funkcie algoritmu je minimalizovať odchýlku medzi správaním modelovanej fuzzy kognitívnej mapy a pozorovaným správaním v dátach. Algoritmus použije vstupné hodnoty konceptov a vypočíta ich nové hodnoty pomocou vyvodzovacieho mechanizmu. Ak tie nekonvergujú do ustáleného stavu, vypočíta hodnotu účelovej funkcie, optimalizuje maticu závislostí a pokračuje znova [23]. Algoritmus bol nasadený na niekoľko rôznych máp, pričom dosiahol dokonca lepšie výsledky než algoritmy *RCGA* či *DHL*, vzhľadom na meranú chybu modelu či štandardné odchýlky [02].

## 2 Cieľ práce, metodika práce a metódy skúmania

Fuzzy kognitívna mapa umožňuje zachytiť zložité dynamické systémy, vizualizovať ich štruktúru grafom a pomocou vyvodzovacieho mechanizmu simulovať dopady závislostí na jednotlivé prvky v mape. Cieľom tvorby fuzzy kognitívnej mapy je teda zachytiť vzťahy v určitom systéme a pomocou simulačného behu zistiť dopady ich vzájomných vplyvov v čase, čím sa buď vyvrátia alebo potvrdia vyslovené predpoklady o správaní systému.

V nasledujúcej kapitole je predstavená aplikácia fuzzy kognitívnej mapy pri modelovaní online spravodajského portálu. Cieľom tejto časti práce bolo vytvoriť model spravodajského webového portálu formou kognitívnej mapy, tú rozšíriť o fuzzy zložku a následne, pomocou vyvodzovacieho mechanizmu, simulovať a interpretovať dopady závislostí medzi kľúčovými konceptmi v čase.

Tvorba kognitívnej mapy, teda výber konceptov a určenie závislostí medzi nimi, prebehla expertným prístupom, na základe známej teórie tvorby fuzzy kognitívnych máp [02] [02], odborných znalostí o problematike a analýze dostupných dát. Počas tvorby mapy boli jednotlivé návrhy testované, až sa dosiahol výsledný počet konceptov a závislostí v mape, ako aj ich smerovanie.

Simulácie fuzzy kognitívnej mapy boli prevedené pre rôzne scenáre dvoma prístupmi. Prvý prístup predstavoval aplikáciu dnes už hojne využívaného numerického fuzzifikovaného modelu. Do intervalu 0 až 1 boli fuzzifikované fyzické množstvá, resp. intenzity kvality ako konceptov, tak aj závislostí. Pre vyvodenie nových hodnôt konceptov bol použitý modifikovaný vyvodzovací mechanizmus B. Koska [14].

V druhom prístupe boli stavy konceptov a intenzity závislostí zachytené slovne, formou hodnôt jazykových premenných, resp. ako fuzzy trojuholníkové čísla. Pre potreby simulácie bol navrhnutý mechanizmus [16] upravený tak, aby bol principiálne zhodný s mechanizmom pre vyvodzovanie fuzzifikovaných hodnôt, pričom si stále zachoval konvergentnú povahu.

Oba navrhnuté modely boli implementované v jazyku R, pričom pre numerický model s fuzzifikovanými hodnotami bola použitá už existujúca voľne dostupná knižnica „fcm“ a pre model s jazykovými premennými bol naprogramovaný vlastný vyvodzovací mechanizmus.

### 3 Výsledky práce

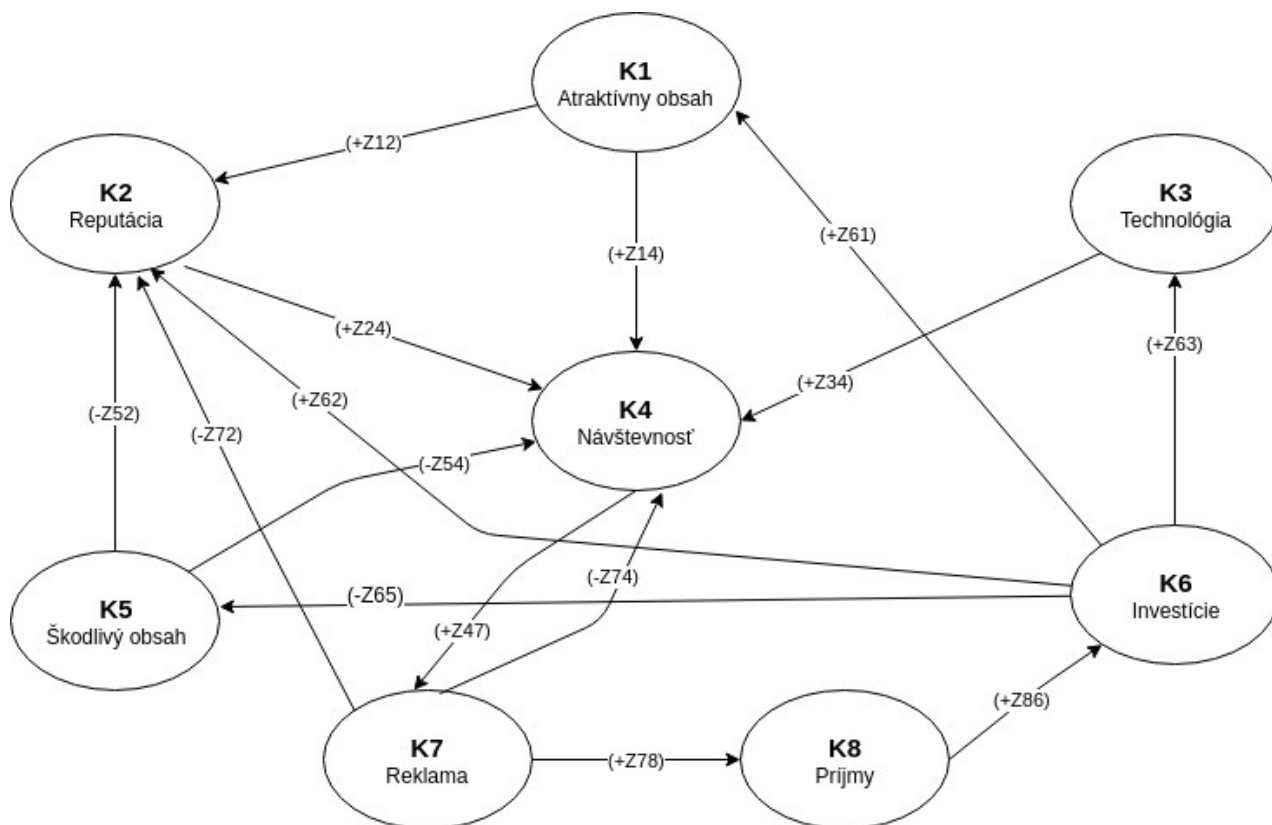
Modelový komerčný spravodajský portál bojuje o svojich čitateľov najmä tvorbou zaujímavého obsahu - či už písaného alebo multimediálneho, pričom jeho cieľom je zvyšovať čítanosť, resp. návštevnosť, čím rastie počet zobrazení reklamy a tým aj príjmy z nej. Kľúčovým faktorom, ovplyvňujúcim koncepty vplývajúce na návštevnosť, sú investície.

V nasledujúcich dvoch podkapitolách je predstavený dizajn kognitívnej mapy a podrobnejšie priblížená úvaha za výberom konceptov a závislostí medzi nimi.

#### 3.1 Dizajn fuzzy kognitívnej mapy spravodajského portálu

Ako prvý krok tvorby fuzzy kognitívnej mapy je nutné vybrať kľúčové koncepty systému. Následne sa určia závislosti medzi nimi - ako ich smer, tak aj ich povaha vplyvu.

Graf č. 5 - fuzzy kognitívna mapa webového spravodajského portálu



## 3.2 Výber konceptov a určenie závislostí medzi nimi

Koncepty boli vybrané na základe expertných znalostí. Hlavným cieľom komerčného webového portálu je maximalizovať svoj zisk, teda koncept *Príjmy*. Z grafu č. 5 je zrejmé, že jediná hrana s kladným ohodnotením, vstupujúca do uzla *Príjmy* (K8), je hrana z uzla *Reklama* (K7), nakoľko zvýšenie počtu zobrazení online reklamy zvýši aj finančné príjmy z nej. Na počet zobrazení reklamy kladne vplyva jediný uzol, *Návštevnosť* (K4), nakoľko vyššia návštevnosť znamená vyšší počet zobrazení reklamy. Na uzol *Návštevnosť* (K4) majú kladné vplyvy uzly K1, K2, a K3, pričom záporné vplyvy majú koncepty *Škodlivý obsah* K5 a *Reklama* K7.

Z navrhutej mapy je možné predpokladať, že ak chce portál dosiahnuť čo najvyššie príjmy, musia byť aj hodnoty konceptov vplývajúce na koncept *Návštevnosť* čo najvyššie a naopak, hodnota konceptu *Škodlivý obsah*, ktorý znižuje návštevnosť, čo najnižšia. Hodnota konceptu *Reklama* bude pravdepodobne niekde medzi vysokou a nízkou, nakoľko *Reklama* síce ako jediný koncept zvyšuje *Príjmy*, avšak zároveň znižuje *Návštevnosť* a *Reputáciu*.

Význam v aplikácii fuzzy kognitívnej mapy je však najmä v schopnosti zhrnúť jednotlivito formulované závislosti medzi konceptmi do jedného celku a následne, pomocou vyvodzovacieho mechanizmu pre výpočet nových hodnôt konceptov, potvrdiť alebo naopak vyvrátiť predpokladané správanie systému. Úvaha za výberom jednotlivých konceptov a závislosťami medzi nimi, je ďalej podrobnejšie priblížená nižšie.

### **Atraktívny obsah** (K1)

Publikovanie atraktívneho obsahu, teda pútavých článkov a multimedialného obsahu (foto/video), zvyšuje reputáciu portálu, ako aj jeho návštevnosť.

### **Reputácia** (K2)

Kladné povedomie o portály pozitívne vplyva na návštevnosť.

### **Technológia** (K3)

Technologické faktory ako rýchlosť odozvy serverov či responzívny dizajn zvyšujú komfort čitateľov, a tým aj návštevnosť.

### Návštevnosť (K4)

Spolu s rastom návštevnosti, resp. čítanosti, rastie aj počet zobrazení reklamy.

### Škodlivý obsah (K5)

Hoci zverejňovanie škodlivého obsahu nie je cieľom portálu, nie je možné tomuto javu úplne zamedziť. Zavádzajúci alebo čitateľsky nezaujímavý obsah znižuje reputáciu aj návštevnosť.

### Investície (K6)

Investície do portálu znižujú množstvo škodlivého obsahu a zvyšujú množstvo atraktívneho obsahu, úroveň technológie, ako aj reputáciu.

### Reklama (K7)

Prítomnosť reklamy negatívne ovplyvňuje návštevnosť a reputáciu, avšak zároveň ako jediný koncept zvyšuje finančné príjmy.

### Príjmy (K8)

Príjmy, ktoré nie sú vyvedené z firmy vo forme zisku, kladne zvyšujú investície do portálu.

Vzťahy medzi konceptmi a všeobecný smer ich vplyvu (kladný alebo záporný) je možné zaznačiť aj formou matice závislostí.

