

SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE
FAKULTA CHEMICKEJ A POTRAVINÁRSKEJ TECHNOLOGIE
Ústav informatizácie, automatizácie a matematiky

BAKALÁRSKY PROJEKT

Identifikácia vybraných procesov metódou Anfis.

Vypracoval: **František Tomeček**

Vedúci bakalárskeho projektu: **Ing. Anna Vasičkaninová**

Bratislava 2009

ABSTRAKT

Bakalárska práca sa zaoberá identifikáciou procesov pomocou metódy ANFIS. Vybraným procesom sú zásobníky kvapaliny. Výhodou metódy Anfis je, že ak sú k dispozícii vstupno-výstupné údaje, je možné tieto údaje použiť na získanie fuzzy modelu typu Sugeno. Anfis je päťvrstvová dopredná neurónová sieť, ktorá na trénovanie siete používa hybridné učenie pomocou metódy najmenších štvorcov a metódy spätného šírenia. Na získanie trénovacích údajov bola vytvorená simulinková schéma s s-funkciou. Táto funkcia obsahuje nelineárne diferenciálne rovnice, popisujúce zásobníky. V bakalárskej práci je stručný opis fuzzy množín a fuzzy modelov. Na vytvorenie neuro-fuzzy modelov sa používajú príkazy *genfis1* a *genfis2*, ktoré sú súčasťou Fuzzy Logic Toolbox v Matlabe.

ABSTRACT

The bachelor work deals with an identification of a choosed processes by anfis method. This method uses a hybrid learning algorithm based on the least-squares and the backpropagation gradient descent method to calculate a parameters of the fuzzy inference system. The work contains a simple description of a fuzzy sets, a fuzzy models and a LS, which are analysed. The anfis editor is not used, so a commands are written to m-files in the Matlab. FIS editor is used for a setting of a weights and a rules. The aim of this work is an identification of a processes (LS) based on the experimental input-output values with *genfis1*, *genfis2* and *genfis3* methods.

Prehlásenie:

Prehlasujem, že na bakalárskej práci som pracoval samostatne na základe vlastných teoretických a praktických poznatkov a za použitia uvedenej literatúry.

V Bratislave 22.5. 2009

.....
podpis

POĎAKOVANIE:

Dovoľujem si poďakovať vedúcej semestrálneho projektu Ing. Anne Vasičkaninovej za poskytnutie cenných rád a pripomienok pri vypracovaní tejto bakalárskej práce.

Obsah

1. ÚVOD	11
2. TEORETICKÁ ČASŤ	12
2.1. Vznik a postavenie fuzzy	12
2.2.1. Definícia fuzzy množiny a jej základných pojmov	13
2.2. Fuzzy množiny	13
2.2.2. Fuzzifikácia	16
2.2.3. Inferencia	17
2.2.4. Kompozícia	18
2.2.5. Defuzzifikácia	19
2.3.1 Substraktívna zhluková analýza	21
2.3. Fuzzy modely	21
2.3.2 Mamdaniho model	22
2.3.3 Sugenov model	24
2.4. ANFIS	26
2.4.1. ANFIS architektura	27
2.4.2. Postup výpočtu metódou ANFIS v Matlabe	28
3. PRAKTICKÁ ČASŤ	29
3.1. Model zásobníkov kvapaliny	29
3.1.1 Genfis 1	34
3.1.2 Genfis 2	38
3.1.3 Genfis 3	40
4. ZÁVER	43
LITERATÚRA	44
PRÍLOHY	45

PRÍLOHY:

Príloha č.1: Výsledná fis matica pre 3 Gaussovske pravidlá

Príloha č.2: Výsledná fis matica pre 13 Gaussovských pravidiel

Príloha č.3: Program anfh.m pre výpočet fis matice pomocou funkcie *genfis1*

Príloha č.4: Program anfgn2.m pre výpočet fis matice pomocou funkcie *genfis2*

Príloha č.5: Program idegn3.m pre výpočet fis matice pomocou funkcie *genfis3*

Príloha č.6: S-funkcia, opisujúca zásobníky

Príloha č.7: Zvonové funkcie príslušnosti použité pri tvorbe modelu typu Mamdani pre vstupnú a výstupnú veličinu

Príloha č.8: Zvonové a lichobežníkové funkcie príslušnosti použité pri tvorbe modelu typu Mamdani pre vstupnú a výstupnú veličinu

Príloha č.9: Schémy

ZOZNAM OBRÁZKOV:

Obrázok 1: Prof. Lotfi Zadeh

Obrázok 2: Charakteristiky funkcie príslušnosti

Obrázok 3: Sled krokov pre systém s fuzzy logikou

Obrázok 4: Príklad možného tvaru výstupnej funkcie príslušnosti získanej kompozíciou funkcií príslušnosti čiastkových výstupov

Obrázok 5: Grafické znázornenie metódy MIN-MAX

Obrázok 6: Štruktúra ANFIS

Obrázok 7: Schéma zariadenia

Obrázok 8: Odozva výšky hladiny v 3. zásobníku na 20% skokovú zmenu prietoku q_{01}

Obrázok 9: Funkcie príslušnosti v Matlabe

Obrázok 10: Gaussovske funkcie príslušnosti

Obrázok 11: Priebeh nameranej výšky hladiny a výšky hladiny po identifikácii.

Obrázok 12: Pravidlá pre 3 Gaussovske funkcie príslušnosti

Obrázok 13: Pravidlá pre 13 Gaussovských funkcií príslušnosti

Obrázok 14: Štruktúra ANFIS pre 3 pravidlá

Obrázok 15: Štruktúra ANFIS pre 13 pravidiel

Obrázok 16: Porovnanie výšok hladín pri identifikácii s 3 pravidlami

Obrázok 17: Porovnanie výšok hladín pri identifikácii pre 48 pravidiel

Obrázok 18: Priebeh nameranej výšky hladiny a výšky hladiny po identifikácii pomocou príkazu `genfis 3`

Obrázok 19: Pravidlá pre model typu Mamdani

Obrázok 20: Znázornenie centier zhlukov

Obrázok 21: Znázornenie jednotlivých zhlukov

Obrázok 22: Zvonové funkcie príslušnosti použité pri tvorbe modelu typu Mamdani pre vstupnú a výstupnú veličinu

Obrázok 23: Zvonové funkcie príslušnosti

Obrázok 24: Priebeh nameranej výšky hladiny a výšky hladiny po identifikácii.

Obrázok 25: Lichobežníkové funkcie príslušnosti

Obrázok 26: Priebeh nameranej výšky hladiny a výšky hladiny po identifikácii.

ZOZNAM TABULIEK:

Tabuľka 1: Parametre zásobníkov kvapaliny

Tabuľka 2: Rôzne hodnoty RADII vo funkcii *genfis2* a s tým súvisiaci rôzny počet zhlukov.

ZOZNAM POUŽITÝCH SKRATIEK:

ANFIS	Adaptive Neuro - Fuzzy Inference System
FIS	Fuzzy Inference System
PFP	Počet funkcií príslušnosti
FM	Fuzzy model
gaussmf	Gaussovská funkcia príslušnosti
gbellmf	Zvonová funkcia príslušnosti
trapmf	Lichobežníková funkcia príslušnosti
FP	Funkcia príslušnosti
TSK	Takagi-Sugeno-Kang

1. ÚVOD

V posledných rokoch sa v praxi môžeme stretnúť v riadení a regulovaní s prístupmi a princípmi, ktoré sú založené na pomerne novej vednej disciplíne. Táto disciplína sa zaoberá symbiózou rôznych výpočtových postupov, pre ktoré je spoločným znakom odklon od klasického modelovania. Ich charakteristickým znakom sú mäkké požiadavky na presnosť popisovaných javov. Charakteristickým znakom fuzzy riadenia je možnosť bezprostredného použitia empirických znalostí človeka – operátora o riadenom procese. Môže byť využitý tam, kde je klasické riadenie neuspokojivé. Fuzzy model je veľmi vhodný ako supervízor, ktorý dohliada na všetky ostatné modely a zapája ich vhodným spôsobom do riadenia.

Obsahom práce je získanie fuzzy modelu zásobníkov kvapaliny v tvare FIS matice pomocou príkazov a funkcií, ktoré obsahuje Fuzzy Logic Toolbox Matlabu. Medzi základné použité funkcie patria *genfis1* a *genfis2*, ktoré umožňujú získať modely typu Takagi-Sugeno a *genfis3*, pomocou ktorej je možné získať model typu Mamdani. Pri použití funkcie *genfis1* sa generuje fuzzy inferenčný systém na základe pravidelného mriežkového rozdelenia vstupných údajov, pričom je možné zadávať rôzny počet aj tvar funkcií príslušnosti. Pri použití funkcie *genfis2* sa generuje fuzzy inferenčný systém na základe metódy subtraktívneho zhlukovania. Môže sa pritom meniť počet funkcií príslušnosti, ale tvar funkcií môže byť iba Gaussovský. Na získanie modelov typu Takagi-Sugeno sa využíva metóda *anfis*. Model typu Mamdani sa počíta *fcm* algoritmom. Výsledné parametre modelov sa počítajú trénovaním zo vstupno-výstupných údajov. Trénovacie údaje boli získané simulovaním zásobníkov kvapaliny, opísaných s-funkciou. Na porovnanie presnosti identifikácie bol vytvorený aj linearizovaný model zásobníkov kvapaliny.

