

SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE

FAKULTA CHEMICKEJ A POTRAVINÁRSKEJ TECHNOLOGIE

ÚSTAV INFORMATIZÁCIE, AUTOMATIZÁCIE A MATEMATIKY

Radlinského 9, 812 37 Bratislava

ODDELENIE INFORMATIZÁCIE A RIADENIA PROCESOV

Bc. Anikó Szűcssová

DIPLOMOVÁ PRÁCA

ADAPTÍVNY NEURO-FUZZY INFERENČNÝ SYSTÉM (ANFIS)

Vedúci diplomovej práce

Ing. Vasičkaninová Anna

Bratislava
2007

Vyhlasenie:

Vyhlasujem, že som diplomovú prácu vypracovala samostatne podľa pokynov vedúcej diplomovej práce, použitím literatúry, ktorú uvádzam v osobitnom zozname.

V Bratislave dňa 14.05.2007

.....

Pod'akovanie :

Chcem sa poďakovať vedúcej diplomovej práce Ing. Anne Vasičkaninovej za jej odborné rady a pripomienky.

ABSTRAKT

Diplomová práca sa zaoberá návrhom neuro-fuzzy regulátora na riadenie etážovej rektifikačnej kolóny v užívateľskom prostredí Matlab Fuzzy Logic. Ako základný prostriedok slúži algoritmus zvaný Anfis, ktorý na výpočet parametrov fuzzy inferenčného systému využíva hybridné učenie pomocou metódy najmenších štvorcov a metódy spätného šírenia. Súčasťou diplomovej práce je matematický opis rektifikačnej kolóny a návrh riadenia kolóny PID-regulátormi, navrhnutými vybranými experimentálnymi metódami. Riadenie týmito regulátormi je porovnané s riadením s navrhnutými neuro-fuzzy regulátormi na základe integrálnych kritérií kvality. Práca obsahuje aj stručný návod na výpočet fuzzy regulátora v grafickom užívateľskom rozhraní.

ABSTRACT

Presented diploma thesis deals with the design of neuro-fuzzy logic controller to a binary distillation column within Matlab's Fuzzy Logic Toolbox. The major routine is executed with so called Anfis algorithm which employs hybrid learning strategy to identify parameters of Sugeno-type fuzzy inference systems using the combination of the least-squares method and the backpropagation gradient descent method. The diploma thesis contains also the mathematic description of the process and designing control of column with PID controllers, designed with exempted experimental methods. Control of column with these controllers is compared with designed neuro-fuzzy controllers on base the integral criteria of quality. A graphic user interface calculations are performed to simplify the presentation.

OBSAH

ÚVOD	1
1. Teoretická časť	3
1.1 Úvod	3
1.1.1 Problémy klasického riadenia.....	3
1.1.2 História vývoja fuzzy logiky pre regulátory.....	4
1.1.3 Základné pojmy	4
1.1.4 Základy fuzzy logiky	8
1.1.5 Operácie s fuzzy množinami	10
1.1.6 Charakteristické vlastnosti fuzzy systémov	11
1.1.7 Fuzzy regulátory	11
1.1.8 Syntéza fuzzy regulátora.....	14
1.2 Fuzzy logic toolbox	16
1.2.1 Implementácia fuzzy logiky a riadenia v Simulinku	16
1.3 Anfis a jeho vlastnosti	17
1.3.1 Anfis	17
1.3.2 Obmedzenia Anfisu	20
1.3.3 Interaktívne grafické prostredie editoru Anfis	20
1.4 Neurónové siete	23
2. Experimentálna časť	28
2.1 Rektifikačná kolóna	28
2.1.1 Matematický model etážovej rektifikačnej kolóny	28
2.1.2 Parametre etážovej rektifikačnej kolóny	33
2.1.3 Simulácia dynamických vlastností rektifikačnej kolóny	34
2.2 Riadenie rektifikačnej kolóny	36
2.2.1 Identifikácia rektifikačnej kolóny a návrh regulátora na riadenie.	36
2.2.2 Posúdenie kvality riadenia rektifikačnej kolóny	42
2.2.3 Riadenie rektifikačnej kolóny neuro-fuzzy regulátorom	44
2.2.4 Grafické zobrazenie riadenia rektifikačnej	46
2.2.5 Použitie metódy subtraktívneho zhlukovania vstupných dát	48
2.2.6 Porovnanie výsledkov simulácie riadenia rektifikačnej kolóny	52
 ZÁVER	 55
Literatúra	58
Prílohy	59

Úvod

Človek sa málokedy stretáva s presne definovanými pojmami. Ľudstvo sa od počiatku snaží veci a vzťahy okolo seba spresňovať a vyjasňovať celkový obraz o svete, v ktorom žije, stále bolo vzhľadom na úroveň svojho poznania a techniky konfrontované s neschopnosťou plniť túto úlohu na 100%. Stále sú mnohé otázky, na ktoré nestačia odpovede „áno“ a „nie“. Nepresnosť, nejasnosť, neurčitosť či vágnosť odpovedá anglickému slovu „fuzzy“.

Táto diplomová práca sa zaoberá využitím štruktúry Anfis pri návrhu fuzzy regulátora na riadenie rektifikačnej kolóny.

Teória fuzzy množiny sa práve snaží riešiť jeden z najzákladnejších problémov vedy, vzťah medzi presnosťou a nepresnosťou. Je to disciplína, ktorá sa počas svojej štyridsať ročnej existencie zaslúžila o riešenie mnohých technických problémov, ktoré v praxi bolo možné riešiť iba čiastočne alebo vôbec nie. Osvedčila sa v mnohých aplikáciách v oblasti riadenia. Je to matematicky snád' najlepšie spracovaná časť prostriedkov umelej inteligencie, pomocou ktorej môžeme simulovať veľkú časť procesov ľudského uvažovania.