Matica závislostí navrhutej kognitívnej mapy (graf č. 5)

$$\mathbf{Z} = \begin{pmatrix} 0 & +Z_{12} & 0 & +Z_{14} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & +Z_{24} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & +Z_{34} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & +Z_{47} & 0 \\ 0 & -Z_{52} & 0 & -Z_{54} & 0 & 0 & 0 & 0 \\ +Z_{61} & +Z_{62} & +Z_{63} & 0 & -Z_{65} & 0 & 0 & 0 \\ 0 & -Z_{72} & 0 & -Z_{74} & 0 & 0 & 0 & +Z_{78} \\ 0 & 0 & 0 & 0 & 0 & +Z_{86} & 0 & 0 \end{pmatrix} \quad (2)$$

Graf č. 5 v predošlej kapitole predstavuje kognitívnu mapu webového portálu. Pre potreby simulačného behu bola navrhnutá mapa rozšírená o fuzzy zložku, a to dvoma

spôsobmi - numerickým modelom a slovným modelom. Pre každý z modelov boli pripravené tri identické scenáre - sady počiatkových stavov konceptov v mape - ktorých vývoj bol simulovaný pomocou vyvodzovacieho mechanizmu. Správanie, resp. interakcia konceptov počas simulácie a následný dosiahnutý ustálený stav bol interpretovaný a porovnaný s očakávaným vývojom pre každý scenár.

### 3.3 Model s fuzzifikovanými hodnotami konceptov a závislostí

Cieľom modelu s fuzzifikovanými hodnotami konceptov na intervale [0,1] a fuzzifikovanými hodnotami závislostí na intervale [-1,1] bolo pomocou implementácie vyvodzovacieho mechanizmu zistiť, či kognitívna mapa s navrhnutými závislosťami medzi konceptmi konverguje do ustáleného stavu, resp. do akého ustáleného stavu konceptov, alebo naopak, diverguje od počiatkových stavov konceptov. Na implementáciu vyvodzovacieho mechanizmu bol použitý jazyk  $R$  a voľne dostupná knižnica „ $fcm$ “ [12].

#### 3.3.1 Fuzzifikácia počiatkových stavov konceptov

Hodnoty konceptov môžeme určiť priamo expertným odhadom alebo – najmä v prípade, ak sú k dispozícii skutočné dáta - zostrojiť fuzzy jazykové premenné, ktoré budú jednoznačne mapovať akúkoľvek hodnotu konceptu do intervalu [0,1].

Hodnoty konceptov aj závislostí sú uvažované za štvrtročné obdobie, t.j. každá iterácia v simulácii predstavuje jeden štvrtrok. Počiatkové hodnoty konceptov kvantitatívnej povahy (obsah, návštevnosť, reklama, finančné zdroje) boli získané fuzzifikáciou reálnych alebo odhadnutých dát, a to vzťahom k pomeru k želanej hodnote:

$$x_{\text{fuzzyfikované}} = \frac{x_{\text{merané}}}{x_{\text{želané}}} \quad (17)$$

Počiatkové hodnoty konceptov kvalitatívnej, resp. ťažko kvantifikovateľnej povahy (reputácia, technológia), boli určené expertným odhadom. Pre ilustráciu je uvedená fuzzifikácia hodnôt tretieho scenára z kapitoly 3.1.1. – Kontroverzný spravodajský portál (*prvý scenár – Začínajúci portál s vysokými investíciami, druhý scenár – Začínajúci portál s*

vysokou úrovnou obsahu, technológie a miernou návštevnosťou), nakoľko v ňom bola zvolená najširšia škála hodnôt konceptov.

Tabuľka č. 1 – fuzzifikácia počiatkových stavov konceptov

Koncept	Nameraná hodnota	Najvyššia uvažovaná	Veličina	$\mu(K)$
(K1) Atraktívny obsah	116	500	články	0.232
(K2) Reputácia	-	-	odhad	0.125
(K3) Technológia	3	24	aktualizácie	0.125
(K4) Návštevnosť	124 026	500 000	návštevníci	0.248
(K5) Škodlivý obsah	18	20	články	0.9
(K6) Finančné zdroje	-	-	odhad	0.25
(K7) Reklama	20	24	kampane	0.833
(K8) Príjmy	-	-	odhad	0.125

### 3.3.2 Fuzzifikácia závislostí medzi konceptmi

Matica závislostí bola získaná ohodnotením hrán matice navrhutej vo všeobecnej kognitívnej mape v predošlej kapitole.

Matica závislostí – expertné odhady fuzzifikovaných hodnôt závislostí (graf č. 5)

$$\mathbf{Z} = \begin{pmatrix} 0 & +0.5 & 0 & +0.75 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & +0.375 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & +0.375 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & +0.75 & 0 \\ 0 & -0.75 & 0 & -0.375 & 0 & 0 & 0 & 0 \\ +0.625 & +0.125 & +0.125 & 0 & -0.625 & 0 & 0 & 0 \\ 0 & -0.5 & 0 & -0.125 & 0 & 0 & 0 & +0.875 \\ 0 & 0 & 0 & 0 & 0 & +0.625 & 0 & 0 \end{pmatrix} \quad (3)$$



### 3.4 Vывodzovací mechanismus pre nové hodnoty konceptov

Najčastejšie využívaným vывodzovacím pravidlom vo fuzzy kognitívnych mapách je vывodzovacie pravidlo navrhnuté Bartom Koskom [01]:

$$A_i(k+1) = f\left(\sum_{j=1, j \neq i}^N z_{ij} \times A_j(k)\right) \quad (18)$$

Kde  $A_i(k+1)$  je hodnota stavu  $i$ -teho konceptu v  $k+1$  kroku simulácie,  $A_j(k)$  je hodnota  $j$ -teho konceptu v  $k$ -tom kroku simulácie,  $w$  je ohodnotenie hrany (intenzity závislosti) medzi  $i$ -tym a  $j$ -tym konceptom a  $f$  je prahová funkcia, ktorá transformuje hodnoty do požadovaného intervalu  $[0,1]$ . Inými slovami, novú hodnotu konceptu vypočítame ako sumu produktu všetkých vplyvov na koncept a konceptov, z ktorých tieto vplyvy vychádzajú, pričom prahová funkcia zabezpečí normovanie výslednej hodnoty do požadovaného intervalu.


V simulačných scenároch bolo použité modifikované vывodzovacie pravidlo Barta Koska [12], ktoré zohľadňuje v prahovej funkcii aj predchádzajúcu hodnotu konceptu  $A_i(k)$ , nakoľko aj v slovnom modeli v kapitole 4 bolo navrhnuté pravidlo, ktoré zohľadňuje pri vывodzovaní aj aktuálny stav konceptu.

$$A_i(k+1) = f\left(A_i(k) + \sum_{j=1, j \neq i}^N z_{ij} \times A_j(k)\right) \quad (19)$$

Ako prahová funkcia bola zvolená sigmoidná funkcia s parametrom  $\lambda$ , nakoľko nemá význam uvažovať záporné hodnoty konceptov a zároveň bolo výhodné získať podrobnejšie informácie o vývoji konceptov (t.j. spojité hodnoty z intervalu 0 až 1), než poskytuje bivalentná prahová funkcia.

$$f(x) = \frac{1}{1 + e^{(-\lambda * x)}} \quad (20)$$

Graf č. 6 – priebeh prahovej funkcie s parametrom  $\lambda = 3$ , ktorý určuje jej strmosť



### 3.4.5 Scenáre simulačného behu s fuzzifikovanými hodnotami

Testovanie navrhnutej fuzzy kognitívnej mapy prebiehalo simuláciou, pričom boli navrhnuté tri sady počiatočných stavov konceptov, ktoré je možné interpretovať ako tri rôzne reálne scenáre online webového portálu. Pre potreby simulácie bol použitý jazyk *R* a knižnica „*fcm*“. Celý kód pre potreby simulácie s fuzzifikovanými hodnotami je uvedený v prílohe č. 1.

#### 3.4.5.1 Scenár I.

Prvý scenár má za cieľ simulovať vývoj konceptov začínajúceho spravodajského portálu. Fuzzifikáciou hodnôt boli získané nasledujúce počiatočné stavy konceptov:

Tabuľka č. 2 – fuzzifikované počiatočné stavy konceptov pre prvý scenár

Koncept	K1	K2	K3	K4	K5	K6	K7	K8
	atrakt. obsah	reputácia	technológia	návštevnosť	škod. obsah	investície	reklama	príjmy
Hodnota	0.125	0.125	0.125	0.125	0.125	0.875	0.125	0.125

Fuzzifikovanú hodnotu 0.875 konceptu *K6 Investície* by sme mohli pomocou slovnej premennej z kapitoly 4. interpretovať ako “*vysoké*”. Počiatočné hodnoty ostatných konceptov (*Atraktívny obsah, Reputácia, Návštevnosť, ...*) sú nízke.


Vzhľadom na to, že jediný koncept s vysokou hodnotou je koncept *Investície*, by sa práve tie mali „rozdistribuovať“ do jednotlivých uzlov – konceptov podľa navrhnutej matice závislostí medzi nimi, t.j. vývoj hodnôt ostatných konceptov závisí len od konceptu *Investície*

a navrhnutými závislosťami medzi konceptmi, čo sa aj potvrdilo v simulácii. Modifikovaný Koskov vyvodzovací mechanizmus sme nastavili s parametrami  $\lambda = 3$ , čo znamená mierne rýchlo rastúcu sigmoidnú funkciu a  $\epsilon = 0.01$ , t.j. ak sa stavy konceptov nezmenia s presnosťou na dve desatinné miesta, sú považované za ustálené. Simulácia dosiahla konvergovaný stav po šiestich iteráciách.

Tabuľka č. 3 – vývoj konceptov počas simulácie prvého scenára

	K1	K2	K3	K4	K5	K6	K7	K8
I.	0.125	0.125	0.125	0.125	0.125	0.875	0.125	0.125
II.	0.88242	0.60393	0.66888	0.67917	0.22000	0.94580	0.65841	0.66888
III.	0.98811	0.88157	0.91382	0.99303	0.24724	0.98356	0.97078	0.97668
IV.	0.99190	0.92296	0.95731	0.99861	0.24928	0.99169	0.99421	0.99584
V.	0.99211	0.92932	0.96245	0.99875	0.24757	0.99217	0.99467	0.99630
VI.	0.99212	0.93080	0.96301	0.99877	0.24645	0.99219	0.99468	0.99631

Graf č. 7 – vizualizácia stavov konceptov počas simulačného behu prvého scenára



Z priebehu hodnôt, resp. z grafu je zrejmé, že vplyvom počiatočných vysokých investícií sa ostatné veličiny priblížili k ustálenému stavu veľmi rýchlo – po šiestich iteráciách sa zmeny v hodnotách diali nanajvýš až za tretím desatinným miestom – pričom už od začiatku ďalej rástol aj samotný koncept *Investície*. Rovnako narástol aj koncept *Škodlivý*

obsah (K5), avšak v súlade s vysloveným predpokladom, že publikovaniu kontroverzného, resp. neatraktívneho obsahu nie je možné celkom zabrániť.

Pre porovnanie bola v simulácii rovnakého scenára použitá aj bivalentná prahová funkcia. V tom prípade koncepty konvergovali k ustálenému už v tretej iterácii, pričom hodnoty stavov konceptov sú uvedené v tabuľke. Hodnoty všetkých konceptov konvergovali v stave 1, len koncept *Škodlivý obsah (K5)* konvergoval do stavu 0, čiže rovnako v súlade s predpokladom vysloveným v úvode.

Tabuľka č. 4 – vývoj stavov konceptov s použitím bivalentnej prahovej funkcie

	K1	K2	K3	K4	K5	K6	K7	K8
I.	0.125	0.125	0.125	0.125	0.125	0.875	0.125	0.125
II.	1	1	1	1	0	1	1	1
III.	1	1	1	1	0	1	1	1

### 3.4.5.2 Scenár II.


Druhý scenár má podobný cieľ ako prvý, simulovať vývoj konceptov začínajúceho spravodajského portálu, avšak s inou stratégiou, resp. iným počiatočnými stavmi. Hodnoty konceptov *Atraktívny obsah* a *Reputácia* by sme pomocou slovných premenných mohli interpretovať ako *vysoké*, hodnotu konceptu *Návštevnosť* ako *miernu* a hodnoty ostatných konceptov, vrátane *Investícií*, sú teraz *nízke*. Po fuzzifikácii hodnôt do počiatočných stavov a následnom simulačnom behu boli získané nasledujúce stavy konceptov.