2. TEORETICKÁ ČASŤ

2.1. Vznik a postavenie fuzzy

Vo všeobecnosti sa za zakladateľa fuzzy teórie považuje azerbajdžanec prof. Lotfi Zadeh, ktorý svojím článkom v roku 1965 s názvom „Fuzzy sets“ dal fuzzy množinám ich meno. Úplné počiatky však možno hľadať ešte dávnejšie pri snahe vybudovať viachodnotovú logiku, ktorá je základom pre Zadeho fuzzy množiny. Práve viachodnotová (Lukasiewiczova) logika umožňuje pracovať s nepresnými (vágnymi) pojmami a odstraňuje nedostatky „klasickej“ dvojhodnotovej logiky využívanej v technike už od dôb antiky. Použitiu vágnych pojmov sa pritom nevyhneme predovšetkým pri popise chovania zložitých systémov, ktorých presný analytický popis by bol technicky neuskutočniteľný alebo neúnosne komplikovaný, a tým aj realizačne drahý. Príčinu vzniku fuzzy teórie možno formulovať aj pomocou tzv. zákona nezlučiteľnosti (inkompatibility) :

„Ak rastie zložitosť nejakého systému, klesá naša schopnosť tento systém popísať presne. Po prekročení určitej hranice zložitosti systému sa presnosť a relevantnosť popisu stávajú vzájomne sa vylučujúcimi charakteristikami.“



Obrázok 1: Prof. Lotfi Zadeh

2.2. Fuzzy množiny

V zásade sa používajú dva základné úzko súvisiace pojmy, a to fuzzy množina a fuzzy logika. Ak používame pojem fuzzy množina, tak máme na mysli predovšetkým len samotný matematický aparát, ktorý definuje pojem fuzzy množiny a operácie medzi viacerými fuzzy množinami. Fuzzy logika je širší pojem, ktorý zahŕňa aj predošlý pojem a používa sa najmä v súvislosti s využitím teórie fuzzy množín v konkrétnych aplikáciách, kde okrem iného treba napr. riešiť problémy implementácie algoritmov využívajúcich fuzzy množiny do daného systému a napojenie na jeho nefuzzifikované časti. Častokrát sa jedná o aplikácie v riadení, kde vystupuje aj pojem typ riadiacej logiky, čo použitiu tohto pojmu ešte viac napomáha.

Potrebu a význam fuzzy množín si môžeme jednoduchšie vysvetliť na nasledujúcom príklade. Predstavme si pojem vek človeka tak, ako ho chápeme v bežnej medziľudskej komunikácii. Bežne sa totiž vyjadrujeme v pojmoch, že ten a ten je mladý, starý a pod. Väčšinou si vieme dosť presne predstaviť, čo tieto pojmy znamenajú a narábame s nimi vlastne, ako keby sme počítali rovno s presnými číslami. Takýchto príkladov sa vyskytuje veľmi veľa, pričom v hojnom počte sa vyskytujú aj v technickej praxi.

Človek si zhruba vie predstaviť význam pojmov ako vysoký, malý a pod., no počítač pri ich interpretácii už má problémy. Preto najprv musíme vedieť tieto slovné (lingvistické) hodnoty popísať a až potom budeme môcť ich spracovávať. Toto bolo aj pôvodným popudom na vytvorenie teórie fuzzy množín, t.j. aby sme mohli matematicky modelovať význam slovných výrazov prirodzeného jazyka, ktoré sa nám javia ako vágne, nejasné, neostré, neurčité, či hmlisté. Presne takýto význam má anglický výraz fuzzy. Základným prostriedkom na exaktný popis významu neostrých lingvistických výrazov je fuzzy množina, pri ktorej popise do popredia vystupuje funkcia príslušnosti.

2.2.1. Definícia fuzzy množiny a jej základných pojmov

Nech X je súbor objektov (prvkov) označených symbolom x . Nech M je množina čísel, na ktorej je definovaný zväz. Fuzzy množina A je množina usporiadaných dvojíc


$$A = \{ (x, \mu_a(x)), x \text{ patrí } X \}$$

kde X je univerzálna množina (univerzum), $\mu_a : X \rightarrow M$ je funkcia príslušnosti a $\mu_a(x)$ je stupeň príslušnosti. Ak $M=\{0,1\}$ pre všetky x patriace do X , potom sa jedná o klasické (ostré) množiny. Platí všeobecná dohoda, že M je uzavretý interval reálnych čísel $\langle 0,1 \rangle$, $\mu_a(x)=0$ ($\mu_a(x)=1$) je najmenší (najväčší) stupeň príslušnosti.

Možno povedať, že stupeň príslušnosti vyjadruje mieru nášho presvedčenia o tom, či daný prvok patrí do množiny.

Charakteristiky funkcie príslušnosti:

- *nosič* (support A) - $\text{supp } A = \{x \text{ patriace } X, \mu_a(x) > 0 \}$
- α rez A - $A_\alpha = \{x \text{ patriace } X, \mu_a(x) \geq \alpha \}$
- striktný α rez A - $A_\alpha = \{x \text{ patriace } X, \mu_a(x) > \alpha \}$
- α hladina A (level A) - $A^\alpha = \{x \text{ patriace } X, \mu_a(x) = \alpha \}$
- *jadro* A ($\text{ker } A$) - $\text{ker } A = \{x \text{ patriace } X, \mu_a(x) = 1 \}$
- *vrchol* A (peak A) - jeden prvok $P(A)$



Obrázok 2: Charakteristiky funkcie príslušnosti

Zápis fuzzy množiny znamená, že ak je univerzum v diskretnom tvare potom:

- $A = \{ x_0, \mu_a(x_0), x_1, \mu_a(x_1), \dots \}$ - vymenovanie dvojíc
- $A = \{ \mu_a(x_0)/x_0, \mu_a(x_1)/x_1, \dots \}$
- $A = \{ \mu_a(x_0)/x_0 + \mu_a(x_1)/x_1 + \dots \}$
- *graficky pomocou diskretnej funkcie*

Ak univerzum je v spojitom tvare:

- $A = \int_x \mu_a(x)/x \, dx$
- *graficky pomocou spojitej funkcie*

Vo všeobecnosti platí, že nelineárne funkcie príslušnosti lepšie popisujú skutočnosť, ale majú vysokú výpočtovú náročnosť. Ak sa dajú použiť lineárne funkcie, tak ich treba použiť. Najznámejšie nelineárne funkcie príslušnosti sú:

- S+ funkcia
- S- funkcia
- π funkcia

Najznámejšie lineárne funkcie príslušnosti sú:

- lichobežníková funkcia (trapezoid, linearizovaná π funkcia)
- Z+ funkcia (linearizovaná S+)
- Z- funkcia (linearizovaná S-)
- trojuholníková funkcia
- singleton

Spôsoby získavania funkcií príslušnosti patria medzi základné problémy fuzzy množín.

Najzákladnejšie spôsoby získavania funkcií príslušností sú:

- subjektívne ohodnotenie, ad-hoc riešenie
- transformácia frekvenčných a štatistických údajov
- fyzikálne merania
- adaptácia, učenie, ladenie


Fuzzy premenná je charakterizovaná usporiadanou trojicou $(X, U, R(X, u))$, kde

- X je názov premennej
- U je univerzálna množina
- $R(X, u)$ je fuzzy podmnožina univerzálnej množiny U, pričom predstavuje fuzzy ohraničenie hodnôt premennej u, ktoré je dané premennou X. Skrátené sa označuje $R(X)$.

Malý príklad. Zoberme si do parády pojem vek človeka, pričom budeme používať tri hodnoty: mladý, stredne starý a starý. Potom vek človeka je lingvistická premenná, mladý, stredne starý a starý sú lingvistické hodnoty, ktoré nadobúda lingvistická premenná vek človeka. Všetky fuzzy premenné (môžu sa volať rovnako ako lingvistické hodnoty, ale môžu mať aj iné názvy, napr. $X_1, \dots$), ktoré sú priradené jednotlivým lingvistickým hodnotám, sú definované na spoločnom univerze U . Tvary fuzzy množín, čiže funkcií príslušnosti a ich parametre bývajú v jednotlivých aplikáciách rôzne a sú spravidla stanovené intuitívne na základe praktických skúseností, prípadne získané učením pomocou neurónových sietí alebo genetických algoritmov.

Najčastejšie používané tvary funkcií príslušnosti sú na obrázku. Ich skrátené názvy sú odvodené z anglických výrazov, keďže u nás ešte nie je ustálená terminológia v tejto oblasti.