Podľa klasickej teórie je možné úspešne riadiť, keď poznáme matematický model procesu. Keď proces je opísaný pomocou lineárnych diferenciálnych rovníc s konštantnými koeficientmi, máme k dispozícii rôzne experimentálne metódy pre návrh účinných regulátorov. U reálnych procesov často býva veľmi obtiažne nájsť ich matematický opis. Výsledný opis môže byť natoľko zložitý, že je takmer nemožné navrhnuť pre neho klasický regulátor. V praxi takéto procesy spravidla reguluje človek, podľa svojich skúseností bez toho, aby poznal presný matematický opis systému. V takýchto situáciách sa používajú fuzzy regulátory. Ak je človek schopný popísať svoju činnosť pri riadení procesu, tak aj fuzzy regulácia má prostriedky, na základe ktorých sa dá riadenie procesu uskutočniť.

Neuro-fuzzy systém Anfis svojou činnosťou zodpovedá Takagi-Sugeno-Kangovmu fuzzy regulátoru. Vnútorne je stavaný ako päťvrstvová dopredná neurónová sieť, ktorej učenie je založené na minimalizácii odchýlok metódou najmenších štvorcov a dopredného šírenia. Parametre sú uložené v uzloch neurónovej siete, preto sa hovorí o adaptívnej neurónovej sieti.

Práca je rozdelená na Teoretickú časť a Experimentálnu časť.

Teoretická časť :

- kapitola *Úvod* sa zaoberá stručným opisom histórie a vývoja fuzzy logiky. Zavádzajú sa pojmy využívané v ďalších kapitolách a základné operácie s fuzzy množinami.
- kapitola *Fuzzy logic toolbox* je jednoduchým manuálom k práci s Fuzzy logic toolboxom v prostredí Matlab, ktorý poskytuje nástroje pre vytváranie, vizualizáciu a simuláciu rôznych fuzzy regulátorov.
- kapitola *Anfis a jeho vlastnosti* sa zaoberá samotnou štruktúrou a princípom ako Anfis pracuje.
- kapitola *Neurónové siete* obsahuje stručný opis pojmov a základné rozdelenia neurónových sietí.

Experimentálna časť :

- kapitola *Rektifikačná kolóna* obsahuje matematický model kolóny, jeho ustálený stav a dynamické vlastnosti.
- kapitola *Riadenie rektifikačnej kolóny* opisuje samotný návrh parametrov neuro-fuzzy regulátora, testuje rôzne navrhnuté regulátory na riadenie zloženia destilátu a teploty pár na hlave etážovej rektifikačnej kolóny.

1. Teoretická časť

1.1 Úvod

V posledných rokoch sa v praxi často môžeme stretnúť pri riadení s princípmi a prístupmi, ktoré sú založené na pomerne mladej vednej disciplíne „Soft – Computing“. Táto disciplína je symbiózou rôznych výpočtových postupov, ktorých spoločným menovateľom je odklon od klasického modelovania založeného na booleovskej logike, analytických modeloch a ostrej klasifikácii. Medzi hlavných zástupcov Soft-Computingu zahrňujeme fuzzy logiku, neurónové siete a genetické algoritmy.

Klasická dvojhodnotová logika naráža na problémy, známe ako logické paradoxy, ktoré nemožno riešiť iba pomocou kategórii platí – neplatí. Ako príklad sa uvádza [6]:

„Jeden klamár z Kréty prehlásil, že všetci Kréťania sú klamári.“ - ak je pravda, že všetci Kréťania sú klamári, tak tento výrok je nepravdivý. Veď ho povedal Kréťan a ten predsa klame. Pre bežného človeka to nie sú paradoxy.

V 20-tych až 30-tych rokoch 20. stor. poľský matematik Lukasiewicz prišiel s myšlienkou zaviesť viachodnotovú logiku a vypracoval dokonca aparát pre nekonečný počet logických hodnôt ako logiku L_{∞} . Hodnoty 0 (neplatí) a 1 (platí) boli krajnými hodnotami tohto systému.

1.1.1 Problémy klasického riadenia

Návrh parametrov klasických regulátorov reálnych systémov naráža na rôzne problémy:

- ❖ nelinearita,
- ❖ obmedzenia riadiacich veličín,
- ❖ požiadavky na riadenie napr. nulový prechod,
- ❖ parametre systému nie sú presne známe, alebo veľmi obtiažne merateľné,
- ❖ veľká citlivosť na zmeny parametrov vstupných veličín,
- ❖ diskretizácia,
- ❖ nestacionárne systémy – meniace sa parametre,
- ❖ matematický model nepostihuje všetky dôležité vzťahy alebo je drasticky zjednodušený.

1.1.2 História vývoja fuzzy logiky pre regulátory

- 1973 Zadeh – navrhol použitie fuzzy logiky v riadení.
- 1975 Mamdani – navrhol prvý fuzzy regulátor parného stroja.
- 1982 Holmblad – navrhol fuzzy regulátor cementárrenskej pece – problém veľa premenných, nelinearita systému.
- 1985 Sugeno – prototypy ďalších priemyselných aplikácií.
- 1987 Yasunobo – fuzzy regulátor metra v Sendai.

Odvtedy nastal veľký „boom“ fuzzy riadených systémov hlavne v Japonsku: výroba práčok, vysávačov, kamier a veľa inej užitočnej „inteligentnej“ techniky.

1.1.3 Základné pojmy

Lukasiewicz zaviedol do logiky viachodnotovosť, filozof Max Black v 1937 definoval pojem vágnych množín a L. Zadeh v 1965 publikoval článok s názvom: „Fuzzy sets“ čím vlastne položil základy teórie fuzzy množín.

V tejto práci nie je možné podať úplný popis teórie fuzzy množín a fuzzy regulátorov, ktorá sa rozrástla na samostatnú matematickú disciplínu, ale je potrebné popísať základy tejto teórie, ktoré sú potrebné na jej využitie v technickej praxi pri riadení procesov.