Tabuľka č. 5 – fuzzifikované počiatočné stavy konceptov pre druhý scenár

	K1 atrakt. obsah	K2 reputácia	K3 technológia	K4 návštevnosť	K5 škod. obsah	K6 investície	K7 reklama	K8 príjmy
<b>Počiat.</b>	0.875	0.875	0.125	0.5	0.125	0.125	0.125	0.125
<b>Konv.</b>	0.99212	0.92906	0.96307	0.99876	0.25137	0.99219	0.99468	0.99631

Simulácia s parametrami  $\lambda = 3$  a  $\epsilon = 0.01$  dosiahla konvergovaný stav po 11 iteráciách.

Graf č. 8 - vizualizácia stavov konceptov počas simulačného behu druhého scenára



Priebeh simulácie druhého scenára je zaujímavejší. Na dosiahnutie konvergovaného stavu bolo potrebných o 5 iterácií viac, ako v prípade prvého scenára, preto prvá stratégia je pre začínajúci portál výhodnejšia. Za zvolených počiatkových stavoch je vidieť nárast množstva *Škodlivého obsahu* (*K5*) až do momentu dosiahnutia určitej hodnoty *Investícií* v tretej iterácii. Nárast *Škodlivého obsahu* spôsobil pokles *Reputácie* (*K2*), ktorá začala opätovne rásť až o niekoľko iterácií neskôr.

### 3.4.5.3 Scenár III.


Tretí scenár reprezentuje kontroverzný online spravodajský portál s vysokým podielom škodlivého, resp. zavádzajúceho obsahu, malou návštevnosťou a vysokou frekvenciou zobrazovania reklám. Fuzzifikáciou počiatkových hodnôt konceptov a následným simulačným behom sme dostali nasledujúce stavy konceptov.

Tabuľka č. 6 – fuzzifikované počiatkové stavy konceptov pre tretí scenár

	K1	K2	K3	K4	K5	K6	K7	K8
	atrakt. obsah	reputácia	technológia	návštevnosť	škod. obsah	investície	reklama	príjmy
<b>Počiat.</b>	0.232	0.125	0.125	0.248	0.9	0.25	0.833	0.125
<b>Konv.</b>	0.99212	0.9263	0.96307	0.99874	0.25710	0.99219	0.99468	0.99631

Simulácia s parametrami  $\lambda = 3$  a  $\epsilon = 0.01$  dosiahla konvergovaný stav po 12 iteráciách.

Graf č. 9 – vizualizácia stavov konceptov počas simulačného behu tretieho scenára



Priebeh tretej simulácie bol taktiež v súlade s vyslovenými predpokladmi a konvergoval do rovnakého ustáleného stavu ako v prípade predošlých dvoch scenárov. Zaujímavý je priebeh vývoja konceptu *K2 Reputácia*, ktorý v druhej iterácii klesol ešte nižšie a až keď koncepty *Investície* a *Atraktívny obsah* dosiahli úroveň približne 0.68, resp. 0.82, začala stúpať aj *Reputácia*. Podobne koncept *K6 Škodlivý obsah* stagnoval na veľmi vysokej úrovni, až *Investície* dosiahli potrebnú výšku, ktorá ho začala znižovať až do ustáleného stavu.

### 3.5 Model s konceptmi a závislosťami ako fuzzy jazykovými premennými

V podmienkach reálneho sveta nie je vždy možné exaktne kvantifikovať veličiny v komplexných systémoch, či už kvôli komplexnosti podkladových dát alebo ich prípadnej úplnej absencii. Často je však možné stavy veličín uspokojivo opísať slovne. Na základe toho vznikla paradigma *CWW (angl. Computing with Words)*, ktorá umožňuje budovanie ľahko interpretovateľných modelov na báze racionálnych úvah [16].


V nasledujúcej časti práce bol model fuzzy kognitívnej mapy z predchádzajúcej kapitoly upravený tak, aby hodnoty závislostí, ako aj konceptov, boli jazykové premenné, a to nielen na vstupe a pri interpretácii výsledkov, ale aj priamo vyvodzovací mechanizmus bol upravený pre výpočet s jazykovými premennými ako trojuholníkovými fuzzy číslami.

### 3.5.1 Rozklad konceptov do jazykovej premennej

Každý koncept bol fuzzy rozkladom rozložený do jazykovej premennej s deviatimi hodnotami, opisujúcimi možné stavy jeho fyzického množstva, resp. intenzity kvality. Deväť hodnôt jazykovej premennej je dostačujúcich pre odlišenie stavov konceptov a zároveň sa nachádza v rámci pásma “sedem, plus mínus dva”, ktoré je považované za najvhodnejšie pre počet jazykových hodnôt vzhľadom na ľudské kognitívne schopnosti [17].

$S = \{ VN \text{ (veľmi nízky)}, N \text{ (nízky)}, SN \text{ (skôr nízky)}, MN \text{ (mierne nízky)}, M \text{ (mierny)},$   
 $MV \text{ (mierne vysoký)}, SV \text{ (skôr vysoký)}, V \text{ (vysoký)}, VV \text{ (veľmi vysoký)} \}$

Graf č. 10 – rozklad konceptov do jazykových premenných



Všeobecný tvar trojuholníkovej funkcie príslušnosti nefuzzifikovanej hodnoty do jazykovej premennej je možné analyticky vyjadriť ako funkciu:

$$\mu(x; a, m, b) = \begin{cases} 0, & x \leq a \\ \frac{(x-a)}{(m-a)}, & a \leq x \leq m \\ \frac{(b-x)}{(b-m)}, & m \leq x \leq b \\ 0, & b \leq x \end{cases} \quad (21)$$

Nakoľko hodnoty všetkých konceptov boli rozložené do jednej jazykovej premennej s rovnakými slovnými hodnotami uvedenými vyššie, a zároveň najnižšia možná hodnota každého konceptu je nula, je možné na fuzzifikáciu počiatkovej hodnoty každého konceptu použiť totožné funkcie príslušnosti. Zároveň je možné jednotlivé hodnoty jazykovej premennej použiť aj ako fuzzy čísla pre ohodnotenie počiatkových stavov konceptov.


### 3.5.2 Rozklad intenzity závislosti do jazykovej premennej

Každá závislosť medzi dvoma konceptmi bola rozložená do jazykovej premennej s deviatimi názvami, opisujúcimi intenzitu jej vplyvu:

$Z = \{ VS \text{ (veľmi slabý)}, S \text{ (slabý)}, SS \text{ (skôr slabý)}, MS \text{ (mierne slabý)}, M \text{ (mierny)}, MV \text{ (mierne vysoký)}, SV \text{ (skôr vysoký)}, V \text{ (vysoký)}, VV \text{ (veľmi vysoký)},$   
 $-VS \text{ (veľmi slabo záporný)}, -S \text{ (slabo záporný)}, -SS \text{ (skôr slabo záporný)}, -MS \text{ (mierne slabo záporný)}, -M \text{ (mierne záporný)}, -MV \text{ (mierne vysoko záporný)}, -SV \text{ (skôr vysoko záporný)}, -V$   
 $\text{ (vysoko záporný)}, -VV \text{ (veľmi vysoko záporný)}, \}$

Nakoľko závislosť medzi dvoma konceptmi môže byť ako kladná (spôsobovať nárast jeho hodnoty), tak aj záporná (spôsobovať jeho pokles), je nutné uvažovať rovnaký slovný rozklad závislostí s opačným vplyvom.

Graf. č. 11 – fuzzy rozklad intenzity závislosti do jazykovej premennej (len kladné hodnoty)





### 3.5.3 Závislosti ako jazykové premenné

Matica závislostí s hodnotami jazykových premenných bola vytvorená z matice závislostí s fuzzifikovanými premennými, pričom slovné hodnoty boli určené podľa najvyššej príslušnosti fuzzifikovaných prvkov.

Matica závislostí s hodnotami slovnej premennej (graf č. 5)


$$\mathbf{Z} = \begin{pmatrix} 0 & +M & 0 & +SV & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & +MS & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & +MS & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & +SV & 0 \\ 0 & -SV & 0 & -MS & 0 & 0 & 0 & 0 \\ +MV & +S & +S & 0 & -MV & 0 & 0 & 0 \\ 0 & -M & 0 & -S & 0 & 0 & 0 & +V \\ 0 & 0 & 0 & 0 & 0 & +M & 0 & 0 \end{pmatrix} \quad (4)$$

### 3.5.4 Interpretácia vzťahov v mape so slovnými hodnotami

Nakoľko všetky hodnoty premenných v modeli sú hodnoty slovných premenných, je možné na základe smeru dopadu závislosti medzi dvoma konceptmi formulovať nasledujúci všeobecný výrok, využiteľný na interpretáciu ľubovoľného vzťahu medzi dvoma konceptmi v mape.

$$\begin{aligned} \{S_i\} \text{ stav konceptu } \{K_{(i)}\} \text{ sa vplyvom závislosti } \{Z_{ji}\} \\ \text{konceptu } K_{(j)} \text{ so stavom } \{S_j\} \text{ zmenil na stav } \{S_{(i+1)}\} \end{aligned} \quad (22)$$

Graf č. 12 – slovný mechanizmus interpretácie dopadu závislostí v mape



### 3.5.5 Vyvodzovací mechanismus pro nové hodnoty konceptov

Nakoľko sú počiatkové stavy konceptov a hodnoty závislostí trojuholníkové fuzzy čísla, je nutné navrhnúť nový vyvodzovací mechanismus pre prácu s nimi. Vyvodzovací mechanismus pre simuláciu s fuzzy jazykovými premennými je možné stručne predstaviť ako postupnosť nasledujúcich krokov:

1. Pre každý vplyv na koncept vypočítaj hodnotu tohto vplyvu ako produkt trojuholníkového čísla závislosti a východzieho konceptu.
2. Sčítaj všetky trojuholníkové čísla vplyvov a výsledné trojuholníkové číslo preved' na slovnú hodnotu (podľa najmensej odchýlky od definovaných slovných hodnôt premennej *Závislost*).
3. Vypočítaj novú hodnotu konceptu ako súčet vplyvu a trojuholníkového čísla konceptu a výsledné číslo preved' na slovnú hodnotu (podľa najmensej odchýlky od definovaných slovných hodnôt premennej *Stav* konceptu).

Matematický aparát, aplikovaný v navrhnutom vyvodzovacom mechanizme, vychádza zo zaužívanej teórie fuzzy logiky a je približený nižšie. Vyvodzovací mechanismus je zobrazený aj vo forme grafu v ďalšej kapitole. Vzhľadom na výpočtovú náročnosť bol vyvodzovací mechanismus pre potreby simulácií implementovaný v jazyku R.