2.2.2. Fuzzifikácia



Obrázok 3: Sled krokov pre systém s fuzzy logikou

Blok fuzzifikácie môže vykonávať dve základné funkcie:

- normalizáciu
- samotnú fuzzifikáciu

Normalizácia predstavuje prepočet vstupných hodnôt všetkých vstupov (x a Δx) na spoločný normalizovaný interval $\langle I_{\min}; I_{\max} \rangle$, ktorý je podmnožinou ich univerza. Takýto prístup umožňuje použitie jedného inferenčného mechanizmu pre riadenie ľubovoľnej sústavy. Normalizácia sa vykoná pomocou normalizačných koeficientov N_x a $N_{\Delta x}$:

$$x_N = N_e x$$

$$\Delta x_N = N_{\Delta e} \Delta x$$

x_N a Δx_N sú normalizované hodnoty, ktoré vždy patria do intervalu $\langle I_{min}; I_{max} \rangle$. Po vykonaní všetkých zmienených fáz regulácie je potrebné výstup y_n , ktorý je tým pádom tiež v normalizovanej podobe, opätovne v denormalizačnom bloku pomocou denormalizačného koeficientu N_u prepočítať na skutočnú hodnotu y :

$$y = N_u y_N$$

Zmenou normalizačných koeficientov je možné meniť citlivosť regulátora, tým narušiť jeho robustnosť, čo môže dokonca viesť k nestabilitám. Vstupmi do modelu môžu byť:

1. Konkrétne číselné hodnoty, t.j. tzv. ostré čísla
2. Fuzzy množiny ako napr. nedefuzzifikované výstupy z iných fuzzy modelov

2.2.3. Inferencia

Pojem inferencia môžeme chápať v užšom a aj v širšom slova zmysle, nakoľko sú dva základné druhy inferencie:

1. Inferencia podľa jednotlivých pravidiel, kde sa jedná o inferenciu v užšom slova zmysle. Každé pravidlo predstavuje istý vzťah (reláciu medzi) vstupom a výstupom pravidla, pričom celá predpokladová časť sa môže skladať z viacerých častí x_1 , x_2 , až x_n , takže vzťah pre k -te pravidlo s výstupom y je možné prepísať na:

$$\text{AK } x_1 \text{ je } LX_1^k \text{ AND ... AND } x_n \text{ je } LX_n^k \text{ POTOM } y \text{ je } LY^k$$

LX_1^k , LX_n^k , LY^k sú FP charakterizujúce konkrétne hodnoty lingvistických premenných v pravidle k . Úlohou inferencie je tieto čiastkové časti predpokladu spojiť pomocou nejakej T -normy (ak by namiesto AND bola logická spojka OR, tak pomocou T -konormy) do spoločnej FM s FP LA^k , ktorá reprezentuje celý predpoklad a tento zase pomocou nejakej T -normy s výstupom pravidla. Výsledkom je upravený čiastkový akčný zásah vo forme FP LY_c^k za pravidlo k v závislosti na tom, do akej miery je splnený predpoklad pravidla. Ak výsledná FP obsahuje aj stupne príslušnosti väčšie ako 0, tak pravidlo je odpálené a postupuje do fázy kompozície. Takto sa vyšetrí všetky pravidlá bázy pravidiel.

Tento druh inferencie pre nižšie potreby kapacity pamäte procesora sa v praktických aplikáciách najviac využíva.


2.2.4. Kompozícia

Kompozícia sa vykoná iba v prípade inferencie podľa jednotlivých pravidiel. Vo fáze kompozície sú fuzzy množiny výstupov všetkých odpálených pravidiel navzájom skombinované tak, aby sa získala jediná spoločná funkcia príslušnosti výstupu LU. Keď jednotlivé pravidlá sú navzájom pospájané spojkou OR, tak sa použije nejaká T - konorma a v prípade, že sú pospájané spojkou AND, tak sa aplikuje nejaká T - norma:

$$LY = S\left(S\left(\dots S\left(S\left(LY_c^1, LY_c^2\right), LY_c^3\right)\dots\right), LY_c^m\right)$$

$$LY = T\left(T\left(\dots T\left(T\left(LY_c^1, LY_c^2\right), LY_c^3\right)\dots\right), LY_c^m\right)$$

Výsledkom môže byť napríklad celkový výstup vo forme FP na obrázku:



Obrázok 4: Príklad možného tvaru výstupnej funkcie príslušnosti získanej kompozíciou funkcií príslušnosti čiastkových výstupov.

Zaujímavou metódou, ktorá sa môže najlepšie uplatniť pri vysokom počte odpálených pravidiel, je metóda piatich najbližších susedov. Tento prístup spočíva na konštruovaní výslednej funkcie príslušnosti výstupu kombináciou funkcií príslušnosti výstupov piatich pravidiel, ktorých lingvistické hodnoty v predpokladovej časti sú najviac podobné lingvistickým vstupom prichádzajúcich do regulátora. Pomocou vhodne vybranej normy sa lingvistické vstupy s ich stupňami príslušnosti porovnávajú s predpokladovou časťou pravidla. Takto sa vypočítajú ich vzdialenosti, ktoré sa umiestnia do vektora, kde jednotlivé položky zodpovedajú vstupom, potom sa za celý vektor vypočíta celková vzdialenosť d .

Pre n pravidiel vznikne n vektorov, z ktorých sa vyberie päť pravidiel s najmenším d_k .

$$d_k \ (k=1, \dots, k=5) \text{ kde } d_i < d_j \text{ pre } i < j \text{ t.j. } d_{\max} = d_s$$

Absolútne váhy sa vypočítajú nasledovne a sú to čísla od 0 po 1:

$$w = \frac{d_{\max} - d_k}{d_{\max}} \Rightarrow w \in \langle 0, 1 \rangle$$

2.2.5. Defuzzifikácia

Výsledkom kompozície je výstup vo forme FM s FP LY , ktorej stupne príslušnosti pre dané u sú $\mu_v(y)$. Ak požadujeme, aby výstup bol vo forme ostrého čísla y , tak musí byť vykonaná defuzzifikácia tejto FM. Ak by sme chceli vypočítať inverznú funkciu z FP LY , tak táto by bola vo všeobecnosti nejednoznačným zobrazením, t.j. nedostali by sme jednu jedinú výslednú hodnotu. Z tohto dôvodu je možné zdefinovať celý rad metód defuzzifikácie. Väčšina z týchto metód je odvodená z dvoch základných všeobecných metód, a to metódy ťažiska a metódy maxima.

1. Metóda ťažiska je založená na výpočte ťažiska plochy výslednej funkcie príslušnosti výstupu získanej pri kompozícii podľa nasledujúceho vzťahu:

$$y^* = \frac{\int_v y \mu_v(y) du}{\int_v \mu_v(y) du}$$

Táto metóda najlogickejšie zodpovedá predstave o tom, ktorá hodnota by mala byť z množiny možných výstupov vybratá, kladie však vysoké nároky na výpočtovú zložitosť.

2. Metóda priemerného súčtu je modifikovanou metódou ťažiska, ktorá zohľadňuje prípady, kde sa FP čiastkových výstupov sčasti prekrývajú, no vo fáze kompozície sa táto informácia stráca. Aby sa plochy, ktoré sa viackrát prekrývajú mohli zobrať do úvahy, použije sa nasledujúci vzťah:

$$y^* = \frac{\int_V y \sum_{k=1}^m \mu_{v_c^k}(y) du}{\int_V \sum_{k=1}^m \mu_{v_c^k}(y) du}$$

Táto metóda vykazuje dokonca menšie výpočtové nároky ako metóda ťažiska a je vôbec najpoužívanejšou defuzzifikačnou metódou.

3. Metóda ťažiska najväčšieho priestoru je skôr metodickým postupom. Táto metóda sa najčastejšie uplatňuje v prípade, ak FP celkového výstupu je nekonvexná, t.j. ak FP má lokálne minimá, čo môže viesť k tomu, že ako u (ostrá hodnota) bude zvolená hodnota s nízkym stupňom príslušnosti. V takomto prípade sa nejakým spôsobom (napr. aj heuristickým) nájde najväčšia konvexná časť funkcie príslušnosti LU a len z tejto časti sa pomocou metódy ťažiska vypočíta u (ostrá hodnota).
4. Metóda stupňov patrí do skupiny metód maxima. U tejto metódy kompozícia a defuzzifikácia splývajú v jeden výpočtový krok. Najprv sa vypočítajú hodnoty vrcholov jednotlivých čiastkových výstupov LY_c^k , t.j. $p_k = P(LY_c^k)$. Ak namiesto vrcholu je interval hodnôt u s maximálnym stupňom príslušnosti, tak sa z nich vyberie prostredná hodnota p_k . Potom sa použije vzťah váženého priemeru:

$$y^* = \frac{\sum_{k=1}^m p_k \mu_{v_c^k}(p_k)}{\sum_{k=1}^m p_k}$$

Vo všeobecnosti metódy maxima vykazujú nízku výpočtovú náročnosť, ale nezohľadňujú tvar FP a jej nosič, čo sa prejavuje najmä u FP nesymetrických voči maximu, preto v takýchto prípadoch metódy maxima nie sú vhodné.

5. Metóda prvého maxima je založená na výbere prvej hodnoty u , ktorá nadobúda maximálny stupeň príslušnosti:

Jej využitie je možné v prípadoch, že chceme zmierniť (vyhladiť) rýchlosť zmeny akčnej veličiny.

6. Metóda posledného maxima je protikladom k predošlej metóde, t.j.:

Jej využitie je možné ak potrebujeme zrýchliť dynamiku riadenia t.j. dosiahnuť čo najrýchlejšiu zmenu akčnej veličiny.