Fuzzy množiny možno považovať za prostriedky, ktoré umožňujú matematicky popísať nepresné pojmy a pracovať s nimi. Je to vlastne matematický zápis nepresnosti ako sprievodné javu všetkých zložitých sústav, ktoré nie je možné presne matematicky popísať, prípadne kde presný matematický popis je veľmi zložitý, alebo nadobúda určitý väčší význam ľudský faktor [11].

Definícia 1.1.1: U budeme nazývať **univerzom**, ak U je ľubovoľná množina prvkov $x \in U$.

Definícia 1.1.2: Funkcia $\mu_A(x)$, ktorá každému prvku z množiny U priradí číslo z intervalu $<0,1>$, sa nazýva **funkciou príslušnosti** (membership function – MF), ktorá definuje množinu A na univerze U .

Funkcie príslušnosti môžu mať rôzny tvar. Z hľadiska výpočtu sa najčastejšie volí čo najjednoduchší tvar, kedy sú tieto funkcie zložené z lineárnych úsekov.

Najčastejšie používané tvary funkcií príslušnosti lichobežníková a zvonovitá sú znázornené na obrázku 1.1.



Obrázok 1.1 Najčastejšie používané tvary MF: lichobežníková a zvonovitá.

Definícia 1.1.3: Stupňom príslušnosti prvku x do fuzzy množiny A budeme nazývať hodnotu funkcie príslušnosti $\mu_A(x) \in <0,1>$, ktorú fuzzy množina A priradí prvku $x \in U$.

Definícia 1.1.4: Fuzzy množinou budeme nazývať usporiadanú dvojicu $A = \{x, \mu(x)\}$, kde všetky $x \in U$.

Pre každú takto definovanú fuzzy množinu je možné určiť základné vlastnosti [6]:

Nosič fuzzy množiny (support) je ostrá množina, pre jej prvky platí, že ich hodnoty funkcie príslušnosti sú rôzne od nuly,

$$\text{supp } A = \{ x \in U, \mu_A(x) > 0 \}.$$

Výška fuzzy množiny (height) je najmenšia horná hranica fuzzy množiny A,

$$\text{hght}(A) = \sup_{x \in U} \mu_A(x),$$

kde sup znamená supremum.

Normálna (normal) fuzzy množina je fuzzy množina s výškou 1,

$$\exists x \in U, \mu_A(x) = 1.$$

Prázdna (empty) fuzzy množina je fuzzy množina, u ktorej funkcia príslušnosti pre všetky prvky má hodnotu 0,

$$\forall x \in U, \mu_A(x) = 0.$$

Jadro (kernel) fuzzy množiny je ostrá množina pre ktorej prvky platí, že ich hodnoty funkcií príslušnosti sú rovné jednej,

$$\text{kerr } A = \{ x, \mu_A(x) = 1 \}.$$

Fuzzy jednotka (singleton) je fuzzy množina s jedným prvkom,

$$A = \{ x/1 \}.$$

α -rez (α -cut) je ostrá množina, pre ktorej prvky platí, že ich hodnoty funkcií príslušnosti sú väčšie alebo rovné α .

$$A_\alpha = \{ x \in U, \mu_A(x) \geq \alpha \}.$$


α -hladina (α -level) je ostrá množina, pre ktorej prvky platí, že ich hodnoty funkcií príslušnosti sú práve rovné α .

$$A^\alpha = \{ x \in U, \mu_A(x) = \alpha \}.$$

Skalárna kardinalita (scalar cardinality) fuzzy množiny je súčet hodnôt funkcií príslušností pre všetky prvky danej množiny.

$$|A| = \sum_{x \in U} \mu_A(x).$$

Grafické znázornenie základných vlastností fuzzy množiny je na obr.1.2.




Obrázok 1.2 Grafické znázornenie základných vlastností fuzzy množiny.

Ostrá množina - charakteristická funkcia každého prvku nadobúda hodnoty len 1 alebo len 0.

Neostrá (fuzzy) množina - charakteristická funkcia nadobúda hodnoty od 0 do 1.

Lingvistická premenná – na rozdiel od číselnej premennej, **lingvistická premenná** používa ako hodnoty nie čísla, ale slovné výrazy. Hodnotu lingvistickej premennej môžeme interpretovať ako fuzzy – neostre množiny. Obrázok 1.3 je zobrazením príkladu lingvistickej premennej.



Obrázok 1.3 Príklad lingvistickej premennej *Vek človeka*.

Pojem „*Vek človeka*“ predstavuje názov tejto lingvistickej premennej, označovaný ako Γ , ktorý charakterizuje spoločný rys takto definovanej fuzzy množiny. Vystupuje tu symbolická úroveň vo forme slovných hodnôt *mladý*, *stredne starý* a *starý*, ktoré spolu tvoria tzv. *term množinu T*. Priradenie jednotlivých funkcií príslušnosti, ktoré sú číselnými kvantifikáciami jednotlivých pojmov nad univerzom U (napr. množina prirodzených čísel), k samotným prvkom term množiny je vykonané pomocou sémantických pravidiel M , čím sa im priradí ich význam. Pre úplnosť definície lingvistickej premennej treba dodať, že sa ešte definujú aj syntaktické pravidlá G , pomocou ktorých je možné konštruovať slovné hodnoty (napr. *stredne starý* z pojmov *starý* a *stredný*), takže vo všeobecnosti je možné lingvistické premenné definovať ako usporiadanú päťicu: $LP = (\Gamma, T, U, G, M)$, kde:

Γ je názov premennej,

T je množina hodnôt,

U univerzum, na ktorom sú definované jednotlivé hodnoty,

G syntaktické pravidlo na generovanie hodnôt,

M sémantické pravidlo na definovanie súhlasu hodnôt s ich významom.