#### 3.5.5.1 Násobenie dvoch jazykových premenných

V prvom kroku je nutné vynásobiť hodnotu jazykovej premennej každej hrany vstupujúcej do konceptu, s hodnotou konceptu, z ktorej hrana vystupuje. Jazykové premenné sú definované ako trojuholníkové fuzzy čísla. Pre každé fuzzy trojuholníkové číslo platí:

$$\tau(A) = [a^D, a^S, a^H]$$
$$a^D \leq a^S \leq a^H$$

$a^D$  – dolné ohraničenie nosiča    (23)  
 $a^S$  – plná príslušnosť  
 $a^H$  – horné ohraničenie nosiča

Pričom platí, že fuzzy číslo A je konvexné, jeho nosič je ohraničený a je normálne (obsahuje prvok s plnou príslušnosťou, t.j. 1). Pre násobenie dvoch trojuholníkových čísel potom môžeme využiť vzťah:

$$\tau(a) \times \tau(b) = [\min(a^D * b^D, a^D * b^S, a^H * b^D, a^H * b^S), \max(a^D * b^D, a^D * b^S, a^H * b^D, a^H * b^S)]$$

(24)

### 3.5.5.2 Sčítanie výsledných trojuholníkových čísel konceptu

Agregáciu vplyvu konceptov na vypočítavaný koncept vyjadríme súčtom vynásobených trojuholníkových čísel.

$$\tau(K_i^{(k+1)}) = \sum_{j=1}^{N_k} \tau_j$$

$\tau$  – trojuholníkové fuzzy číslo (25)  
*i* – poradie konceptu  
*k* – číslo kroku iterácie

Pričom trojuholníkové fuzzy čísla je možné sčítať intuitívne podľa vzťahu:

$$\tau(a) + \tau(b) = (a^D + b^D, a^S + b^S, a^H + b^H) \quad (26)$$

### 3.5.5.3. Výpočet odchýlok trojuholníkových čísel

Kým vo vyvodzovacom mechanizme pre fuzzifikované hodnoty normuje vypočítanú hodnotu do intervalu [0,1] prahová funkcia, v prípade navrhnutého mechanizmu plní túto úlohu nižšie uvedený vzorec pre výpočet rezídua súčtu trojuholníkových čísel od jazykovej premennej.

$$\delta(A, B) = \sqrt{\frac{1}{3} * [(a^D - b^D)^2 + (a^S - b^S)^2 + (a^H - b^H)^2]}$$

pričom:

$$A(a^D, a^S, a^H) \text{ je trojuholníkové číslo konceptu, tj. } \tau(K_i^{(k+1)}) \quad (27)$$

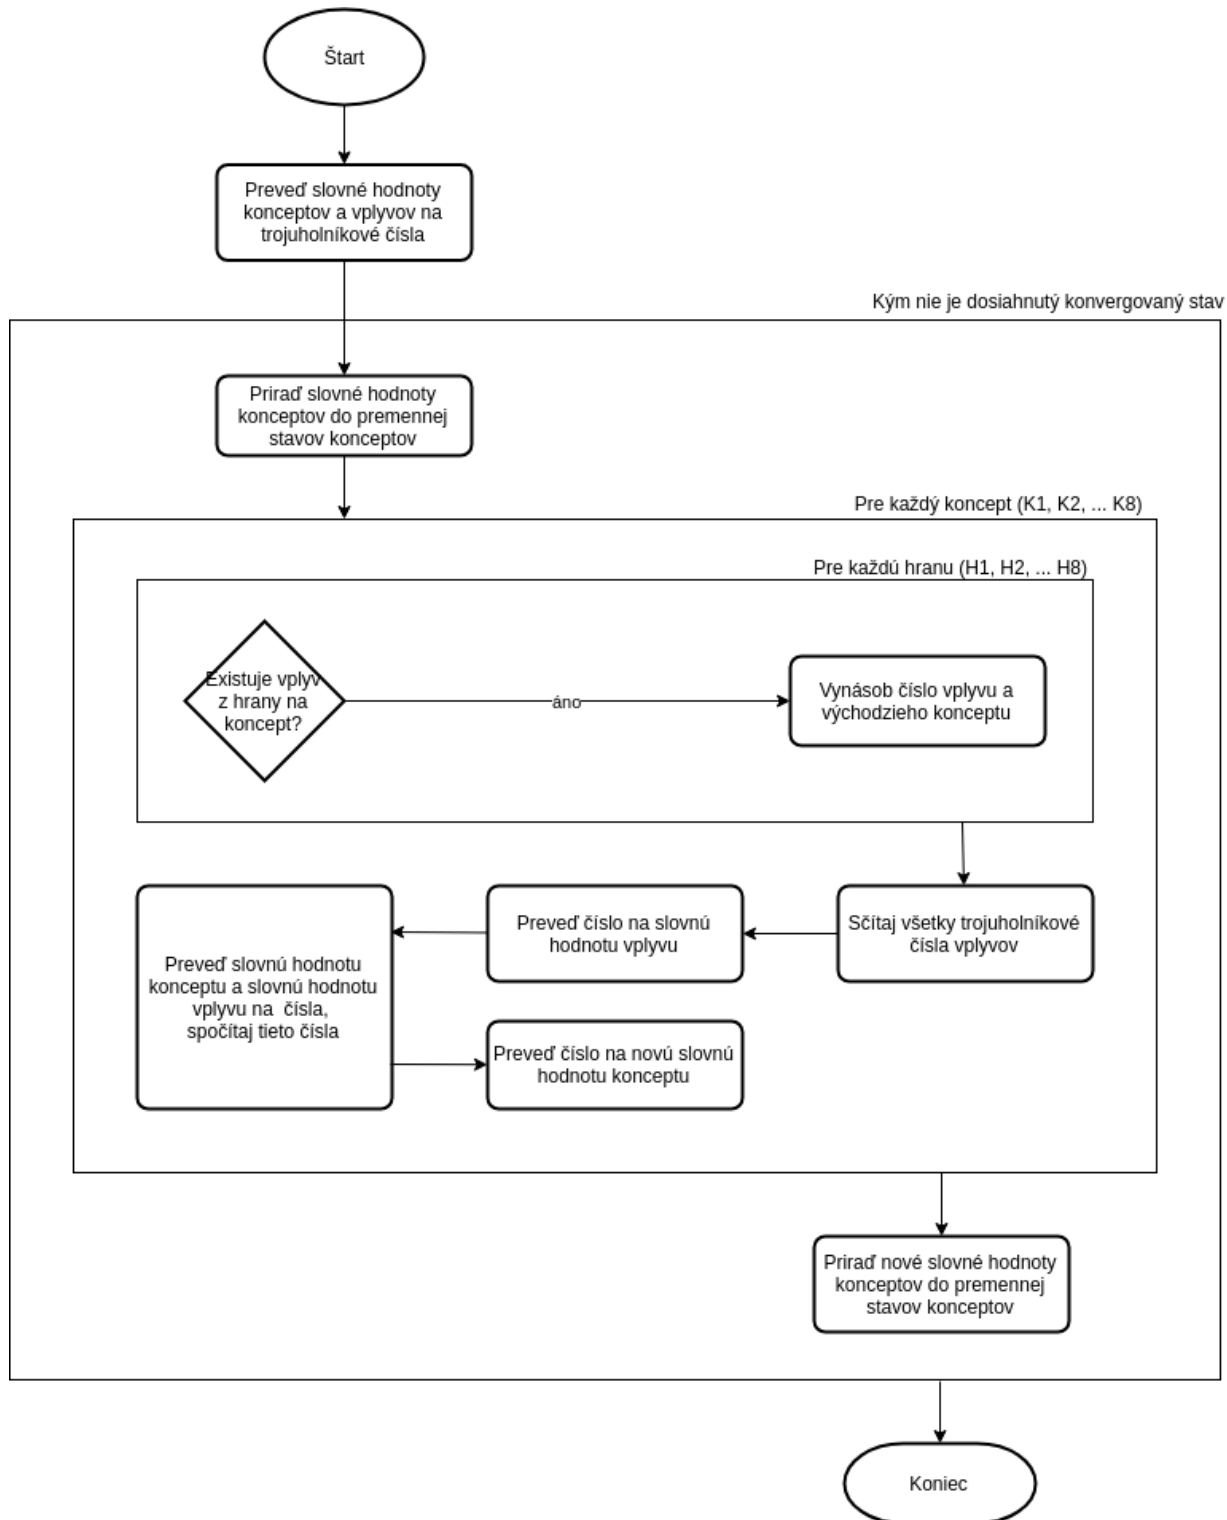
$$B(b^D, b^S, b^H) \text{ je trojuholníkové číslo závislosti, tj. } \tau(Z_k)$$

V druhom aj treťom kroku je nutné previesť vypočítané trojuholníkové číslo na hodnotu slovnej premennej. Vypočíta sa teda odchýlka trojuholníkového čísla od každej hodnoty jazykovej premennej. Najmenšia odchýlka predstavuje slovnú hodnotu daného čísla.

#### 3.5.5.4 Algoritmus v jazyku R

Nakoľko momentálne neexistuje dostupná knižnica v jazyku R pre fuzzy kognitívne mapy so slovnými premennými, vzhľadom na výpočtovú náročnosť bolo pre potreby simulačných behov nutné navrhnuť vlastný algoritmus. Na grafe č. 13 je zobrazený princíp fungovania algoritmu ako diagram. Celý kód je aj s komentármi uvedený v prílohe č. 2.

Graf č. 13 – vyvodzovací mechanismus pre simuláciu so slovnými premennými



### 3.5.6 Scenáre simulačného behu modelu so slovnými hodnotami

Pre potrebu simulácie jednotlivých scenárov so slovnými premennými a následné porovnanie s fuzzifikovaným modelom bolo nutné priradiť im čo najpodobnejšie hodnoty, ako mali fuzzifikované premenné na intervale  $[0,1]$ . Hodnoty slovných premenných jednotlivých konceptov boli teda určené podľa najvyššej príslušnosti numerickej fuzzifikovanej hodnoty – singletonu - do hodnoty slovnej premennej.

#### 3.5.6.1 Scenár I.

Prvý scenár predstavuje začínajúci portál s vysokou úrovňou investícií, pričom hodnoty všetkých ostatných konceptov sú nízke. Očakávaný vývoj stavov konceptov je zhodný s predpokladom vo fuzzifikovanom modeli – *Investície* by mali postupne zvýšiť všetky hodnoty konceptov, až na *Škodlivý obsah*, na ktorý majú mierne vysoko záporný vplyv.

Hodnoty slovnej premennej *Stav* konceptu boli získané fuzzifikáciou hodnôt scenára predošlého modelu, pomocou funkcie príslušnosti do jazykovej premennej. Slovná hodnota bola zvolená podľa najvyššej hodnoty jej funkcie príslušnosti. Napríklad výpočet prevodu konceptu  $K6 = 0.875$  na slovnú hodnotu bol nasledovný:

$$x_{K6} = 0.875$$
$$\mu_{\text{vysoký}}(x_{K6}; 0.75, 0.875, 1) = \frac{(x_{K6} - 0.75)}{(0.875 - 0.75)} = 1 \quad (28)$$

Príslušnosť do jazykovej hodnoty stavu *Vysoký* je úplná, t.j. 1, takže slovná hodnota stavu konceptu je vysoká.

Hodnoty konceptov v prvom a druhom scenári fuzzifikovaného modelu boli zámerne zvolené tak, aby ich príslušnosť do slovných premenných bola úplná, t.j. rovná jednej. Bolo tak urobené z dôvodu vylúčenia vplyvu nepresností, a teda čo najlepšieho porovnania obidvoch modelov.

Tabuľka č. 7 – počiatkové hodnoty slovných premenných konceptov

<b>Koncept</b>	K1 atrakt. obsah	K2 reputácia	K3 technológia	K4 návštevnosť	K5 škod. obsah	K6 investície	K7 reklama	K8 príjmy
<b>Hodnota</b>	N nízky	N nízka	N nízka	N nízka	N nízky	V vysoké	N nízka	N nízke

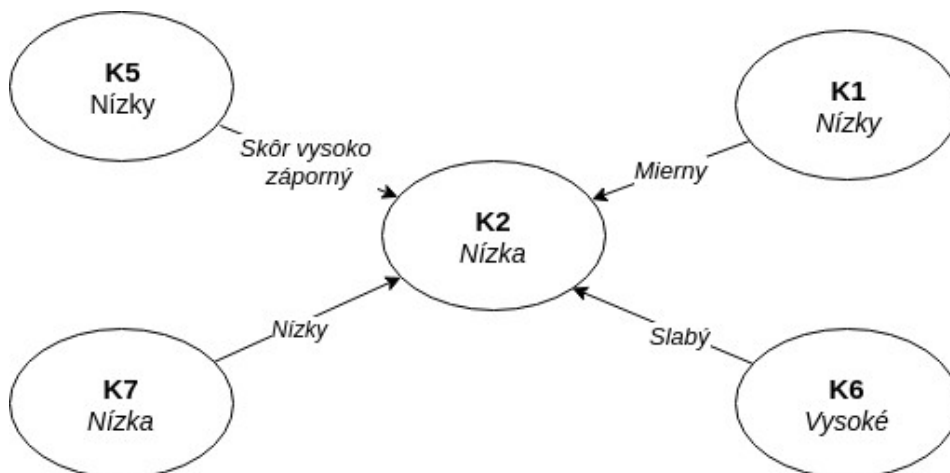
### 3.5.6.2 Príklad výpočtu novej hodnoty druhého konceptu

Pre ilustráciu fungovania navrhnutého vyvodzovacieho mechanizmu je uvedený nasledujúci výpočet novej hodnoty konceptu *K2*. Koncept *Reputácia K2* má počiatkový stav *S* „nízky“. Na koncept *K2* vplyvajú ďalšie štyri koncepty s rôznym stavom a rôznou intenzitou vplyvu. Koncepty a intenzity vplyvu sú uvedené v tabuľke nižšie.