7. Metóda stredného maxima je kompromisom predošlých dvoch metód.

Nech $y_{\min}^*$ je výsledkom metódy prvého maxima a $y_{\max}^*$ výsledkom metódy posledného maxima, potom

$$y^* = y_{\min}^* - \frac{y_{\max}^* - y_{\min}^*}{2}$$

Vlastne je to samotná metóda maxima v tej najčistejšej podobe, čo sa princípu a vlastností týka.

2.3. Fuzzy modely

Oproti modelu pomocou viacvrstvovej neurónovej siete, kde sú informácie roztrúsené vo váhach neurónových spojení, sú informácie vo fuzzy modely jasne interpretovateľné v lokálnych modeloch. To prináša výhodu poskytnutia predbežnej apriórnej informácie do fuzzy modelu, ak je k dispozícii, alebo jednou z metód zhlukovej analýzy. Tieto metódy hľadajú v nameraných vstupno-výstupných údajoch množiny navzájom blízkyh dát, zhluky (clustery).

2.3.1 Substraktívna zhluková analýza

Využitie možnosti dodať apriórne informácie je diskutovaná v rôznych prácach rôzne. V literatúre sme sa stretli s rôznymi deleniami vstupného priestoru pri hľadaní zhlukov, napríklad, prostredníctvom zhlukových analýz (fuzzy clustering). Existuje množstvo algoritmov, fuzzy modifikácií základného C-Means clusteringu HCM, z ktorých sú odvodené fuzzy verzie FCM, ale mnohé majú spoločnú tú vlastnosť, že

potrebujú apriórne zadaný počet zhlukov, ktorých centrá majú určiť. To značne komplikuje automatickú tvorbu modelu.

Substraktívny clustering (substraktívna zhluková analýza) poskytuje zásadnú výhodu automatického určenia počtu clusterov, čo znamená možnosť automatického generovania fuzzy modelu pri poskytnutí iba vstupno-výstupných údajov, bez nutnosti explicitného zadávania počtu hľadaných zhlukov. Táto metóda hľadá vo vstupno-výstupných údajoch zhluky navzájom podobných údajov, pričom každý zhluk predstavuje samostatný lokálny model fuzzy systému. Výhodou substraktívneho clusteringu oproti mnohým iným metódam zhlukových analýz a samo organizujúcich sa máp je optimálny počet nájdených zhlukov, a automatické určenie ich počtu. Mnohé iné zhlukové metódy vyžadujú apriórne zadanie počtu zhlukov, a ďalej hľadajú iba ich umiestnenie. Substraktívna zhluková analýza ich optimálny počet určí sama. Kľúčovým pojmom v tejto metóde je tzv. miera hustoty každého bodu vo vstupno-výstupných údajoch. Okolo každého bodu sa kvantitatívne vyjadrí hustota, s akou sú okolo neho rozložené okolité body. Bod s najväčšou hustotou predstavuje súradnicu prvého zhliku, čiže prvé nájdené fuzzy pravidlo.

2.3.2 Mamdaniho model

Tento model je najstarším a v súčasnosti aj najrozšírenejším typom fuzzy modelu. Vyvinul ho profesor Mamdani v roku 1974 a bol odskúšaný na laboratórnom parnom stroji. Pôvodne bol navrhnutý pre inferenciu podľa jednotlivých pravidiel, ale nevylučuje sa aj použitie kompozičnej inferencie. Hlavným charakteristickým rysom je použitie operátora minima v procese inferencie a operátora maxima v procese akumulácie. Sú to najjednoduchšie operátory, takže nároky na výpočet sú v porovnaní s inými operátormi najnižšie. Pre takúto inferenciu a akumuláciu ako celok (t.j. inferenciu v najširšom slova zmysle) sa v literatúre používa aj pojem metóda MIN-MAX.

V praxi sa vyskytujú aj niektoré aplikácie, ktoré namiesto operátora minima využívajú operátor produktu a namiesto operátora maxima operátor sumy. Takáto metóda sa nazýva PRODUCT-SUM.

V procese fuzzifikácie sú ostré hodnoty vstupujúce do modelu pretransformované na fuzzy množiny, ktorých funkcie príslušnosti (ďalej FP) sú v tvare singletonov. Realizuje sa výpočet hodnoty pre celú časť predpokladu každého pravidla. Ide tu o skladanie

stupňov príslušnosti jednotlivých vstupov (v tomto prípade jednotlivých singletonov). Výsledkom je zase singleton za celú predpokladovú časť k-teho pravidla so stupňom príslušnosti μ_a^k , označovaný ako sila pravidla (alebo alfa pravidla), ktorý vyjadruje, do akej miery je predpoklad pravidla splnený (v intervale $<0; 1>$). Existuje celá rada spôsobov výpočtu sily pravidla. Najčastejšie používané metódy sú:

1. metóda MIN
2. metóda PRODUCT
3. metóda SOFTMIN

Tieto metódy zabezpečujú, že sila pravidla sa pohybuje v rozsahu $<0; 1>$.

U metódy MIN je funkcia príslušnosti zhora orezaná najmenším stupňom príslušnosti vstupov. Je tu priama súvislosť s interpretáciou operácie konjunkcie vo fuzzy logike. Táto metóda je najviac používaná. U metódy PRODUCT je funkcia príslušnosti vynásobená najmenším stupňom príslušnosti vstupov. Metóda SOFTMIN je modifikáciou a rozšírením MIN.

Pravidlá, ktoré majú silu väčšiu ako 0, sú odpálené a postupujú do fázy akumulácie. Keďže jednotlivé pravidlá sú navzájom pospájané spojkami disjunkcie, tento fakt sa uplatní aj v jednotlivých metódach kompozície. Zvyčajne sa používajú metódy:


1. metóda MAX
2. metóda SUM

U metódy MAX je výsledná funkcia príslušnosti vytváraná pridávaním maximálnych hodnôt výstupných FP jednotlivých pravidiel bod po bode. U metódy SUM je výsledná funkcia príslušnosti vytváraná sčítavaním hodnôt výstupných FP jednotlivých pravidiel bod po bode. V tomto prípade sa ale môžu vyskytnúť pravdivostné hodnoty väčšie ako 1. Preto môže byť použitá len vtedy, ak je výsledok normovaný alebo defuzzifikovaný.

Postup práce Mamdaniho modelu:

1. fuzzifikácia - pomocou singletonov
2. operátor kompatibility T_C - MIN
3. operátor inferencie v užšom zmysle slova T_I - MIN
4. operátor akumulácie S_A - MAX

MIN-MAX model sa používa pre potreby rýchleho modelovania. Pri modelovaní sa berú do úvahy len maximálne hodnoty. Pri PRODUCT-MAX modely je priebeh plynulejší, bez lokálnych miním, prechodový dej však trvá dlhšie.



Obrázok 5: Grafické znázornenie metódy MIN-MAX

2.3.3 Sugenov model

Tento model sa nazýva podľa svojho tvorca prof. Sugena. Na jeho tvorbe a vylepšení majú podiel aj Takagi a Kang. Preto sa niekedy tento model označuje aj ako Takagi - Sugeno - Kangov model (TSK). Štruktúra a princíp činnosti sú veľmi podobné Mamdaniho modelu, líši sa iba v tom, že výstup z pravidla nie je fuzzy premenná, ale analytická funkcia, takže tu odpadá potreba defuzzifikácie, čím sa dosiahne aj vyššia rýchlosť výpočtu.

Tento model je výhodné použiť v prípadoch, keď nevieme presne určiť stav, v ktorom sa modelovaná sústava nachádza (ak je stav známy, návrh akčného zásahu už je možné analyticky popísať). Majme sústavu m pravidiel typu IF-THEN, ktoré sú tvaru:

$$\begin{aligned} & \text{AK } x_1 \text{ je } LX_1^1 \text{ A ... A } x_n \text{ je } LX_n^1 \text{ POTOM } u_1^* = f_1(x_1, \dots, x_n) \\ & \text{AK } x_1 \text{ je } LX_1^2 \text{ A ... A } x_n \text{ je } LX_n^2 \text{ POTOM } u_2^* = f_2(x_1, \dots, x_n) \\ & \dots \\ & \text{AK } x_1 \text{ je } LX_1^m \text{ A ... A } x_n \text{ je } LX_n^m \text{ POTOM } u_m^* = f_m(x_1, \dots, x_n) \end{aligned}$$

LX sú funkcie príslušnosti, pomocou ktorých sú reprezentované významy jednotlivých lingvistických hodnôt, x_i sú vstupy, ktoré sú vyčíslené pomocou analytických funkcií f_i . Celkový výsledok y^* so silami jednotlivých pravidiel μ_{yi} :

$$y^* = \frac{\sum_{i=1}^m \mu_{yi} y_i^*}{\sum_{i=1}^m \mu_{yi}}$$

Pri takomto type modelov sa minimalizuje výpočtová náročnosť výpočtu pravidiel. Odpadá problém defuzzifikácie, ako operátory inferencie sa používajú metódy MIN, SOFTMIN, PRODUCT a akumulácia sa realizuje výpočtom jednoduchého váženého priemeru.