1.1.4 Základy fuzzy logiky

Prepojenie fuzzy množín s matematickou logikou umožní ich využiť pri tvorbe technických systémov. Zatiaľ najúspešnejšie sa javí rozšírenie konceptu *fuzzy expertného systému* pôvodne založeného na dvojhodnotovej logike, známeho viac ako **fuzzy regulátor**, ktorý bol prvý krát použitý pri riadení parného stroja.

Myšlienka je veľmi jednoduchá. Expertný systém založený na produkčných pravidlách typu *AK <predpoklad> POTOM <záver>* bol rozšírený využitím fuzzy množín na popis neurčitých slovných výrazov. Rozšírené produkčné pravidlo môže mať tvar fuzzy pravidla o dvoch vstupoch a jednom výstupe:

$$AK \quad x \text{ je } A \& y \text{ je } B \quad POTOM \quad u \text{ je } C, \quad (1.1)$$

kde x , y , u sú prvkami troch rôznych univerz X , Y a U . V prípade rektifikačnej kolóny vstupmi môžu byť napr. regulačný odchýlka a jej derivácia podľa času, výstupom zase zloženie destilátu. Proces vyhodnotenia jedného pravidla (1.1) je možné rozdeliť na tri fázy:

1. výpočet kompatibility,
2. agregácia čiastkových predpokladov (vstupov),
3. samotná inferencia pravidiel.

V prvej fáze sa vypočíta, do akej miery je splnené tvrdenie x je A (y je B). V konvenčnom expertnom systéme by výsledkom bola 0 alebo 1 , neplatí alebo platí. Fuzzy systém však vie jemnejšie posúdiť mieru platnosti, a to v rozsahu $[0; 1]$. Na výpočet sa využíva niektorý z operátorov realizujúcich prienik dvoch fuzzy množín, t.j. A a B .

Všetky vstupy je potom potrebné spojiť do celkového vstupu (predpokladu), čo je úlohou druhej fázy. Výsledkom tohto spojenia je vlastne miera splnenia predpokladovej časti pravidla. Operátor výpočtu závisí od logickej spojky, v našom prípade $\&$, ktorej odpovedá v množinovej matematike operácia prieniku.

V tretej fáze by klasická inferencia (odvodzovanie) rozhodovala iba dvojhodnotovo. Ak by predpoklad nebol splnený, potom by bol aj záver neplatný. V prípade úplného splnenia predpokladu by bol záver prijatý bezo zmien. V prípade fuzzy systému sú to krajné stavy. Je dosť logické predpokladať, že čím je miera splnenia predpokladu vyššia, tým sa výsledný záver bude viac podobáť na záver v pravidle (1.1) a čím bude miera splnenie menšia, tým sa aj záver bude viac podobáť prázdnej množine. Pre tento účel sa používajú operátory inferencie. Výsledkom teda bude fuzzy množina C' , tvarovo „niekde“ medzi prázdnu množinou a pôvodnou množinou C v pravidle (1.1).

Skutočný systém spravidla obsahuje niekoľko pravidiel (rádovo desiatky až niekoľko stoviek). Na záver preto vyvstáva úloha spojiť závery C_i' jednotlivých pravidiel ($i=1, \dots, n$), každé vyhodnotené v spomenutých fázach zvlášť, do výsledného záveru. Táto úloha preto pokračuje spoločnou fázou *akumulácie*, ktorej realizácia je závislá od použitej spojky, ktorou sú pravidlá navzájom pospájané (väčšinou logickým súčtom). Tento prístup umožňuje zahrnúť aj čiastočne protirečivé pravidlá.

Na základe uvedeného je zrejmé, že fuzzy logika ako aparát jednoznačne patrí do oblasti umelej inteligencie. Matematicky modeluje spôsob vnímania a uvažovania človeka, využíva reprezentáciu znalostí typickú pre človeka a najmä pristupuje k riešeniu danej úlohy spôsobom, akým by ju riešil samotný človek, čiže nezostáva iba na úrovni riešenia úloh typických iba pre človeka, ale navyše si osvojuje jeho spôsoby práce.

Rozšíreniu fuzzy systémov veľmi napomáha reprezentácia znalostí, ktorú využívajú. Pre človeka je prirodzené si vytvárať pravidlá, zisťovať stav a na základe takých pravidiel sa rozhodovať pre akciu. V automatizácii sa z veľmi nezrozumiteľného a ťažkopádneho popisu pomocou diferenciálnych rovníc dalo prejsť do popisu priamo vyhovujúcemu človeku. Skrátila sa doba návrhu regulátorov a v mnohých prípadoch je to jediná možnosť, ako daný proces zautomatizovať.

1.1.5 Operácie s fuzzy množinami

Fuzzy množiny sa dajú pokladať za zovšeobecnenie klasických ostrých množín. Fuzzy logika používa rozšírené funkcie operátorov (AND, OR, NOT) z dvojhodnotovej logiky pre viachodnotovú, fuzzy – logiku.

- ❖ Fuzzy komplement, doplnok množiny A, $C = \text{NOT } A$.

$$\mu_C(x) = 1 - \mu_A(x) \quad (1.2)$$


- ❖ Fuzzy prienik množín (logický súčin) $C = A \text{ AND } B$.

$$\mu_C(x) = \mu_{A \wedge B}(x) = \min\{\mu_A(x), \mu_B(x)\} \quad (1.3)$$

- ❖ Fuzzy zjednotenie množín (logický súčet) $C = A \text{ OR } B$.

$$\mu_C(x) = \mu_{A \vee B}(x) = \max\{\mu_A(x), \mu_B(x)\} \quad (1.4)$$

Grafické porovnanie operácií na klasických a fuzzy množinách je na obrázku 1.4.



Obrázok 1.4 Grafické porovnanie operácií na klasických a fuzzy množinách.