Tabuľka č. 8 - koncepty a závislosti ako slovné premenné a trojuholníkové čísla

Koncept	Koncept slovne	Koncept ako číslo	Vplyv slovne	Vplyv ako číslo
K1	Nízky	(0, 0.125, 0.25)	Mierne kladný	(0.375, 0.5, 0.625)
K5	Nízky	(0, 0.125, 0.25)	Skôr vysoko záporný	(-0.625, -0.75, -0.875)
K6	Vysoký	(0.75, 0.875, 1)	Slabo kladný	(0, 0.125, 0.25)
K7	Nízky	(0, 0.125, 0.25)	Mierne záporný	(-0.375, -0.5, -0.625)

Graf č. 14 - ilustrácia vplyvov na koncept *K2 Reputácia* vo forme grafu



V prvom kroku vypočítame jednotlivé vplyvy na koncept K2, a to ako produkt *trojuholníkové číslo konceptu \* trojuholníkové číslo vplyvu*:

$$\begin{aligned}
 \text{Vplyv1: } \tau(N) * \tau(+M) &= \tau(0, 0.125, 0.25) * \tau(0.375, 0.5, 0.625) = \tau(0, 0.0625, 0.15625) \\
 \text{Vplyv2: } \tau(N) * \tau(-SV) &= \tau(0, 0.125, 0.25) * \tau(-0.625, -0.75, -0.875) = \tau(-0.21875, -0.09375, 0) \\
 \text{Vplyv3: } \tau(V) * \tau(+S) &= \tau(0.75, 0.875, 1) * \tau(0, 0.125, 0.25) = \tau(0, 0.109375, 0.25) \\
 \text{Vplyv4: } \tau(N) * \tau(-M) &= \tau(0, 0.125, 0.25) * \tau(-0.375, -0.5, -0.625) = \tau(-0.15625, -0.0625, 0) \\
 \tau(\text{Vplyv1}) + \tau(\text{Vplyv2}) + \tau(\text{Vplyv3}) + \tau(\text{Vplyv4}) &= (-0.375, 0.015625, 0.40625) = \tau(\text{Vplyv})
 \end{aligned}$$

V ďalšom kroku vypočítame všetky odchýlky výsledného vplyvu na koncept K2. Najmenšia odchýlka výsledného vplyvu od trojuholníkového čísla závislosti je slovná hodnota výsledného vplyvu.

$$\begin{aligned}
 & \frac{\delta(\tau(\text{Vplyv}), \tau(-VV))}{\sqrt{(1/3 * ((-0.375 - (-0.875))^2 + (0.015625 - (-1))^2 + (0.40625 - (-1))^2))}} = 1.0423 \\
 & \frac{\delta(\tau(\text{Vplyv}), \tau(-V))}{\sqrt{(1/3 * ((-0.375 - (-0.75))^2 + (0.015625 - (-0.875))^2 + (0.40625 - (-1))^2))}} = 0.9851 \\
 & \frac{\delta(\tau(\text{Vplyv}), \tau(+S))}{\sqrt{(1/3 * ((-0.375 - (0))^2 + (0.015625 - (0.125))^2 + (0.40625 - (0.25))^2))}} = \mathbf{0.2429} \\
 & \frac{\delta(\tau(\text{Vplyv}), \tau(+VV))}{\sqrt{(1/3 * ((-0.375 - (+0.875))^2 + (0.015625 - (+1))^2 + (0.40625 - (+1))^2))}} = 0.9805
 \end{aligned}$$

Najmenšie rezíduum výsledného vplyvu bolo vypočítané od hrany závislosti *Slabá* (0.2429), takže výsledná slovná hodnota intenzity vplyvu na koncept K2 je „*Slabá*“.

V ďalšom kroku spočítame stav konceptu K2 *Nízky* s intenzitou celkového vplyvu na tento koncept, *Slabý*. Slovné hodnoty spočítame opäť ako trojuholníkové fuzzy čísla zodpovedajúce slovným hodnotám.

$$\begin{aligned}
 \tau(N) + \tau(S) &= (0 + 0, 0.125 + 0.125, 0.25 + 0.25) \\
 \tau(N) + \tau(S) &= (0, 0.25, 0.5)
 \end{aligned}$$



Opäť vypočítame odchýlky výsledného čísla, tentoraz od hodnôt konceptov. Slovná hodnota konceptu s najnižšou odchýlkou od vypočítaného čísla je nová slovná hodnota konceptu K2.

$$\delta(\tau(\text{Koncept}), \tau(+SN)) = \sqrt{(1/3 * ((0 - (+0.125))^2 + (0.25 - (+0.25))^2 + (0.5 - (+0.375))^2))} = 0.1021$$

Hodnota konceptu K2 *Reputácia* sa teda pod vplyvom vyššie uvedených konceptov zmenila zo stavu *Nízka* na stav *Skôr nízka*, t.j. jej stav narástol.

### Vývoj konceptov počas simulačného behu

Výsledné hodnoty simulačného behu algoritmu boli zaznačené do tabuľky. Prírastok konceptu je zvýraznený zelenou farbou, pokles jeho hodnoty červenou. Žiadna zmena je reprezentovaná čiernou farbou. Žltou farbou je zvýraznená iterácia konceptu K2 z hodnoty *Nízka* na *Skôr nízka*, numericky ilustrovaná vyššie.

Tabuľka č. 9 – vývoj konceptov po jednotlivých iteráciách

	<b>K1</b>	<b>K2</b>	<b>K3</b>	<b>K4</b>	<b>K5</b>	<b>K6</b>	<b>K7</b>	<b>K8</b>
I.	N	N	N	N	N	V	N	N
II.	MV	SN	SN	SN	VN	V	SN	SN
III.	VV	M	MN	V	VN	V	M	M
IV.	VV	SV	M	VV	VN	VV	VV	V
V.	VV	V	MV	VV	VN	VV	VV	VV
VI.	VV	V	SV	VV	VN	VV	VV	VV
VII.	VV	V	V	VV	VN	VV	VV	VV
VIII.	VV	V	V	VV	VN	VV	VV	VV

Konvergovaný stav bol dosiahnutý v ôsmom kroku simulačného behu. V prípade modelu s fuzzifikovanými hodnotami sa konvergovaný stav pri  $\varepsilon = 0.01$  dosiahol už po šiestich iteráciách.

Koncept *Škodlivý obsah (K5)* sa ustálil na hodnote *Veľmi nízky*, koncepty *Reputácia* a *Technológia* na úrovni *Vysoká* a ostatné koncepty na úrovni *Veľmi vysoká*. V prípade modelu s fuzzifikovanými konceptmi sa ich hodnoty pohybujú v intervale 0.9293 až 0.9987 pre všetky koncepty okrem konceptu K5 (0.2476). Oba modely teda konvergovali k približne zhodným stavom konceptov.

Priebehy stavov konceptov boli pre prvý scenár v oboch modeloch monotónne, t.j. každý z konceptov od začiatku buď rástol alebo klesal, trend jeho vývoja sa nemenil.

### Interpretácia dopadov závislostí na stavy konceptov

Na rozdiel od kognitívnej mapy s fuzzy hodnotami na intervale  $[0,1]$ , resp.  $[-1,1]$ , je možné dopady závislostí v kognitívnej mape s jazykovými premennými slovne interpretovať veľmi jednoducho. Napríklad vývoj konceptu *K8 Príjmy*, ktorého stav závisí od konceptu *K7 Reklama*, je možné slovne opísať podľa mechanizmu navrhnutého v kapitole 4.4 nasledovne:

I. iterácia

*Nízka úroveň príjmov sa vysokým vplyvom nízkej úrovne reklamy zmenila na skôr nízku.*

II. iterácia

*Skôr nízka úroveň príjmov sa vysokým vplyvom skôr nízkej úrovne reklamy zmenila na miernu.*

III. iterácia

*Mierna úroveň príjmov sa vysokým vplyvom miernej úrovne reklamy zmenila na vysokú.*

IV. iterácia

*Vysoká úroveň príjmov sa vysokým vplyvom veľmi vysokej úrovne reklamy zmenila na veľmi vysokú.*

### 3.5.6.2 Scenár II.

Druhý scenár predstavuje začínajúci portál s počiatočnými stavmi konceptov, ktorých hodnoty slovných premenných sú uvedené v tabuľke.

Tabuľka č. 10 – počiatočné hodnoty slovných premenných konceptov

Koncept	K1	K2	K3	K4	K5	K6	K7	K8
	atrakt. obsah	reputácia	technológia	návštevnosť	škod. obsah	investície	reklama	príjmy
Hodnota	V	V	N	M	N	N	N	N
	vysoký	vysoký	nízka	mierna	nízky	nízke	nízka	nízke

Tabuľka č. 11 – vývoj konceptov po jednotlivých iteráciách

	K1	K2	K3	K4	K5	K6	K7	K8
I.	V	V	N	M	N	N	N	N
II.	V	VV	N	VV	VN	N	M	SN
III.	V	VV	N	VV	VN	SN	VV	SV
IV.	V	VV	N	VV	VN	MV	VV	VV
V.	VV	VV	SN	VV	VN	VV	VV	VV
VI.	VV	VV	MN	VV	VN	VV	VV	VV
VII.	VV	VV	M	VV	VN	VV	VV	VV
VIII.	VV	VV	MV	VV	VN	VV	VV	VV
IX.	VV	VV	SV	VV	VN	VV	VV	VV
X.	VV	VV	V	VV	VN	VV	VV	VV
XI.	VV	VV	V	VV	VN	VV	VV	VV

Oba modely dosiahli podobný ustálený stav zhodne v 11. kroku simulácie. V druhom scenári sa však líši vývoj stavov konceptov K2 a K5. Kým v slovnom modeli sú ich priebehy monotónne, v modeli s fuzzifikovanými hodnotami koncept K2 najskôr rastie, potom klesá, až následne opäť rastie až do ustáleného stavu. Koncept K5 prvé 2 iterácie rastie a až potom klesá do ustáleného stavu.

Odlišnosť priebehu stavov niektorých konceptov pramení z neurčitosti fuzzy čísiel. Vzhľadom na zhodné smery závislostí v oboch modeloch však pri dostatočom počte iterácií oba konvergujú k podobným výsledkom.

### 3.5.6.3 Scenár III.

Tretí scenár predstavuje kontroverzný portál s počiatočnými stavmi konceptov, ktorých hodnoty slovných premenných sú uvedené v tabuľke.