Nelinearita TSK modelu:

Predpokladajme špeciálny prípad, že f_i je lineárna funkcia, t.j.:

$$y_i^* = c_{1i}x_1 + c_{2i}x_2 + \dots + c_{ni}x_n$$

kde c_{ji} sú parametre (konštanty), potom pre y^* dostaneme:

$$y^* = \frac{\sum_{i=1}^m (c_{1i} + c_{2i} + \dots + c_{ni}) \mu_{yi}}{\sum_{i=1}^m \mu_{yi}}$$

ak zavedieme substitúcie p_1 až p_n , dostaneme:

$$y^* = \frac{\sum_{i=1}^m c_{1i} \mu_{yi}}{\sum_{i=1}^m \mu_{yi}} x_1 + \frac{\sum_{i=1}^m c_{2i} \mu_{yi}}{\sum_{i=1}^m \mu_{yi}} x_2 + \dots + \frac{\sum_{i=1}^m c_{ni} \mu_{yi}}{\sum_{i=1}^m \mu_{yi}} x_n$$

$$y^* = p_1 x_1 + p_2 x_2 + \dots + p_n x_n$$

Táto rovnica udáva, že výsledná hodnota y^* je (pri opomenutí spôsobu získania parametrov p_1 až p_n) výsledkom lineárnej funkcie. Nelinearita je skrytá vo výpočte parametrov p_i a samotné vstupy sú v lineárnom vzťahu, čo je určujúce pri posúdení, či systém je lineárny alebo nie.

Ak x_i sú jednotlivé derivácie vstupu x , t.j. $(x^{(0)}, x^{(1)}, x^{(2)}, \dots, x^{(n-1)})$, tak tento vzťah bude predstavovať lineárny filter s premenlivými parametrami, ktorý na rozdiel od klasickej stavovej adaptívnej filtrácie, kde sa robí tvrdé prepínanie medzi klasickými filtermi a v okolí bodu prepnutia môže dochádzať k nespojitostiam, poskytuje možnosť hladkej filtrácie v celom rozsahu vstupných hodnôt x .


2.4. ANFIS

Z veľkého počtu typov hybridných neuro - fuzzy systémov patrí medzi najznámejšie systém **ANFIS** (Adaptive Neuro – Fuzzy Inference System). Ide o prepis fuzzy modelu do doprednej neurónovej siete. Najväčším problémom pri ladení tohto typu neuro – fuzzy systémov ostáva výber skupiny dát určenej na učenie siete. Ak existuje v rámci simulačných experimentov, alebo v reálnej prevádzke učiteľ, je najtriviálnejšie získať dáta kopírovaním jeho činnosti. Učiteľom môže byť v tomto prípade správne nastavený model, prípadne človek (operátor). Nevýhodou tohto prístupu je neprenositelnosť takto naladeného fuzzy modelu na iný riadený systém. Pri prenose na iný systém je potrebná znova prítomnosť kvalifikovaného operátora a následné správne ladenie.

Vnútorne je ale reprezentovaný ako päťvrstvová dopredná neurónová sieť, ktorej učenie je založené na minimalizácii odchýlok metódou najmenších štvorcov a zodpovedá úprave tzv. premisných a konsekvntných parametrov. Tieto parametre nie sú uložené

vo váhach spomínanej neurónovej siete, ale v jej uzloch - preto je správne hovoriť tu o adaptívnej, nie neurónovej sieti (jednou zo základných vlastností neurónových sietí je, že informácie sa ukladajú do medzineurónových spojení, tzv. synaptických váh).

2.4.1. ANFIS architektura



Obrázok 6: Štruktúra ANFIS

Vrstva 1:

Každý uzol tejto vrstvy je adaptívny, s funkciou

$$O_i^1 = \mu_{A_i}(x)$$

Výstupom je teda hodnota príslušnosti vstupu x k úrovni A_i lingvistickej premennej. Obyčajne zvolíme funkciu μ_{A_i} tvaru zvona, s maximom rovným 1 a minimom 0.

$$\mu_{A_i} = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}}$$

a_i, b_i, c_i je množina parametrov, pomocou ktorých tieto funkcie príslušnosti môžu meniť svoj tvar i polohu. Sú to *premisné parametre*.

Vrstva 2:

Každý uzol tejto vrstvy je neadaptívny, označený znakom Π , ktorý násobí vstupné signály a vysiela ich súčin. Reprezentuje silu pravidla.

Vrstva 3:

Každý uzol tejto vrstvy je neadaptívny a počíta pomer sily i-teho pravidla k sume všetkých síl pravidiel

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2$$

Vrstva 4:

Každý uzol tejto vrstvy je adaptívny, s množinou *konsekventných parametrov*:

$$p_i, q_i, r_i$$

$$O_i^4 = \bar{w}_i f = \bar{w}_i (p_i x + q_i y + r_i)$$

Vrstva 5:

Neadaptívny uzol plniaci funkciu sčítania vstupných signálov

$$O_i^5 = \text{celkovovstup} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

Na trénovanie siete používa *anfis* hybridnú učiacu metódu. Parametre v antecedente pravidla (určujúce funkcie príslušnosti vstupných premenných) sú optimalizované gradientovou metódou, parametre konsekventu (konštanty alebo koeficienty lineárnej funkcie) sa počítajú metódou najmenších štvorcov.

2.4.2. Postup výpočtu metódou ANFIS v Matlabe


1. Inicializácia fuzzy systému: príkazy *genfis1*, *genfis2*, alebo *genfis3*
2. Zadanie parametrov potrebných na učenie: počet iterácií (epochy), tolerancia (chyba).
3. Začiatok procesu učenia: príkaz *anfis*; pri dosiahnutí zadanej tolerancie sa výpočet končí.
4. Overenie správnosti výpočtu s nezávislými údajmi.

3. PRAKTICKÁ ČASŤ

3.1. Model zásobníkov kvapaliny

Cieľom projektu bolo vytvorenie neuro-fuzzy modelu troch zásobníkov kvapaliny na základe nameraných vstupno-výstupných údajov pomocou metódy ANFIS.

Zásobníky kvapaliny sú prietochné procesy s jednoduchou akumuláciou hmoty. Patria medzi najrozšírenejšie zariadenia chemickej technológie. Pri riadení sústavy zásobníkov kvapaliny nás zaujíma hlavne, ako vplýva vstupný prietok kvapaliny na výšky hladín v jednotlivých zásobníkoch.



Obrázok 7: Schéma zapojenia 3 zásobníkov kvapaliny

Parameter	Jednotka	Hodnota
k_{11}	$\text{m}^{2,5} \text{min}^{-1}$	1,2
k_{22}	$\text{m}^{2,5} \text{min}^{-1}$	1,2
k_{33}	$\text{m}^{2,5} \text{min}^{-1}$	1,2
F_1	m^2	2
F_2	m^2	2
F_3	m^2	2
q_{01}	$\text{m}^3 \text{min}^{-1}$	1
q_{02}	$\text{m}^3 \text{min}^{-1}$	0
q_{03}	$\text{m}^3 \text{min}^{-1}$	0,25

Tabuľka 1: Parametre zásobníkov kvapaliny

Nelineárny dynamický matematický model

$$\begin{aligned}F_1 \frac{dh_1(t)}{dt} &= q_{01}(t) - k_{11}\sqrt{h_1(t) - h_2(t)} \\F_2 \frac{dh_2(t)}{dt} &= k_{11}\sqrt{h_1(t) - h_2(t)} - k_{22}\sqrt{h_2(t)} + q_{02}(t) \\F_3 \frac{dh_3(t)}{dt} &= -k_{33}\sqrt{h_3(t)} + k_{22}\sqrt{h_2(t)} + q_{03}(t)\end{aligned}$$

Materiálová bilancia (v ustálenom stave)

$$\begin{aligned}F_1 \frac{dh_1^s}{dt} &= q_{01}^s - k_{11}\sqrt{h_1^s - h_2^s} \\F_2 \frac{dh_2^s}{dt} &= k_{11}\sqrt{h_1^s - h_2^s} - k_{22}\sqrt{h_2^s} + q_{02}^s \\F_3 \frac{dh_3^s}{dt} &= -k_{33}\sqrt{h_3^s} + k_{22}\sqrt{h_2^s} + q_{03}^s\end{aligned}$$

Výpočet výšky hladín

$$\begin{aligned}h_1^s &= \left(\frac{q_{01}}{k_{11}} \right)^2 + h_2^s \\h_2^s &= \left(\frac{q_{01} + q_{02}}{k_{22}} \right)^2 \\h_3^s &= \left(\frac{q_{03} + q_2}{k_{33}} \right)^2\end{aligned}$$