1.1.6 Charakteristické vlastnosti fuzzy systémov

Na základe vyhodnotenia úspešnosti aplikácií fuzzy logiky a ich porovnania s inými prístupmi je možné ako všeobecné vyzdvihnúť nasledujúce vlastnosti fuzzy systémov (okrem práce s neurčitou a nepresnou informáciou):

- Ľahká zrozumiteľnosť, najmä reprezentácia znalostí.
- Jednoduchší návrh.
- Modulárnosť riešenia – je možné pridávať a odstraňovať jednotlivé moduly bez nutnosti úplne prepracovať celý systém, napr. pravidlá v báze znalostí.
- Paralelizmus vo výpočtoch, t.j. možnosť paralelne vyhodnocovať jednotlivé pravidlá.
- Robustnosť návrhu, t.j. systém nie je nutné upravovať v prípade zmeny parametrov riešenej úlohy v rámci istého okolia.

1.1.7 Fuzzy regulátory


O fuzzy regulátoroch je možné tvrdiť, že sú univerzálnymi aproximátormi ľubovoľnej spojitkej funkcie. Jazykové fuzzy regulátory sú fuzzy systémy s bázou znalostí, ktoré pomocou fuzzifikácie, vhodného spôsobu odvodzovanie záverov a defuzzifikácie priradujú hodnotám veličín sledovaných na vstupe hodnoty veličín sledovaných na výstupe. Z matematického hľadiska vytvárajú funkcie aproximujúce neznáme závislosti medzi sledovanými výstupnými a vstupnými veličinami.

Charakteristickým znakom fuzzy riadenia je možnosť bezprostredného použitia empirických znalostí človeka – operátora o procese, ktoré sú označené ako báza znalostí. Bázu znalostí tvoria:

- ❖ informácie o stacionárnych stavoch, intervaloch, v ktorých sa pohybujú hodnoty vstupných a výstupných veličín, atď. Všetky tieto informácie o procese na báze znalostí sa označujú ako báza dát.
- ❖ kvantitatívne formulované skúsenosti a slovne definované stratégie riadenia, pomocou ktorých je možné realizovať riadenie. Z týchto skúseností získané stratégie riadenia sa označujú ako báza pravidiel.

Základná bloková schéma fuzzy regulátora s regulovanou sústavou pre dva vstupy a jeden

výstup je na obrázku 1.5. Jeho ústredný člen tvoria 3 základné bloky: fuzzifikácia, inferencia a blok defuzzifikácia.



Obrázok 1.5 Štruktúra fuzzy regulátora s regulovanou sústavou pre 2 vstupy a 1 výstup.

Blok fuzzifikácie - Fuzzifikácia predstavuje prvý krok v realizácii fuzzy regulátora. Na prácu s pravidlovým systémom založeným na jazykových premenných je potrebné previesť kvantitatívne vyjadrené hodnoty z technológie na kvalitatívne (jazykové) premenné s ich hodnotami. V tomto bloku sa počítajú jednotlivé stupne príslušností pre každú hodnotu jazykovej premennej. Mapuje sa tu ostrá hodnota vstupu do rozsahu (0,1) pre každú jazykovú hodnotu. Taktiež, ak je to nutné, prevádza sa v tomto bloku normalizácia vstupných hodnôt. Normalizácia v tomto prípade znamená prevod ešte „ostrých“ hodnôt z technologického procesu, ktoré bývajú často v rozsahu definovanom rôznymi typmi snímačov (napr. 0 až 10 V) na rozsah univerz, s ktorými pracuje fuzzy regulátor. Najčastejšie sú všetky univerzá v rozsahu (-1,1), aby bolo možné bez ďalších problémov použiť rôzne typy fuzzy množín, implikácií a algoritmov učenia napr. pri spojení s neurónovými sieťami.

Blok bázy znalostí - Blok bázy znalostí býva rozdelený na viacero menších celkov:

báza dát, kde sú uložené tvary a počty funkcií príslušností vstupných a výstupných premenných. Často sa sem zahrňujú aj definície operátorov, implikácie, kompozície a defuzzifikácie.

báza pravidiel, kde sú uložené jednotlivé pravidlá v tvare fuzzy implikácie. Všetky pravidlá sú spojené pomocou agregácie (zjednotenia) do jedného zloženého fuzzy výroku popisujúceho stratégiu riadenia fuzzy regulátora.

Blok inferenčného mechanizmu - Tu prebieha samotný mechanizmus vyhodnotenia jednotlivých pravidiel v závislosti od definovaného typu logických operácií v báze dát. Spadá sem vyhodnotenie antecedentu (predpokladu), implikácie a konzekventu (dôsledku). Výstupom z inferenčného mechanizmu býva fuzzy množina zjednotená z fuzzy výstupných množín jednotlivých pravidiel, ktorá nám slovne popisuje akčný zásah z fuzzy regulátora.

Blok defuzzifikácie - Prevedie výstupnú jazykovú hodnotu, ktorá vznikla kompozíciou výstupov z jednotlivých pravidiel na „ostrú“ hodnotu, ktorá vstupuje do technologického procesu v podobe akčného zásahu. Existuje viacero spôsobov ako získať z celkovej fuzzy plochy „ostrú“ hodnotu, ktoré sa líšia prístupom k samotnému výpočtu. Všetky vychádzajú z vyjadrenia celkovej výstupnej fuzzy plochy pomocou analytického výrazu.

Typy fuzzy regulátorov sú nasledovné:

❖ konvenčné regulátory:

- Mamdaniho regulátor: napríklad fuzzy P, PI, PID regulátory a regulátory pre kľzavú reguláciu. Typické pravidlo používané v modeli má tvar:

Ak **e** je **A** a **de** je **B** potom **z** je **C**.

Aj vstupy, aj výstup sú opísané pomocou fuzzy množín. Model typu Mamdani bol prvýkrát použitý v aplikácii riadenia parného motora v kombinácii s kotlom pomocou pravidiel vyprodukovaných skúseným ľudským operátorom.

- Takagi-Sugeno-Kangov regulátor (TSK): nelineárny TSK regulátor a lineárny TSK regulátor s premenlivými parametrami. Typické pravidlo používané v modeli má tvar:

Ak **e** je **A** a **de** je **B** potom **z** je **f(x,y)**.