Tabuľka č. 12 – počiatočné hodnoty slovných premenných konceptov

Koncept	K1 atrakt. obsah	K2 reputácia	K3 technológi a	K4 návštevnosť	K5 škod. obsah	K6 investície	K7 reklama	K8 príjmy
Hodnota	SN skôr nízky	N nízka	N nízka	SN skôr nízka	V nízky	SN skôr nízke	V vysoká	N nízke

Tabuľka č. 13 – vývoj konceptov po jednotlivých iteráciách

	K1	K2	K3	K4	K5	K6	K7	K8
I.	SN	N	N	SN	V	SN	V	N
II.	MN	VN	N	SN	V	SN	VV	V
III.	M	VN	N	MN	V	SV	VV	VV
IV.	V	VN	SN	M	MN	VV	VV	VV
V.	VV	VN	MN	V	VN	VV	VV	VV
VI.	VV	N	M	VV	VN	VV	VV	VV
VII.	VV	SN	MV	VV	VN	VV	VV	VV
VIII.	VV	MN	SV	VV	VN	VV	VV	VV
IX.	VV	M	V	VV	VN	VV	VV	VV
X.	VV	MV	V	VV	VN	VV	VV	VV
XI.	VV	SV	V	VV	VN	VV	VV	VV
XII.	VV	V	V	VV	VN	VV	VV	VV
XIII.	VV	V	V	VV	VN	VV	VV	VV

Simulácia slovného modelu dosiahla ustálený stav v 13. kroku, model s fuzzifikovanými hodnotami a  $\varepsilon = 0.01$  dosiahol ustálený stav v 12. kroku. Trend vývoja konceptov v treťom scenári je zhodný v simuláciách oboch modelov.

## 4. Diskusia

V predošlej kapitole bola navrhnutá kognitívna mapa online spravodajského portálu. Navrhnutá mapa bola rozšírená o fuzzy zložku dvoma spôsobmi – fuzzifikáciou hodnôt konceptov a závislostí v jednom modeli a priradením fuzzy slovných hodnôt konceptom a závislostiam v druhom.

Klasická kognitívna mapa umožňuje reprezentáciu kľúčových konceptov v systéme a smeru vplyvov medzi nimi. Avšak kauzalita nie je binárnej povahy [01], preto je možné prítomnosť závislosti medzi dvoma konceptmi presnejšie vyjadriť pomocou miery príslušnosti fuzzy logiky. Kognitívnym mapám rovnako chýba mechanizmus na vyvodzovanie dopadov týchto závislostí, v ekonomických aplikáciách slúžia teda najmä na zachytenie vedomostí o skúmanom systéme.

Tabuľka č. 14 - porovnanie kľúčových vlastností modelov

	<b>Fuzzifikované premenné</b>	<b>Slovné premenné</b>
Konvergentný model	Áno <i>(resp. podľa dizajnu mapy)</i>	Áno <i>(resp. podľa dizajnu mapy)</i>
Využitie	Najmä ak existujú historické dáta	Najmä pri expertných odhadoch
Príprava vstupných hodnôt	Zložitejšia <i>(fuzzifikácia ostrých hodnôt)</i>	Jednoduchá <i>(výber slovných hodnôt)</i>
Vyvodzovací mechanizmus	Menej náročný na výpočet	Náročnejší na výpočet
Interpretácia výsledkov	Zložitejšia <i>(nutný prevod numerických hodnôt na slovné hodnoty)</i>	Jednoduchá <i>(dostupné slovné hodnoty v ktorejkoľvek iterácii)</i>

### 4.1 Porovnanie navrhnutých modelov

Spoločnou vlastnosťou oboch modelov je konvergencia k približne rovnakému ustálenému stavu. Pre žiadny z navrhnutých ani testovacích scenárov nebolo pozorované divergentné, t.j. chaotické správanie konceptov v mape.

Modely sa však líšia potenciálnym využitím. V prípade, ak sú dostupné historické dáta konceptov, poskytnú potenciálne presnejšie výsledky priama fuzzifikácia týchto hodnôt a prípadné nasadenie učiaceho algoritmu na generovanie matice závislostí. Naopak, ak dáta nie sú dostupné, môžu práve jazykové premenné pomôcť objektívnejšie a jednoduchšie opísať stavy konceptov a intenzity závislostí, najmä, ak je nutné nájsť zhodu medzi viacerými expertnými názormi.

Rozdielne sú aj vyvodzovacie mechanizmy. Navrhnutý mechanizmus pre vyvodzovanie so slovnými hodnotami, t.j. trojuholníkovými číslami, je zložitejší, nakoľko každé trojuholníkové číslo pozostáva z troch prvkov, násobenie dvoch trojuholníkových čísiel vyžaduje násobenie prvkov každého z nich (karteziánsky súčin), je potrebné hľadanie minima a maxima, výpočet odchýlky čísla od definovaných hodnôt slovnej premennej a ďalšie operácie. Hoci by bolo možné navrhnutý algoritmus ďalej optimalizovať - napríklad využitím preddefinovaného zoznamu všetkých možných produktov dvoch slovných hodnôt – nie je možné sa priblížiť k výpočtovo menej náročnému mechanizmu pre vyvodzovanie fuzzifikovaných hodnôt. Výpočtová náročnosť je preto nevýhodou slovného modelu.

Naopak, výhodou slovného modelu je možnosť zrozumiteľnej a prípadne aj automatizovanej interpretácie stavu kognitívnej mapy v ktoromkoľvek kroku simulačného behu. Rovnaký mechanizmus na slovnú interpretáciu stavov je však možné aplikovať aj v prípade numerického modelu, t.j. rozklad hodnôt konceptov do jazykovej premennej a následné priradenie hodnoty podľa príslušnosti do konkrétneho stavu. Nakoľko ale model pracuje s numerickými hodnotami v intervale -1 až 1, bolo by nutné zakaždým previesť numerickú hodnotu na slovnú pomocou funkcie príslušnosti.

## 4.2 Možné oblasti zlepšenia a trendy

Fuzzy kognitívne mapy sú svojou povahou blízke neurónovým sieťam, umožňujú modelovanie zložitých systémov s istou mierou neurčitosti. Hlavným nedostatkom neurónových sietí, resp. všeobecne strojového učenia a umelej inteligencie, je nemožnosť interpretácie výsledkov. Kvôli konceptu tzv. čiernej skrinky nie je možné zistiť, ako a prečo dospel algoritmus strojového učenia k určitým záverom. Trendom je tzv. vysvetliteľná umelá inteligencia, EAI (angl. *Explainable AI*), ktorá umožňuje zdôvodnenie dosiahnutého riešenia, ako aj jeho reprodukciu [08]. Prístup tvorby fuzzy kognitívnych máp spĺňa požiadavky EAI.

Po výbere konceptov sa učiacim algoritmom na základe dát vygeneruje matica závislostí. Pôvod takéhoto riešenia je vďaka tomu vysvetliteľný [21].

Predstavené fuzzy kognitívne mapy umožňujú modelovanie len monotónnej kauzality. Možným riešením sú fuzzy kognitívne mapy na báze slovných pravidiel [05]. Vo svojej podstate vychádzajú zo základov fuzzy logiky na báze slovných pravidiel, pričom ju rozširujú o kauzálne vzťahy a spätnú väzbu, tak ako aj v kognitívnych mapách. Hlavný prínos fuzzy máp na báze slovných pravidiel je schopnosť odpovedať na „what – if“ otázky, a teda aktivovať rozdielne kauzálne vzťahy podľa vývoja stavov v mape. Hoci stabilita takejto mapy, resp. jej schopnosť konvergovať k ustálenému stavu, vo veľkej miere závisí od jej dizajnu, pomocou fuzzy máp na báze slovných pravidiel bolo možné upraviť inak chaotické fuzzy kognitívne mapy tak, aby konvergovali k ustálenému stavu [05].

Oblasťami ďalšieho rozvoja fuzzy kognitívnych máp sú napríklad evolučné fuzzy systémy [22]. Synergiou fuzzy systémov na báze slovných pravidiel a evolučných algoritmov je možné dosiahnuť požadovanú presnosť aj interpretovateľnosť výsledkov, čím sa rovnako splnia požiadavky *Explainable AI*.

## Záver

Fuzzy kognitívna mapa umožňuje zachytiť systém spôsobom blízky ľudskému vnímaniu. Vďaka tomu je ako celok zrozumiteľná bez nutnosti chápania odborného pozadia. Zároveň je ľahko modifikovateľná v prípade potreby pridania či odobrania nových konceptov alebo závislostí. V porovnaní s inými mapovacími metódami majú fuzzy kognitívne mapy viaceré výhody. Vďaka vyvodzovaciemu mechanizmu dokážu modelovať dynamiku systému, sú schopné odhaliť skryté vzťahy medzi konceptmi a majú vlastnosť vnorenia – je možné vytvoriť fuzzy kognitívnu mapu, zloženú z viacerých máp, vďaka čomu sú vhodným nástrojom aj na modelovanie systémov s podsystémami [03].

Azda ich najväčšou výhodou je však vysvetliteľnosť, resp. interpretovateľnosť ich cesty k ustáleného stavu. Či už je určitá fuzzy kognitívna mapa zostrojená expertne, matematickým prístupom alebo ich kombináciou, vďaka kauzálnemu reťazeniu smerom vpred je výsledok simulácie zdôvodniteľný.

Práca vo svojom výsledku porovnáva dva prístupy fuzzifikácie kognitívnej mapy. Vďaka slovnému modelu je interpretácia stavov mapy možná a zmysluplná v ktoromkoľvek kroku simulácie. Numerický model s hodnotami  $[-1, 1]$  sa črtá ako vhodnejší v prípade využitia historických dát a učiacich algoritmov. Naopak, slovný model má svoje opodstatnenie pri expertných poznatkoch a potrebe jednoduchého odhadu smerovania vývoja v mape. Konceptom a závislostiam postačuje priradiť jazykové hodnoty a pomocou navrhnutého algoritmu v jazyku R simulovať ich vzájomné dopady.



## Zoznam použitej literatúry

- [01] Kosko, B. - Fuzzy cognitive maps, *Int. J. Man-Machine Studies*, 1986, s. 65 – 78
- [02] Glykas, M. - Fuzzy Cognitive Maps – Advances in Theory, Methodologies, Tools and Applications. Springer, 2010, 425 s.
- [03] Papageorgiou E. I., Kontogianni A. - Using Fuzzy Cognitive Mapping in Environmental Decision Making and Management: A Methodological Primer and an Application, Technological Educational Institution of Lamia, 2012, s. 427 – 450.
- [04] Hudec, M. - Fuzzy logika pre hospodársku informatiku. *Ekonom*, 2015, 218 s.
- [05] Carvallho J. P., Tomé J. A. B. - Computational Intelligence for Modelling, Control & Automation - Rule Based Fuzzy Cognitive Maps: Fuzzy Causal Relations. INESC - Instituto de Engenharia de Sistemas e Computadores, IST – Instituto Superior Técnico (s. 275 – 281).
- [06] Lawrence J. Mazlack - Representing causality using fuzzy cognitive maps. Annual Meeting of the North American Fuzzy Information Processing Society, 2009, 7 s.
- [07] Lin Ch., He Y. - The Algorithm for Solving All Feedback Loops of Fuzzy Cognitive Map. International Conference on Artificial Intelligence and Computational Intelligence, 2009.
- [08] Goebel R., Chander A., Holzinger K., Lecue F., Akata Z., Stumpf S., Kieseberg P., Holzinger A. (2018). - Explainable AI: The New 42? In: Machine Learning and Knowledge Extraction, Springer Lecture Notes in Computer Science LNCS 11015, edited by Holzinger A., Kieseberg P., Tjoa A., Weippl E. pp. 295-303. Springer, Cham.
- [09] Papageorgiou E. I. - Learning Algorithms for Fuzzy Cognitive Maps - A Review Study. 150 IEEE Transactions on Systems, Man, and Cybernetics – Part C: Applications and Reviews, vydanie 42, č. 2, marec 2012.
- [10] Kandasamy V., W. B. - Fuzzy Cognitive Maps and Neutrosophic Cognitive Maps. Phoenix, 2003, 210 s.