DMM – MMRS

$$\begin{aligned}F_1 \frac{dh_1(t)}{dt} - F_1 \frac{dh_1^s}{dt} &= -k_{11}\sqrt{h_1(t) - h_2(t)} + k_{11}\sqrt{h_1^s - h_2^s} + q_{01}(t) - q_{01}^s \\F_2 \frac{dh_2(t)}{dt} - F_2 \frac{dh_2^s}{dt} &= -k_{22}\sqrt{h_2(t)} + k_{22}\sqrt{h_2^s} \\k_{11}\sqrt{h_1(t) - h_2(t)} - k_{11}\sqrt{h_1^s - h_2^s} &+ q_{02}(t) - q_{02}^s\end{aligned}$$

$$F_3 \frac{dh_3(t)}{dt} - F_3 \frac{dh_3^s}{dt} = -k_{33}\sqrt{h_3(t)} + k_{33}\sqrt{h_3^s} + k_{22}\sqrt{h_2(t)} - k_{22}\sqrt{h_2^s} + q_{03}(t) - q_{03}^s$$

$$F_1 \frac{d[h_1(t) - h_1^s]}{dt} = -k_{11}\sqrt{h_1(t) - h_2(t)} + k_{11}\sqrt{h_1^s(t) - h_2^s} + q_{01}(t) - q_{01}^s$$

$$F_2 \frac{d[h_2(t) - h_2^s]}{dt} = -k_{22}\sqrt{h_2(t)} + k_{22}\sqrt{h_2^s} + k_{11}\sqrt{h_1(t) - h_2(t)} -$$

$$-k_{11}\sqrt{h_1^s - h_2^s} + q_{02}(t) - q_{02}^s$$

$$F_3 \frac{d[h_3(t) - h_3^s]}{dt} = -k_{33}\sqrt{h_3(t)} + k_{33}\sqrt{h_3^s} + k_{22}\sqrt{h_2(t)} - k_{22}\sqrt{h_2^s} + q_{03}(t) - q_{03}^s$$

Linearizácia nelineárneho člena

$$\sqrt{h_1 - h_2} \Big|_{h_1 - h_1^s, h_2 - h_2^s} = \sqrt{h_1^s - h_2^s} + \frac{\partial \sqrt{h_1 - h_2}}{\partial h_1} \Big|_{h_1 - h_1^s, h_2 - h_2^s} (h_1 - h_1^s) +$$

$$\frac{\partial \sqrt{h_1 - h_2}}{\partial h_2} \Big|_{h_1 - h_1^s, h_2 - h_2^s} (h_2 - h_2^s) = \sqrt{h_1^s - h_2^s} + \frac{1}{2\sqrt{h_1^s - h_2^s}} x_1(t) - \frac{1}{2\sqrt{h_1^s - h_2^s}} x_2(t)$$

$$\sqrt{h_2} \Big|_{h_2 - h_2^s} = \sqrt{h_2^s} + \frac{\partial \sqrt{h_2}}{\partial h_2} \Big|_{h_2^s} (h_2 - h_2^s) = \sqrt{h_2^s} + \frac{1}{2\sqrt{h_2^s}} x_2(t)$$

$$\sqrt{h_3} \Big|_{h_2 - h_2^s} = \sqrt{h_3^s} + \frac{\partial \sqrt{h_3}}{\partial h_3} \Big|_{h_3^s} (h_3 - h_3^s) = \sqrt{h_3^s} + \frac{1}{2\sqrt{h_3^s}} x_3(t)$$

Dosadenie po linearizácii

$$F_1 \frac{dx_1(t)}{dt} = -k_{11}\sqrt{h_1^s - h_2^s} - k_{11} \frac{1}{2\sqrt{h_1^s - h_2^s}} x_1(t) + k_{11} \frac{1}{2\sqrt{h_1^s - h_2^s}} x_2(t) + k_{11}\sqrt{h_1^s - h_2^s} + u_1(t)$$

$$F_2 \frac{dx_2(t)}{dt} = -k_{22}\sqrt{h_2^s} - k_{22} \frac{1}{2\sqrt{h_2^s}} x_2(t) + k_{22}\sqrt{h_2^s} + k_{11}\sqrt{h_1^s - h_2^s} +$$

$$+ k_{11} \frac{1}{2\sqrt{h_1^s - h_2^s}} x_1(t) - k_{11} \frac{1}{2\sqrt{h_1^s - h_2^s}} x_2(t) - k_{11}\sqrt{h_1^s - h_2^s} + u_2(t)$$

$$F_3 \frac{dx_3(t)}{dt} = u_3(t) + k_{22}\sqrt{h_2^s} + k_{22} \frac{1}{2\sqrt{h_2^s}} x_2(t) - k_{22}\sqrt{h_2^s} - \left[k_{33}\sqrt{h_3^s} + \frac{1}{2\sqrt{h_3^s}} x_3(t) - k_{33}\sqrt{h_3^s} \right]$$

Definovanie konštánt

$$k_1 = k_{11} \frac{1}{2\sqrt{h_1^s - h_2^s}}$$

$$k_2 = k_{22} \frac{1}{2\sqrt{h_2^s}}$$

$$k_3 = k_{33} \frac{1}{2\sqrt{h_3^s}}$$

Linearizovaný model

$$F_1 \frac{dx_1(t)}{dt} = -k_1 x_1(t) + k_1 x_2(t) + u_1(t)$$

$$F_2 \frac{dx_2(t)}{dt} = k_1 x_1(t) - k_1 x_2(t) - k_2 x_2(t) + u_2(t)$$

$$F_3 \frac{dx_3(t)}{dt} = k_2 x_2(t) - k_3 x_3(t) + u_3(t)$$

$$y_1(t) = x_1(t)$$

$$y_2(t) = x_2(t)$$

$$y_3(t) = x_3(t)$$

$$\frac{dx_1(t)}{dt} = -\frac{k_1 x_1(t)}{F_1} + \frac{k_1 x_2(t)}{F_1} + \frac{u_1(t)}{F_1}$$

$$\frac{dx_2(t)}{dt} = \frac{k_1 x_1(t)}{F_2} - \frac{k_1 x_2(t)}{F_2} - \frac{k_2 x_2(t)}{F_2} + \frac{u_2(t)}{F_2}$$

$$\frac{dx_3(t)}{dt} = \frac{k_2 x_2(t)}{F_3} - \frac{k_3 x_3(t)}{F_3} + \frac{u_3(t)}{F_3}$$

Rovnice, opisujúce zásobníky kvapaliny, tvoria s-funkciu. Táto s-funkcia bola použitá na vytvorenie simulinkovej schémy na získanie vstupných tréningových údajov (je uvedená v prílohe).

Matice linearizovaného modelu použité v schéme č.2, ktorá je uvedená v prílohe.

$$A = \begin{pmatrix} \frac{-k1}{F1} & \frac{k1}{F1} & 0 \\ \frac{k1}{F2} & \frac{-k1-k2}{F2} & 0 \\ 0 & \frac{k2}{F3} & -\frac{k3}{F3} \end{pmatrix}$$

$$B = \begin{pmatrix} \frac{1}{F1} & 0 & 0 \\ 0 & \frac{1}{F2} & 0 \\ 0 & 0 & \frac{1}{F3} \end{pmatrix}$$

$$C = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$$


$$D = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix}$$

$$A = \begin{pmatrix} -0.360 & 0.360 & 0 \\ 0.360 & -0.720 & 0 \\ 0 & 0.360 & -0.288 \end{pmatrix}$$

$$B = \begin{pmatrix} 0.5 & 0 & 0 \\ 0 & 0.5 & 0 \\ 0 & 0 & 0.5 \end{pmatrix}$$

$$C = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$$

$$D = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix}$$



Obrázok 8: Odozva výšky hladiny v 3. zásobníku na 20% skokovú zmenu prietoku q_{01}

3.1.1 Genfis 1

Príkaz *genfis1* generuje východiskový fuzzy inferenčný systém (FIS) Sugenovského typu na trénovanie neurónovej siete použitím mriežkového rozkladu vstupných dát.


Najjednoduchší formát príkazu je: *genfis1*(DATA).

DATA obsahujú údaje v stĺpcoch, pričom prvé stĺpce sú automaticky považované za vstupné údaje a posledný stĺpec je výstup. Pre každý vstup sa štandardne používajú 2 zvonové funkcie príslušnosti a parametre výstupu sa počítajú ako lineárna funkcia.


Parametre príkazu sa dajú voliť: *genfis1*(DATA, NUMMFS, INPUTMF, OUTPUTMF)

Môžeme voliť:

- NUMMFS: počet funkcií príslušnosti každého vstupu
- INPUTMF: typ funkcií príslušnosti každého vstupu. Fuzzy Toolbox obsahuje funkcie príslušnosti *trimf*, *trapmf*, *gbellmf*, *gaussmf*, *gauss2mf*, *dsigmf*, *psigmf*, *pimf*.
- OUTPUTMF: parametre konsekventov pravidiel fis-funkcie môžu byť počítané ako konštanty alebo ako koeficienty lineárnej funkcie




Obrázok 9: Funkcie príslušnosti v Matlabe



Obrázok 10: Gaussovske funkcie príslušnosti


Na obrázku 10 sú znázornené Gaussovske funkcie príslušnosti a na obrázku 11 je priebeh nameranej výšky hladiny v porovnaní s modelom typu Takagi-Sugeno s Gaussovskými funkciami príslušnosti pre vstupnú veličinu, m-file je súčasťou prílohy. Obrázky porovnávajú presnosť modelov pre rôzny počet funkcií príslušnosti, v tomto prípade 3 a 13.




Obrázok 11: Priebeh nameranej výšky hladiny a výšky hladiny po identifikácii.