Vstupy sú opísané pomocou fuzzy množín, výstup je ostrá množina. Model typu Sugeno bol navrhnutý Takagim, Sugenom a Kangom ako výsledok snahy o vytvorenie systematického prístupu na generovanie fuzzy pravidiel zo vstupno – výstupných údajov.

❖ Adaptívny fuzzy regulátor:

- samo nastaviteľný regulátor
- samo organizačný regulátor.

- ❖ Špeciálne fuzzy regulátory: nepatria ani do jednej z predchádzajúcich tried, napríklad Mac Vicar-Whelanov regulátor.

1.1.8 Syntéza fuzzy regulátora

Pod syntézou fuzzy regulátora rozumieme jeho navrhovanie pre konkrétny riadený systém, pričom môžeme samotné navrhovanie rozdeliť na viacero fáz [11]:

- stanovenie počtu, tvaru a rozloženia fuzzy množín,
- stanovenie pravidiel,
- stanovenie inferenčného mechanizmu,
- stanovenie metódy defuzzifikácie.

Stanovenie počtu, tvaru a rozloženia fuzzy množín.

Prvou dôležitou otázkou je určenie počtu fuzzy množín. Keďže fuzzy logika vychádza z ľudského pozorovania procesu, nemá zmysel použiť veľké množstvo funkcií príslušností (jazykových hodnôt) pre jednu jazykovú premennú. Človek dokáže určiť len obmedzené množstvo úrovní jeho jednotlivých zmyslov a preto sa počet funkcií volí obvykle z intervalu 3-7 (9). Tvar funkcií príslušností je závislý od predpokladaného využitia fuzzy regulátora. V praxi sa najčastejšie stretáme s „zvonovitou“ a „lichobežníkovou“ funkciou [6]. Okrem nich sa môžeme stretnúť s „gausovou“ funkciou príslušnosti a s jej modifikovanými tvarmi. Tvar funkcií závisí aj od dynamiky systému s fuzzy regulátorom, ktorú potrebujeme dosiahnuť. Napr. pre rýchle fuzzy regulátory býva často použitý tvar monotónnej funkcie príslušnosti, ktorá má zanedbateľný čas výpočtu. Samotný tvar funkcií príslušností, rovnako ako počet, sa stanovuje buď apriori (intuitívne), alebo je možné použiť matematické analýzy zo zameraných dát, ktoré vstupujú do fuzzy regulátora. V druhom prípade je počet funkcií príslušností vyšší a záleží na vstupných dátach. Príkladom je tzv. zhluková analýza „fuzzy C-means“. Pre fuzzy množiny platí, že musia pokryť celé univerzá jednotlivých jazykových premenných. To znamená, že ani jeden bod univerza nesmie mať stupeň príslušnosti rovný nule. Najčastejšie však táto podmienka býva ešte prísnejšia. Pri nej žiadny bod univerza nesmie mať stupeň príslušnosti menší ako zvolené číslo, často v rozsahu (0.3-0.5). Pri splnení takejto podmienky existuje vždy aspoň jedno dominantné pravidlo, ktorého existencia má vplyv na správnu funkčnosť fuzzy regulátora.

Stanovenie pravidiel.

Ak máme určený počet funkcií príslušnosti (počet hodnôt jazykových premenných), môžeme považovať všetky ich kombinácie za stavový priestor regulátora. Každý bunke stavového priestoru (jednej kombinácii vstupov) potom potrebujeme určiť pravidlo, podľa ktorého sa má fuzzy regulátor pre daný stav správať. Ak máme teda napr. 2 vstupy a jeden výstup, pričom každý zo vstupov a rovnako aj výstup má 3 jazykové hodnoty (funkcie príslušností), potom je stavový priestor regulátora rozdelený na $3 \times 3 = 27$ buniek a potrebujeme najviac 27 pravidiel (stávajú sa prípady, keď je pravidiel menej). Pravidlá získame najčastejšie pomocou konzultácie s operátorom, ktorý má na starosti riadenie danej technológie. Využívajú sa pritom rôzne metódy získavania informácií, napr. pozorovaním jeho činnosti. Pri pozorovaní sú využívané aj metódy „identifikácie“ pravidiel pomocou neurónových sietí (napr. ANFIS).

Stanovenie inferenčného mechanizmu.

Stanovenie inferenčného mechanizmu znamená určenie typu T-normy, T-konormy a implikácie, ktoré je nutné určiť pre vyhodnocovanie pravidiel. Ich výber je často intuitívny. Ak je možnosť vykonať simulácie systému s fuzzy regulátorom, tak je často inferenčný mechanizmus vybraný metódou pokus - omyl až po dosiahnutie požadovaných vlastností fuzzy regulátora.

Stanovenie metódy defuzzifikácie.


Posledným problémom je určenie metódy defuzzifikácie. Tu sa taktiež používajú rôzne heuristické prístupy a zatiaľ neexistuje jednotný postup pre určenie toho – ktorého typu defuzzifikácie pre danú aplikačnú oblasť.

1.2 Fuzzy logic toolbox

Návrh fuzzy regulátorov v prostredí programovacieho jazyka Matlab – Simulink sa robí pomocou programu Fuzzy Logic Toolbox. Simulačné výpočty vrátane aj reálnych meraní sa uskutočňujú v časti Simulink.

1.2.1 Implementácia fuzzy logiky a riadenia v Simulinku

Na riadenie, meranie a simuláciu sa používa Simulink, ktorý pri aktivácii Fuzzy Logic Toolboxu obsahuje v menu Fuzzy Logic Toolboxu fuzzy regulátor:



Obrázok 1.6 Fuzzy logic regulátor v Simulinku.

Základnú štruktúru fuzzy regulátora, ktorú tvoria bloky fuzzifikácia, defuzzifikácia a inferencia, zastupuje v Simulinku blok „Fuzzy logic controller“.