- [11] Peña, A., Sossa, H., Gutiérrez, A. - Cognitive Maps: an Overview and their Application for Student Modeling, 2007, s. 230 – 250.
- [12] Dikopoulou, Z., Papageorgiou, E. I. - Inference of Fuzzy Cognitive Maps (FCMs), 2017 verzia 0.1.3 <<https://cran.r-project.org/web/packages/fcm/>>
- [13] Seising, R. - Views on fuzzy sets and systems from different perspectives : philosophy and logic, criticisms and applications. Springer, 2009, 565 s.
- [14] Papageorgiou E. I. - Fuzzy Cognitive Maps for Applied Sciences and Engineering – From Fundamentals to Extensions and Learning Algorithms. Springer, 2014, 395 s.
- [15] Engin Yesil, Dodurka M., Urbas L. - Triangular fuzzy number representation of relations in Fuzzy Cognitive Maps. IEEE International Conference on Fuzzy Systems, 2014, 9 s.
- [16] Frias M., Filiberto Y., Nápoles G., García-Socarrás Y., Vanhoof K., Bello R. - Fuzzy Cognitive Maps reasoning with words based on triangular fuzzy numbers. 16th Mexican International Conference on Artificial Intelligence, 2017, 14 s.
- [17] Kosko, B. - Virtual Worlds as Fuzzy Dynamical Systems, 1996 CiteSeer, 35 s.
- [18] Miller, G. A. - The magical number seven, plus or minus two. Some limits on our capacity for processing information. Psychol. Rev. 63, 81–97 (1956).
- [19] Meulemeeste, J. L., Rochat, D. - A causality analysis of the link between higher education and economic development, Elsevier Ltd. (1995), s. 351 – 361.
- [20] Joe Anand M.C., Devadoss A. V. - Using New Triangular Fuzzy Cognitive Maps (TRFCM) to Analyze Causes of Divorce in Family. International Journal of Communications Networking System, 2013, s. 205 – 213.
- [21] Hudec M., Bednářová E., Holzinger A. (2018). Augmenting Statistical Data Dissemination by Short Quantified Sentences of Natural Language. Journal of Official Statistics, 34(4), 981-1010.

[22] Fernandez A. et al - Evolutionary Fuzzy Systems for Explainable Artificial Intelligence: Why, When, What for, and Where to? IEEE Computation Intelligence Magazine, 2018.

[23] Zhengjian D., Dai L., Juanjuan J. - First Study of Fuzzy Cognitive Map Learning Using Ants Colony Optimization. Journal of Computational Information Systems 7: 13, 2011.

# Prílohy

## 1. Algoritmus pre simulácie s fuzzifikovanými hodnotami

```
# nainštaluje knižnicu pre vyvodzovanie numerických hodnot
install.packages( "fcm" )
library( fcm )
# nastavi working directory (adresar)
setwd( "~/R/fuzzy" )

## I. scenar - Zacinajuci portal - vysoka uroven investicii, ostatne
koncepty nizke
scenar1.vec <- data.frame( 0.125, 0.125, 0.125, 0.125, 0.125, 0.875,
0.125, 0.125 )
## II. scenar - Zacinajuci portal - vysoka uroven atraktivneho obsahu,
reputacie a mierna navstevnost
scenar2.vec <- data.frame( 0.875, 0.875, 0.125, 0.5, 0.125, 0.125,
0.125, 0.125 )
## III. scenar - Zabehnuty portal - kontroverzna strategia
scenar3.vec <- data.frame( 0.232, 0.125, 0.125, 0.248, 0.9, 0.25, 0.833,
0.125 )

# tu je mozne zmenit scenar (scenar1, scenar2, scenar3)
pociatocne_stavy.vec <- scenar1.vec
colnames( pociatocne_stavy.vec ) <- c( "K1", "K2", "K3", "K4", "K5", "K6",
"K7", "K8" )
zavislosti.mat <- read.csv( "matica_zavislosti_ciselne.csv" )
ustaleny_stav <- fcm.infer( pociatocne_stavy.vec, zavislosti.mat, 15, "mk",
"s", 3, 0.01 )
ustaleny_stav$values
library ( reshape2 )
library ( ggplot2 )
iterations <- as.numeric( rownames( ustaleny_stav$values ) ) # vytvori
vektor s cislami
df <- data.frame( iterations, ustaleny_stav$values ) # prida "iterations"
do dataframeu "output1$values"
```

```
df2 <- melt(df, id="iterations") # transformacia
ggplot(data=df2, # vykresli hodnoty konceptov po iteraciach do grafu
        aes( x=iterations, y=value, group=variable, colour=variable ) ) +
theme_bw() + geom_line( size=0.7 ) + geom_point( size = 3 )
```

## 2. Algoritmus pre simulácie so slovnými hodnotami

```
# nastavi working directory (adresar)
setwd("~/R/fuzzy")

### Globalne premenne

## obor hodnot konceptov
slovne_hodnoty_konceptov <- list()

VN <- list(0, 0, 0.125)
slovne_hodnoty_konceptov[["VN"]] <- c( VN )

N <- list(0, 0.125, 0.25)
slovne_hodnoty_konceptov[["N"]] <- c( N )

SN <- list(0.125, 0.25, 0.375)
slovne_hodnoty_konceptov[["SN"]] <- c( SN )

MN <- list(0.25, 0.375, 0.5)
slovne_hodnoty_konceptov[["MN"]] <- c( MN )

M <- list(0.375, 0.5, 0.625)
slovne_hodnoty_konceptov[["M"]] <- c( M )

MV <- list(0.5, 0.625, 0.75)
slovne_hodnoty_konceptov[["MV"]] <- c( MV )

SV <- list(0.625, 0.75, 0.875)
slovne_hodnoty_konceptov[["SV"]] <- c( SV )

V <- list(0.75, 0.875, 1)
slovne_hodnoty_konceptov[["V"]] <- c( V )

W <- list(0.875, 1, 1)
slovne_hodnoty_konceptov[["W"]] <- c( W )

## obor hodnot zavislosti (hran)
```

```

slovne_hodnoty_hran <- list()
VS <- list(0, 0, 0.125)
slovne_hodnoty_hran[["VS"]] <- c( VS )
S <- list(0, 0.125, 0.25)
slovne_hodnoty_hran[["S"]] <- c( S )
SS <- list(0.125, 0.25, 0.375)
slovne_hodnoty_hran[["SS"]] <- c( SS )
MS <- list(0.25, 0.375, 0.5)
slovne_hodnoty_hran[["MS"]] <- c( MS )
M <- list(0.375, 0.5, 0.625)
slovne_hodnoty_hran[["M"]] <- c( M )
MV <- list(0.5, 0.625, 0.75)
slovne_hodnoty_hran[["MV"]] <- c( MV )
SV <- list(0.625, 0.75, 0.875)
slovne_hodnoty_hran[["SV"]] <- c( SV )
V <- list(0.75, 0.875, 1)
slovne_hodnoty_hran[["V"]] <- c( V )
VV <- list(0.875, 1, 1)
slovne_hodnoty_hran[["VV"]] <- c( VV )
VS <- list(0, 0, -0.125)
slovne_hodnoty_hran[["NEGVs"]] <- c( VS )
S <- list(0, -0.125, -0.25)
slovne_hodnoty_hran[["NEGS"]] <- c( S )
SS <- list(-0.125, -0.25, -0.375)
slovne_hodnoty_hran[["NEGSS"]] <- c( SS )
MS <- list(-0.25, -0.375, -0.5)

```

```

slovne_hodnoty_hran[["NEGMS"]] <- c( MS )
M <- list(-0.375, -0.5, -0.625)
slovne_hodnoty_hran[["NEGM"]] <- c( M )
MV <- list(-0.5, -0.625, -0.75)
slovne_hodnoty_hran[["NEGMV"]] <- c( MV )
SV <- list(-0.625, -0.75, -0.875)
slovne_hodnoty_hran[["NEGSV"]] <- c( SV )
V <- list(-0.75, -0.875, -1)
slovne_hodnoty_hran[["NEGV"]] <- c( V )
VV <- list(-0.875, -1, -1)
slovne_hodnoty_hran[["NEGVV"]] <- c( VV )

#### Definicie funkcie

## Vrati produkt dvoch trojuholnikovych cisiel
# list trojuholnikove cislo
# list trojuholnikove cislo
vynasobCisla <- function( trin_a, trin_b ) {
  trin_13 <- list()
  a <- list( trin_a[[1]][[1]], trin_a[[1]][[2]], trin_a[[1]][[3]] )
  b <- list( trin_b[[1]][[1]], trin_b[[1]][[2]], trin_b[[1]][[3]] )
  # vsetky kombinacie dolneho a horneho ohranicenia
  trin_13 <- c( trin_13, a[[1]] * b[[1]] )
  trin_13 <- c( trin_13, a[[1]] * b[[3]] )
  trin_13 <- c( trin_13, a[[3]] * b[[1]] )
}

```



```

trin_13 <- c( trin_13, a[[3]] * b[[3]] )

trin_2 <- a[[2]] * b[[2]] #stred

# nove cislo je min(DxH), S*S, max(DxH)

nove_cislo <- list( min( unlist( trin_13 ) ), trin_2,
max( unlist( trin_13 ) ) )

return( nove_cislo )
}

## Scita vsetky fuzzy cisla v liste
# list trojuholnikovych cisiel
scitajCisla <- function( cisla ) {
  scitanec = list(0, 0, 0) # zadefinuje prazdne fuzzy cislo
  for ( cislo in cisla ) {
    scitanec[[1]] <- scitanec[[1]] + cislo[[1]]
    scitanec[[2]] <- scitanec[[2]] + cislo[[2]]
    scitanec[[3]] <- scitanec[[3]] + cislo[[3]]
  }
  if ( scitanec[[1]] > 1 ) {
    scitanec[[1]] <- 1
  }
  if ( scitanec[[2]] > 1 ) {
    scitanec[[2]] <- 1
  }
  if ( scitanec[[3]] > 1 ) {
    scitanec[[3]] <- 1
  }
}

```

```

    return( scitanec )
}

## Vrať slovnú hodnotu konceptu
# list trojuholnikove cislo
konceptSlovnePodlaRezidua <- function( trojuholnikove_cislo ) {

    deltas <- c()

    VN <- c(0, 0, 0.125)
    N <- c(0, 0.125, 0.25)
    SN <- c(0.125, 0.25, 0.375)
    MN <- c(0.25, 0.375, 0.5)
    M <- c(0.375, 0.5, 0.625)
    MV <- c(0.5, 0.625, 0.75)
    SV <- c(0.625, 0.75, 0.875)
    V <- c(0.75, 0.875, 1)
    VV <- c(0.875, 1, 1)

    koncepty.mat <- matrix( c(VN, N, SN, MN, M, MV, SV, V, VV ), nrow =18,
ncol=3, byrow=TRUE )

    i <- 1
    while ( i <= 18 ) {
        koncept <- ( koncepty.mat[c(i), c(1,2,3)] )
    }
}

```

```

    delta <- sqrt( 1/3 * ( ( trojuholnikove_cislo[[1]] - koncept[1])^2 +
( trojuholnikove_cislo[[2]] - koncept[2])^2 + ( trojuholnikove_cislo[[3]] -
koncept[3])^2 ) )

    deltas[i] <- delta

    i <- i + 1
}

minimum = min( unlist( deltas ) )
poradie = which.min( unlist( deltas ) ) # ktory koncept

if ( poradie == 1 ) {
    nova_hodnota_konceptu = "VN"
}

if ( poradie == 2 ) {
    nova_hodnota_konceptu = "N"
}

if ( poradie == 3 ) {
    nova_hodnota_konceptu = "SN"
}

if ( poradie == 4 ) {
    nova_hodnota_konceptu = "MN"
}

if ( poradie == 5 ) {
    nova_hodnota_konceptu = "M"
}

if ( poradie == 6 ) {
    nova_hodnota_konceptu = "MV"
}