V prílohe č.8 sú uvedené priebehy zvonových a lichobežníkových funkcií príslušnosti a porovnanie priebehov výšky hladiny v treťom zásobníku s modelmi typu Takagi-Sugeno s uvedenými funkciami príslušnosti. Pre porovnanie bol použitý rovnaký počet funkcií príslušnosti ako vo vyššie uvedenej identifikácii, teda 3 a 13.

Zobrazenie pravidiel pre 3 a 13 Gaussovských funkcií príslušnosti je na obrázku 12-13. Pravidlá sú zobrazené použitím príkazu *ruleview*.




Obrázok 12: Pravidlá pre 3 Gaussovske funkcie príslušnosti




Obrázok 13: Pravidlá pre 13 Gaussovských funkcií príslušnosti

Na obrázkoch 14-15 je pre uvedené pravidlá znázornená štruktúra Anfis.



Obrázok 14: Štruktúra ANFIS pre 3 pravidlá




Obrázok 15: Štruktúra ANFIS pre 13 pravidiel


3.1.2 Genfis 2

Príkaz *genfis2* generuje fuzzy inferenčný systém (FIS) Sugenovského typu použitím metódy subtraktívneho zhľukovania vstupných údajov pomocou funkcie SUBCLUST na predpokladanie počtu funkcií príslušnosti a určenie pravidiel. Príkaz na použitie *genfis2* v Matlabe má tvar: *genfis2* (XIN, XOUT,RADII)

Subtraktívne zhľukovanie patrí k metódam delenia vstupného priestoru pri hľadaní zhľukov, pričom poskytuje zásadnú výhodu automatického určenia počtu zhľukov, to znamená, že fuzzy modely sa automaticky vygenerujú pri poskytnutí iba vstupných údajov, bez zadávania počtu zhľukov. Pomocou tejto metódy sa vo vstupných údajoch hľadájú zhľuky navzájom podobných údajov. Okolo každého bodu sa kvantitatívne vyjadri hustota, s akou sú okolo neho rozložené okolité body. Bod s najväčšou hustotou predstavuje súradnice prvého zhľuku - prvé nájdené fuzzy pravidlo. Pri hľadaní ďalších zhľukov sa miery hustôt ďalších zhľukov oslabujú o hustotu nájdených zhľukov. Obyčajne stačí meniť posledný údaj RADII. Jeho hodnota je od 0 po 1. Čím je hodnota menšia, tým väčší je počet zhľukov. Počet pravidiel predstavuje počet zhľukov.



Obrázok 16: Porovnanie výšok hladín pri identifikácii s 3 pravidlami



Obrázok 17: Porovnanie výšok hladín pri identifikácii pre 52 pravidiel

RADII	Počet zhlukov	RADII	Počet zhlukov
1	2	0,09	20
0,9	2	0,08	23
0,8	2	0,07	29
0,7	2	0,06	37
0,6	2	0,05	52
0,5	3	0,04	65
0,4	4	0,03	98
0,3	5	0,02	177
0,2	7	0,01	333
0,1	17	0	0

Tabuľka 2: Rôzne hodnoty RADII vo funkcii *genfis2* a s tým súvisiaci rôzny počet zhlukov.


3.1.3 Genfis 3

Hlavným charakteristickým rysom tejto metódy je použitie operátora minima v procese inferencie a operátora maxima v procese akumulácie.


Príkaz *genfis3* pracuje na princípe hľadania centier zhlukov pomocou algoritmu *fcm* a má 4 nastaviteľné parametre, ktoré majú štandardne hodnoty [0,5; 1,25; 0,5; 0,15]. Pri tejto metóde sa predpokladá, že všetky údaje patria do jednotkovej kocky.

V Matlabe má tvar: *genfis3* (x,y,'mamdani',14, [0,5; 1,25; 0,5; 0,15].);


- Prvé číslo je miera vplyvu na údaje v uvedenom priestore,
- Druhé číslo ovplyvňuje voľbu, či sú zhluky pri sebe blízko alebo ďaleko,
- Tretie číslo je polomer oblasti, v ktorej sa má počítať miera hustoty okolo daného bodu,
- Štvrté číslo je polomer oblasti, v ktorej má dôjsť k redukcii miery hustoty v okolí zhuku daného bodu.



Obrázok 18: Pribeh nameranej výšky hladiny a výšky hladiny po identifikácii pomocou príkazu *genfis3*




Obrázok 19: Pravidlá pre model typu Mamdani



Obrázok 20: Znáozornenie centier zhluokov

Na obrázku 20 je znázornených 9 centier zhluokov, teda výsledná fis matica má 9 pravidiel. Na obrázku 21 je znázornené vytvorenie 5 zhluokov, teda výsledná fis matica má 5 pravidiel.



Obrázok 21: Znázornenie jednotlivých zhlukov

4. ZÁVER

Cieľom tejto práce bola identifikácia zásobníkov kvapaliny pomocou metódy ANFIS. Vstupné údaje boli získané pomocou s - funkcie, ktorá opisovala skúmaný systém. Meranou veličinou bola výška hladiny v treťom zásobníku. Pri tvorbe FIS modelu boli použité funkcie *genfis1*, *genfis2* a *genfis3*, ktoré sú súčasťou Toolboxu a využívajú metódy a algoritmy ako mriežkové rozdelenie, fcm, anfis, subtraktívne zhľukovanie. Môžeme si položiť otázky:

Má tvar funkcií príslušnosti vplyv na identifikáciu?

Má význam zväčšovať počet funkcií príslušnosti?

Z výsledkov riešenia zadanej problematiky vyššie uvedenými metódami vyplývajú nasledujúce poznatky:

Pre prípad *genfis1* je vhodnejšie použiť na identifikáciu Gaussovské alebo zvonové funkcie príslušnosti ako lichobežníkové. So zvyšovaním počtu pravidiel a počtu funkcií príslušnosti je identifikácia síce presnejšia, ale model sa stáva zložitejším.

Pri metóde *genfis2* sa menil parameter RADII. Zistilo sa, že znížením jeho hodnoty sa zlepšuje identifikácia, avšak rastie počet pravidiel.

Príkaz *genfis3* pracuje na princípe hľadania centier zhľukov pomocou algoritmu *fcm* a pracuje s mamdaniho modelom. Identifikácia pri 14 pravidlách je v porovnaní s *genfis1* pri 13 pravidlách lepšia.

Zistilo sa, že identifikácia modelu sa dá zlepšovať zvyšovaním počtu funkcií príslušnosti, čím sa zvýši počet pravidiel.

LITERATÚRA

- [1] BAKOŠOVÁ, M. a kol.: Základy automatizácie. Laboratórne cvičenie zo základov automatizácie. Vydavateľstvo STU, Bratislava 2003
- [2] JURA, P.: Základy fuzzy logiky pro řízení a modelování. Brno: VUTIUM, 2003.
- [3] KOLESÁROVÁ, A., KOVÁČOVÁ, M.: Fuzzy množiny a ich aplikácie. Bratislava: Vydavateľstvo STU, 2004.
- [4] MIKLEŠ, J., DOSTÁL, P., MÉSZÁROS, A.: Riadenie technologických procesov. Vydavateľstvo STU, Bratislava 1994
- [5] MIKLEŠ, J., FIKAR, M.: Modelovanie, identifikácia a riadenie procesov 2, STU Press, Bratislava, 2004.
- [6] MÉSZÁROS, A. a kol.: Základy automatizácie. Vydavateľstvo STU, Bratislava 1997
- [7] NOVÁK, V.: Základy fuzzy modelování, Ostrava: BEN, ISBN 80-7300- 009-1, 2000
- [8] VASIČKANINOVÁ A., BAKOŠOVÁ, M., DVORAN J.: Tvorba neuro – fuzzy modelov metódou Anfis, AT&P journal 11/2006
- [9] VYSOKÝ, P.: Fuzzy řízení, ČVUT Praha, 1996

PRÍLOHY

Príloha č.1: Výsledná fis matica pre 3 Gaussovske pravidlá

[System]

Name='fism2'

Type='sugeno'

Version=2.0

NumInputs=1

NumOutputs=1

NumRules=3

AndMethod='prod'

OrMethod='max'

ImpMethod='prod'

AggMethod='max'

DefuzzMethod='wtaver'

[Input1]

Name='input1'

Range=[0 100]

NumMFs=3

MF1='in1mf1':'gaussmf',[21.23 -0.0063]

MF2='in1mf2':'gaussmf',[21.24 49.98]

MF3='in1mf3':'gaussmf',[21.23 99.99]

[Output1]

Name='output'

Range=[1.08 1.50]

NumMFs=3

MF1='out1mf1':'linear',[0.019 1.076]

MF2='out1mf2':'linear',[0.0044 1.22]

MF3='out1mf3':'linear',[0.0030 1.17]

[Rules]

1, 1 (1) : 1

2, 2 (1) : 1

3, 3 (1) : 1

Príloha č.2: Výsledná fis matica pre 13 Gaussovských pravidiel

[System]

Name='fism2'

Type='sugeno'

Version=2.0

NumInputs=1

NumOutputs=1

NumRules=13

AndMethod='prod'

OrMethod='max'

ImpMethod='prod'

AggMethod='max'

DefuzzMethod='wtaver'

[Input1]

Name='input1'

Range=[0 100]