Pri klasickej implementácii regulátorov typu PID sa najprv volí jeho štruktúra (P, PI, PD, PID) a potom nasleduje návrh jeho parametrov. Regulátor typu PID len vyhodnocuje a spracováva informácie o regulačnej odchýlke. Výsledkom tohto procesu je výstupná veličina z regulátoru $u(t)$. Fuzzy regulátor využíva ďalšie možné informácie o procese (báza pravidiel a dát) vrátane informácii a skúsenosti obsluhy. Obsahom návrhu fuzzy regulátoru je takto získať informácie a využiť ich v rámci návrhu fuzzy regulátora.

Návrh štruktúry fuzzy regulátora je možné urobiť vlastným návrhom pomocou interaktívneho grafického prostredia programu Matlab-Simulink alebo regulátor sa môže navrhnuť pomocou súboru údajov (ak sú k dispozícii) s využitím štruktúry Anfis.

1.3 Anfis a jeho vlastnosti

1.3.1 Anfis

Anfis je päťvrstvová dopredná neurónová sieť, ktorej výsledkom je fuzzy inferenčný systém typu Takagi-Sugeno [12]. Anfis na určenie parametrov funkcií príslušnosti – na tréovanie neurónovej siete – používa kombináciu metódy najmenších štvorcov a metódy spätného šírenia. Prostredníctvom týchto dvoch metód je Anfis schopný natréovať doprednú neurónovú sieť, čím zjednodušuje prácu pri tvorbe jednotlivých modelov. Využíva schopnosť hybridného určenia algoritmov k identifikácii parametrov funkcií príslušnosti jednoduchého výstupu, ako je Sugenov typ fuzzy systémov. Ide o prepis fuzzy regulátora do doprednej neurónovej siete. Pri učení takejto siete dochádza aj k zmenám parametrov samotného fuzzy regulátora. Po naučení siete je možné tieto parametre spätne získať, alebo použiť takúto naučenú sieť priamo na riadenie.

Postup výpočtu metódou ANFIS v Matlabe [12]:

1. Inicializácia fuzzy systému: príkazy *genfis1* alebo *genfis2*.
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.

Opis použitých príkazov na identifikáciu parametrov fuzzy regulátora [13]:

ANFIS - Adaptívny neuro-fuzzy inferenčný systém.

Najjednoduchší príkaz v Matlabe na generovanie výsledného fuzzy inferenčného systému je v tvare `FIS= Anfis(TRNDATA)`. `Trndata` je matica vstupných a výstupných údajov z referenčného systému, kde prvé `N` stĺpce matice obsahujú vstupné údaje (napr. `e`, `de` z riadenia systému klasickým regulátorom) a posledný stĺpec matice obsahuje výstupné dáta (napr. `u` z riadenia klasickým regulátorom). Pri použití tejto formy príkazu ostatné možnosti nastavení Anfisu Matlab použije predvolené hodnoty a metódy.

Najjednoduchší hore uvedený príkaz sa dá rozšíriť do rôznych foriem, napríklad:

$$FIS = Anfis(TRNDATA,INITFIS,TRNOPT,DISPOPT,CHKDATA,OPTMETHOD)$$

Opis Trndata je uvedený hore, ostatné možnosti nastavení sú:

- **INITFIS**: štartovanie učenia neurónovej siete. Bez zadania Initfis, Matlab použije možnosť Genfis1 s počtom funkcií príslušnosti 2, typu funkcií príslušnosti GBELLMF a výstupnú funkciu príslušnosti typu LINEAR. Opis možností zadania príkazu Genfis1 a Genfis2 sú uvedené nižšie.

- **TRNOPT**: vektor na špecifikáciu nastavení tréovania:

- **TRNOPT(1)**: počet tréovacích iterácií. Nastavená hodnota je 10.
- **TRNOPT(2)**: miera chýb tréovania s nastavenou hodnotou 0.
- **TRNOPT(3)**: veľkosť počiatočného kroku tréovania s hodnotou 0.01.
- **TRNOPT(4)**: miera zníženia veľkosti kroku s nastavenou hodnotou 0.9.
- **TRNOPT(5)**: miera zvýšenia veľkosti kroku, štandardne 1.1.

Proces tréovania neurónovej siete sa zastaví v momente, keď sa dosiahne určený počet iterácie alebo miera tolerancie tréovania siete.

- **DISPOPT**: umožňuje zobrazit' nastavenia počas tréovania siete. Hodnota 1 funkcie Disopt zobrazuje, hodnota 0 ukryje informácie:

- **DISPOPT(1)**: všeobecné informácie Anfisu.
- **DISPOPT(2)**: chyba.
- **DISPOPT(3)**: veľkosť kroku každého aktualizovaného parametra.
- **DISPOPT(4)**: konečný výsledok.

Štandardne všetky možnosti Disoptu sú nastavené na hodnotu 1.

- **CHKDATA**: kontrola dát na zabránenie preučeniu – pretrénovaniu siete. Dochádza k nemu, keď generovaný fuzzy inferenčný systém síce veľmi dobre popisuje tréovacie údaje, ale jeho odozva na nové pojmy je veľmi zlá. **CHKDATA** má štruktúru ako funkcia **TRNDATA**. Preučenie je zistené, keď kontrolná chyba začína stúpať pokiaľ tréovacia tolerancia stále klesá.

- **OPTMETHOD**: vyberá optimalizačné metódy používané počas trénovania siete. Voľba 1 použije predvolenú hybridnú metódu, čo je kombinácia metódy najmenších štvorcov a metódy spätného šírenia. Voľba 0 použije len metódu spätného šírenia chýb.