```

```

if ( poradie == 7 ) {
  nova_hodnota_konceptu = "SV"
}
if ( poradie == 8 ) {
  nova_hodnota_konceptu = "V"
}
if ( poradie == 9 ) {
  nova_hodnota_konceptu = "VV"
}

return( nova_hodnota_konceptu )

}

## vrati slovnu hodnotu vplyvu z oboru hodnot
# list trojuholnikove fuzzy cislo
vplyvSlovnePodlaRezidua <- function( scitanec_vplyvov ) {

  deltas <- c()

  NEGVV = c(-0.875, -1, -1)
  NEGV= c(-0.75, -0.875, -1)
  NEGSV = c(-0.625, -0.75, -0.875)
  NEGVM = c(-0.5, -0.625, -0.75)
  NEGM = c(-0.375, -0.5, -0.625)

```

```

NEGMS = c(-0.25, -0.375, -0.5)
NEGSS = c(-0.125, -0.25, -0.375)
NEGS = c(0, -0.125, -0.25)
NEGVS = c(0, 0, -0.125)
VS = c(0, 0, 0.125)
S = c(0, 0.125, 0.25)
SS = c(0.125, 0.25, 0.375)
MS = c(0.25, 0.375, 0.5)
M = c(0.375, 0.5, 0.625)
MV = c(0.5, 0.625, 0.75)
SV = c(0.625, 0.75, 0.875)
V = c(0.75, 0.875, 1)
VV = c(0.875, 1, 1)

zavislosti.mat <- matrix( c(NEGVV, NEGVS, NEGSV, NEGVS, NEGVS, NEGVS, NEGVS,
NEGVS, NEGVS, VS, S, SS, MS, M, MV, SV, V, VV ), nrow =18, ncol=3, byrow=TRUE
)

i <- 1
while ( i <= 18 ) {
  zavislost <- ( zavislosti.mat[c(i), c(1,2,3)] )

  delta <- sqrt( 1/3 * ( ( scitanec_vplyvov[[1]] - zavislost[1] )^2 +
( scitanec_vplyvov[[2]] - zavislost[2] )^2 + ( scitanec_vplyvov[[3]] -
zavislost[3])^2 ) )

  deltas[i] <- delta

  i <- i + 1
}

minimum = min( unlist( deltas ) )

```

```
poradie = which.min( unlist( deltas ) ) # v kolkej/ktorej hrane
```

```
if ( poradie == 1 ) {
```

```
  hrana = "NEGVV"
```

```
}
```

```
if ( poradie == 2 ) {
```

```
  hrana = "NEGV"
```

```
}
```

```
if ( poradie == 3 ) {
```

```
  hrana = "NEGSV"
```

```
}
```

```
if ( poradie == 4 ) {
```

```
  hrana = "NEGMV"
```

```
}
```

```
if ( poradie == 5 ) {
```

```
  hrana = "NEGM"
```

```
}
```

```
if ( poradie == 6 ) {
```

```
  hrana = "NEGMS"
```

```
}
```

```
if ( poradie == 7 ) {
```

```
  hrana = "NEGSS"
```

```
}
```

```
if ( poradie == 8 ) {
```

```
  hrana = "NEGS"
```

```
}
```

```
if ( poradie == 9 ) {  
    hrana = "NEGVVS"  
}  
if ( poradie == 10 ) {  
    hrana = "VS"  
}  
if ( poradie == 11 ) {  
    hrana = "S"  
}  
if ( poradie == 12 ) {  
    hrana = "SS"  
}  
if ( poradie == 13 ) {  
    hrana = "MS"  
}  
if ( poradie == 14 ) {  
    hrana = "M"  
}  
if ( poradie == 15 ) {  
    hrana = "MV"  
}  
if ( poradie == 16 ) {  
    hrana = "SV"  
}  
if ( poradie == 17 ) {  
    hrana = "V"  
}
```

```

}

if ( poradie == 18 ) {
  hrana = "VV"
}

return( hrana )

}

## Spocita dve slovne fuzzy cisla
# string slovna hodnota vplyvu
# string slovna hodnota konceptu
zapocitajVplyvDoKonceptu <- function( vplyv_slovne, koncept_slovne ) {

  nove_cislo <- list(0,0,0)

  nove_cislo[[1]] <- slovne_hodnoty_hran[vplyv_slovne][[1]][[1]] +
slovne_hodnoty_konceptov[koncept_slovne][[1]][[1]]

  nove_cislo[[2]] <- slovne_hodnoty_hran[vplyv_slovne][[1]][[2]] +
slovne_hodnoty_konceptov[koncept_slovne][[1]][[2]]

  nove_cislo[[3]] <- slovne_hodnoty_hran[vplyv_slovne][[1]][[3]] +
slovne_hodnoty_konceptov[koncept_slovne][[1]][[3]]

  return( nove_cislo )

}

```



```

## Prahova funkcia pre trojuholnikove fuzzy cisla
# string slovna hodnota hrany
novaHodnotaKonceptu <- function( slovnaHodnotaHrany ) {
  koncept <- ""
  if ( slovnaHodnotaHrany == "NEGVV" ) {
    koncept <- "VN"
  }
  if ( slovnaHodnotaHrany == "NEGV" ) {
    koncept <- "N"
  }
  if ( slovnaHodnotaHrany == "NEGSV" ) {
    koncept <- "SN"
  }
  if ( slovnaHodnotaHrany == "NEGMV" ) {
    koncept <- "SN"
  }
  if ( slovnaHodnotaHrany == "NEGM" ) {
    koncept <- "SN"
  }
  if ( slovnaHodnotaHrany == "NEGMS" ) {
    koncept <- "SN"
  }
  if ( slovnaHodnotaHrany == "NEGSS" ) {
    koncept <- "MN"
  }
  if ( slovnaHodnotaHrany == "NEGS" ) {

```

```
    koncept <- "M"
  }
  if ( slovnaHodnotaHrany == "NEGV" ) {
    koncept <- "M"
  }
  if ( slovnaHodnotaHrany == "VS" ) {
    koncept <- "MV"
  }
  if ( slovnaHodnotaHrany == "S" ) {
    koncept <- "MV"
  }
  if ( slovnaHodnotaHrany == "SS" ) {
    koncept <- "SV"
  }
  if ( slovnaHodnotaHrany == "MS" ) {
    koncept <- "SV"
  }
  if ( slovnaHodnotaHrany == "M" ) {
    koncept <- "SV"
  }
  if ( slovnaHodnotaHrany == "MV" ) {
    koncept <- "V"
  }
  if ( slovnaHodnotaHrany == "SV" ) {
    koncept <- "V"
  }
}
```

```

if ( slovnaHodnotaHrany == "V" ) {
  koncept <- "VV"
}
if ( slovnaHodnotaHrany == "VV" ) {
  koncept <- "VV"
}
return( koncept )
}

## Vyvodi nove hodnoty vstupnych konceptov po zadany pocet iteracii
# string nazov suboru matice slovnych zavislosti
# list slovne hodnoty konceptov
# integer pocet iteracii
simuluj <- function( matica_zavislosti, koncepty_slovne, pocet_iteracii ) {

  hrany_slovne = read.csv( matica_zavislosti, sep="," )
  hrany_slovne <- as.matrix( hrany_slovne )

  ## premeni slovne hodnoty konceptov na fuzzy cisla
  koncepty <- list()
  for ( koncept in koncepty_slovne ) {
    koncepty <- c( koncepty, slovne_hodnoty_konceptov[koncept] )
  }

  print( paste("Počiatočné stavy konceptov: ",
  paste( shQuote( koncepty_slovne ), collapse="," ) ) ) )
}

```

```

## premeni slovne hodnoty hran na fuzzy cisla

hrany <- matrix( rep(list(), 3), nrow =8, ncol=8, byrow=TRUE )

i = 1
j = 1
for ( r in 1:nrow( hrany_slovne ) ) {
  j <- 1
  for ( c in 1:ncol( hrany_slovne ) ) {
    if ( hrany_slovne[r,c] != "0" ) {
      hrany[ i, j ] <- slovne_hodnoty_hran[hrany_slovne[r,c]]
      print(hrany_slovne[r,c])
      print(slovne_hodnoty_hran[hrany_slovne[r,c]])
    } else {
      hrany[ i, j ] <- "NA"
    }
    j <- j + 1
  }
  i <- i + 1
}

iteracia <- 1
while ( iteracia <= pocet_iteracii ) {

  # priradi trojuholnikove cisla podla slovných hodnot konceptov
  koncepty <- list()

```

```

for ( koncept in koncepty_slovne ) {
  koncepty <- c( koncepty, slovne_hodnoty_konceptov[koncept] )
}

nove_slovne_hodnoty_konceptov <- list("", "", "", "", "", "", "", "")

poradie_konceptu <- 1 # poradie konceptu v cykle
for ( koncept in koncepty_slovne ) {

  i <- 1
  vplyvy <- list()

  # pre kazdu zavislost vplyvajucu na koncept
  while ( i <= 8 ) {

    # ak existuje zavislost vplyvajuca na koncept
    if ( hrany[ i, poradie_konceptu ] != "NA" ) {

      # vplyvajuci koncept * hrana
      vplyv <- vynasobCisla( koncepty[i], hrany[ i, poradie_konceptu ] )
      # priradi trojuholnikove cislo do listu vplyvov
      vplyvy <- append( vplyvy, list( vplyv ) )

    }

    i <- i + 1
  }
}

```

```

}

vysledny_vplyv = scitajCisla( vplyvy )
#print("vplyv je")
#print(vysledny_vplyv)

vysledny_vplyv_slovne = vplyvSlovnePodlaRezidua( vysledny_vplyv )
#print("vplyv slovne je")
#print(vysledny_vplyv_slovne)

nove_cislo_konceptu = zapocitajVplyvDoKonceptu( vysledny_vplyv_slovne,
koncept )
#print("nove cislo konceptu je")
#print(nove_cislo_konceptu)

novy_koncept_slovne <-
konceptSlovnePodlaRezidua( nove_cislo_konceptu )
#print("koncept slovne je")
#print(novy_koncept_slovne)

#print("***vypocet konceptu***")

nove_slovne_hodnoty_konceptov[poradie_konceptu] <- novy_koncept_slovne

poradie_konceptu <- poradie_konceptu + 1

}

```

```

koncepty_slovne <- nove_slovne_hodnoty_konceptov

#print(nove_slovne_hodnoty_konceptov)

print( paste( "Nové stavy konceptov:",
paste( shQuote( nove_slovne_hodnoty_konceptov ), collapse=", " ) ) )

iteracia <- iteracia + 1

}

print( paste("Výsledné stavy konceptov: ",
paste( shQuote( nove_slovne_hodnoty_konceptov ), collapse=", " ) ) )

#return( nove_slovne_hodnoty_konceptov )

}

## I. Zacinajuci portal - vysoka uroven investicii

scenar1 <- list( "K1" = "N", "K2" = "N", "K3" = "N", "K4" = "N", "K5" = "N",
"K6" = "V", "K7" = "N", "K8" = "N")

## II. Zacinajuci portal - (V)yysoka uroven atraktivneho obsahu, reputacie a
technologie

scenar2 <- list( "K1" = "V", "K2" = "V", "K3" = "N", "K4" = "M", "K5" = "N",
"K6" = "N", "K7" = "N", "K8" = "N")

## III. Rozbehnuty portal - kontroverzny

scenar3 <- list( "K1" = "SN", "K2" = "N", "K3" = "N", "K4" = "SN", "K5" =
"V", "K6" = "SN", "K7" = "V", "K8" = "N")

# tu je mozne zmenit scenar (scenar1, scenar2, scenar3)

koncepty_slovne <- scenar1

matica_zavislosti <- "matica_zavislosti_slovne.csv"

```

```
simuluj( matica_zavislosti, koncepty_slovne, 20 )
```