NumMFs=13

MF1='in1mf1': 'gaussmf', [3.53 -0.0080]

MF2='in1mf2': 'gaussmf', [3.54 8.32]

MF3='in1mf3': 'gaussmf', [3.54 16.66]

MF4='in1mf4': 'gaussmf', [3.54 25.002]

MF5='in1mf5': 'gaussmf', [3.54 33.33]

MF6='in1mf6': 'gaussmf', [3.53 41.67]

MF7='in1mf7': 'gaussmf', [3.53 50.004]

MF8='in1mf8': 'gaussmf', [3.53 58.33]

MF9='in1mf9': 'gaussmf', [3.53 66.66]

MF10='in1mf10': 'gaussmf', [3.53 74.99]

MF11='in1mf11': 'gaussmf', [3.53 83.33]

MF12='in1mf12': 'gaussmf', [3.53 91.66]

MF13='in1mf13': 'gaussmf', [3.53 99.99]

[Output1]

Name='output'

Range=[1.086 1.50]

NumMFs=13

MF1='out1mf1': 'linear', [0.0004 1.105]

MF2='out1mf2': 'linear', [0.012 1.14]

MF3='out1mf3': 'linear', [0.0089 1.23]

MF4='out1mf4': 'linear', [0.0073 1.26]

MF5='out1mf5': 'linear', [0.0065 1.24]

MF6='out1mf6': 'linear', [0.0040 1.30]

MF7='out1mf7': 'linear', [0.0027 1.34]

MF8='out1mf8': 'linear', [0.0006 1.44]

MF9='out1mf9': 'linear', [-0.0014 1.58]

MF10='out1mf10': 'linear', [-0.0028 1.69]

MF11='out1mf11': 'linear', [-0.0029 1.72]

MF12='out1mf12': 'linear', [-0.0002 1.51]

MF13='out1mf13': 'linear', [-0.0013 1.61]

[Rules]

1, 1 (1) : 1

2, 2 (1) : 1

3, 3 (1) : 1

4, 4 (1) : 1

5, 5 (1) : 1

6, 6 (1) : 1

7, 7 (1) : 1

8, 8 (1) : 1

9, 9 (1) : 1

10, 10 (1) : 1

11, 11 (1) : 1

```
12, 12 (1) : 1
13, 13 (1) : 1
```

Príloha č.3: Program anfh.m pre výpočet fis matice pomocou funkcie *genfis1*

```
load h3s.dat -ascii
t=h3s(:,1);h=h3s(:,2);
x=[t ];y=h;

trnData = [x y];
numMFs =13;  mfType ='gbellmf'; %See also evalmf, gauss2mf, gaussmf, gbellmf,
mf2mf, pimf, psigmf, sigmf,
                        %smf, trapmf, trimf, zmf.
epoch_n =1;
in_fismat = genfis1(trnData,numMFs,mfType);
writefis(in_fismat,'fism1');%type fis3.fis;
a=readfis('fism1');
    plotmf(a,'input', 1),pause
    out_fismat = anfis(trnData,in_fismat,3);
    writefis(out_fismat,'fism2');
    a=readfis('fism2');
    ytz=evalfis(x,out_fismat);
    plot(t,y,t,ytz),pause
    legend('h3 namerane','h3 navrhnuté z ANFISu '),pause
    fismat1=readfis('fism2');
    type fism2.fis
    ruleview('fism2'),pause
```

Príloha č.4: Program anfgn2.m pre výpočet fis matice pomocou funkcie *genfis2*

```
load h3.dat -ascii
t=h3(:,1);h=h3(:,2);
x=[t ];y=h;
trnData = [x y];
in_fismat =genfis2(x,y,0.6)
    writefis(in_fismat,'clusterin.fis');
type clusterin.fis
    out_fismat = anfis(trnData,in_fismat,1)
    ew1=evalfis(x,in_fismat);
    plot(t,y,t,ew1), legend('nelineárny model','Takagi-Sugenov model, subtraktívne
zhlukovanie ')
    xlabel('t [min]'),ylabel('h_3 [m]')
    fis1=readfis('clusterin.fis');
    ruleview('clusterin')
```

Príloha č.5: Program idegen3.m pre výpočet fis matice pomocou funkcie *genfis3*

```
load h3.dat -ascii
load q1.dat -ascii
t=h3(:,1);h=h3(:,2);h2=h3(:,3);
q=q1(:,2)
x=[t h2];y=h;
x=[h];y=h
trnData = [x y];

[C]=subclust(trnData,0.005);U=initfcm(46, y);
[c,U,obj]=fcm(trnData,46);
in_fismat =genfis3(x,y,'mamdani',14,[3.9,500,0,0]);
writefis(in_fismat,'fcmmin.fis');
type fcmmin.fis
ew1=evalfis(x,in_fismat);
plot(t,y,t,ew1); legend('Training Data','fcmmamdani')
fis1=readfis('fcmmin.fis');
```

Príloha č.6: S-funkcia, opisujúca zásobníky

```
function [sys,x0,str,ts] = fero(t,x,u,flag)
```

```
switch flag,
```

```
case 0
```

```
    [sys,x0,str,ts] = mdlInitializeSizes;
```

```
case 1
```

```
    sys = mdlDerivatives(t,x,u);
```

```
case 3
```

```
    sys = mdlOutputs(t,x,u);
```

```
case {2, 4, 9}
```

```
    sys = [];
```

```
otherwise
```

```
    error(['unhandled flag = ',num2str(flag)]);
```

```
end;
```

```
function [sys,x0,str,ts] = mdlInitializeSizes % inicializacia: do tejto funkcie vkladame
```

```
vlastne udaje
```

```
sizes = simsizes;
```

```
sizes.NumContStates = 3; % pocet spojitych stavov
```

```
sizes.NumDiscStates = 0; % pocet diskretnych stavov
```

```
sizes.NumOutputs = 1; % pocet vystupov
```

```
sizes.NumInputs = 3; % pocet vstupov
```

```
sizes.DirFeedthrough = 0; % = 0 v pripade, ze v rovniciach vystupu nevystupuje u alebo  
nevystupuje matica D. Inak =1.
```

```
sizes.NumSampleTimes = 1; % 1 pre spojite systemy
```

```
sys = simsizes(sizes);
```

```
h1s=1.3889;
```

```
h2s=0.6944;
```

```
h3s=1.0851;
```

```
x0=[h1s h2s h3s]; % zaciatočne podmienky pre dif. rovnice
```

```
str = []; % str je prazdna matica
```

```


ts = [0 0]; %% velkost perody vzorkovania, pre spojite systemy =[0 0]
function sys = mdlDerivatives(t,x,u) % vypocet derivaci: do tejto funkcie vkladame
vlastne udaje - rovnice dynamiky
k11=1.2;
k22=1.2;
k33=1.2;
F1=2;
F2=2;
F3=2;
q01=1;
q02=0;
q03=0.25;
sys(1)=(u(01)-k11*sqrt(x(1)-x(2)))/F1;
sys(2)=(u(02)+k11*sqrt(x(1)-x(2))-k22*sqrt(x(2)))/F2;
sys(3)=(u(03)+k22*sqrt(x(2))-k33*sqrt(x(3)))/F3;

function sys = mdlOutputs(t,x,u) % vypocet vystupov: do tejto funkcie vkladame
vlastne udaje - rovnice vystupu

sys(1) =x(3)+0.05*rand;


```

Príloha č.7: Zvonové funkcie príslušnosti použité pri tvorbe modelu typu Mamdani pre vstupnú a výstupnú veličinu




Obrázok 22: Zvonové funkcie príslušnosti použité pri tvorbe modelu typu Mamdani pre vstupnú a výstupnú veličinu

Príloha č.8: Zvonové a lichobežníkové funkcie príslušnosti použité pri tvorbe modelu typu Mamdani pre vstupnú a výstupnú veličinu




Obrázok 23: Zvonové funkcie príslušnosti

Na obrázku 23 sú znázornené zvonové funkcie príslušnosti a na obrázku 24 je priebeh nameranej výšky hladiny v porovnaní s modelom typu Takagi-Sugeno so zvonovými funkciami príslušnosti pre vstupnú veličinu, m-file je súčasťou prílohy. Obrázky porovnávajú presnosť modelov pre rôzny počet funkcií príslušnosti, v tomto prípade 3 a 13.




Obrázok 24: Priebeh nameranej výšky hladiny a výšky hladiny po identifikácii.



Obrázok 25: Lichobežníkové funkcie príslušnosti

Na obrázku 25 sú znázornené lichobežníkové funkcie príslušnosti a na obrázku 26 je priebeh nameranej výšky hladiny v porovnaní s modelom typu Takagi-Sugeno s lichobežníkovými funkciami príslušnosti pre vstupnú veličinu, m-file je súčasťou prílohy. Obrázky porovnávajú presnosť modelov pre rôzny počet funkcií príslušnosti, v tomto prípade 3 a 13.



Obrázok 26: Priebeh nameranej výšky hladiny a výšky hladiny po identifikácii.

Príloha č.9: Schémy





Schéma č.1: Schéma zásobníkov kapaliny



Príloha č.2: Schéma pre porovnanie nelineárneho a linearizovaného modelu zásobníkov kapaliny