Možnosti nastavenia INITFIS, iniciácie fuzzy systému:

- **GENFIS1** generuje východiskový (počiatočný) fuzzy inferenčný systém (FIS) Sugenovského typu na trénovanie neurónovej siete použitím mriežkového rozkladu (bez zhlukovania) vstupných dát. Najjednoduchší príkaz na jeho použitie je:

$$INITFIS = Genfis1(DATA).$$

DATA má štruktúru aj funkciu ako *TRNDATA*. Štandardne *Genfis1* používa dve funkcie príslušnosti typu *GBELLMF* na každý vstup. Každé pravidlo generované s *Genfis1* má jednu výstupnú funkciu príslušnosti, ktorá je typu *LINEAR*.

Ak sa rozhodneme zmeniť preddefinované voľby typu a počtu funkcií príslušnosti, použijeme príkaz vo forme:

$$FIS = Genfis1(DATA, NUMMFS, INPUTMF, OUTPUTMF),$$

kde špecifikujeme:

- **NUMMFS** : počet funkcií príslušnosti každého vstupu v rozmedzí (2 až 9).
- **INPUTMF** : typ funkcií príslušnosti každého vstupu (trimf, trapmf, gbellmf, gaussmf, gauss2mf, dsigmf, psigmf, pimf).
- **OUTPUTMF** : typ výstupnej funkcie príslušnosti *LINEAR* alebo *CONSTANT*.

- **GENFIS2** generuje fuzzy inferenčný systém (FIS) Sugenovského typu použitím metódy subtraktívneho zhlukovania vstupných údajov pomocou funkcie *SUBCLUST* na predpokladanie počtu funkcií príslušnosti a určenie pravidiel.

Príkaz na použitie *Genfis2* v Matlabe má tvar:

$$INITFIS = Genfis2(XIN, XOUT, RADII),$$

vytvára fuzzy inferenčný systém Sugenovho typu z daných vstupných údajov XIN a výstupných údajov $XOUT$. Matice Xin a $Xout$ majú po jednom stĺpci pre FIS vstup a výstup. $RADII$ špecifikuje hranice, dosah vplyvu centra zhluku pre vstup a výstup, za predpokladu úbytku údajov v medziach $(0,1)$. Špecifikovanie malého okruhu zhluku bude (samozrejme) poskytovať viac malých zhlukov údajov, viac pravidiel. Ak $RADII$ je skalárna veličina, tá bude aplikovaná na všetky vstupné a výstupné dimenzie. Ak $RADII$ je vektor, každý člen bude mať patričný vstup a výstup.

Operácia *SUBCLUST* na hľadanie optimálnych bodov dát na určenie centier zhlukov je založená na skúmaní hustoty okolitých bodov dát. Všetky ostatné dáta, ktoré nie sú centrami zhluku vo vnútri rozpätia $RADII$ budú použité na príkaz určovanie nasledujúceho zhluku dát a jeho centra. Tento proces je opakovaný až kým každý údaj nebude vo vnútri rozpätia $RADII$ centra niektorého zhluku.


1.3.2 Obmedzenia Anfisu

Anfis podporuje len sugenovské systémy, ktoré majú nasledovné vlastnosti:

- ❖ sugenovský systém má byť nultého alebo prvého poriadku,
- ❖ má jeden výstup. Všetky funkcie príslušnosti výstupu musia byť rovnakého typu a tiež lineárne alebo konštantné.
- ❖ počet funkcií príslušnosti výstupu sa rovná počtu pravidiel,
- ❖ všetky pravidlá sú rovnako závažné.

1.3.3 Interaktívne grafické prostredie editoru Anfis

Práca s interaktívnym grafickým prostredím sa začína v príkazovom riadku programu Matlab - Simulink napísaním príkazu: `anfisedit`. Otvorí sa okno na obrázku 1.7.




Obrázok 1.7 Interaktívne grafické okno editoru Anfis.

Možnosti nastavenia okna sú nasledovné:

- ❖ **Load data:** načítanie údajov na tréningovanie, testovanie a overenie Anfisu. Načítané dáta sú znázornené na grafe.
- ❖ **Generate FIS:** generovanie vstupného FIS modelu alebo načítanie vstupného FIS modelu. Voľba Grid partition – mriežkové rozdelenie vstupných dát (Genfis1), kým voľba Subtractive clustering – subtraktívne zhlukovanie vstupných dát (Genfis2).
- ❖ Nastaviť metódu hybridnú alebo metódu spätného šírenia.
- ❖ Voľba hodnoty tolerancie.
- ❖ Voľba počtu iterácie.
- ❖ **Train now:** tréningovanie nastavuje parametre funkcií príslušnosti.
- ❖ **Test now:** testuje a vykreslí dáta a FIS výstup do grafického pola.

Výsledná anfis štruktúra pre systém s dvomi vstupmi a jedným výstupom je na obrázku 1.8.



Obrázok 1.8 Výsledná anfis štruktúra.

Vrstva 1 – adaptívne uzly, ich prenosové funkcie zodpovedajú funkciám príslušnosti daných lingvistických hodnôt.

Vrstva 2 - neadaptívne uzly, ktoré násobia vstupné signály a výstupu tak poskytujú váhu pravidiel.

Vrstva 3 - neadaptívne uzly, ktoré na výstupe poskytujú pomer váh jednotlivých pravidiel ku súčtu váh všetkých pravidiel.

Vrstva 4 - neadaptívne uzly. Ich prenosová funkcia je daná požadovaným tvarom u z rovnice (1.1). Tvar môže byť lineárny alebo konštantný.

Vrstva 5 - neadaptívny uzol. Počíta celkový výstup ako súčet všetkých vstupných signálov.

1.4 Neurónové siete

Vzhľadom na to, že Anfis je päťvrstvová dopredná neurónová sieť, je potrebné uviesť úvod do dnes intenzívne rozvíjajúcej sa oblasti neurónových sietí. Je tu zhrnutá len tá najzákladnejšia teória neurónových sietí týkajúca sa ich štruktúry a algoritmov učenia.

Podľa [14] je neurónová sieť masívny paralelný procesor, ktorý má schopnosť pamätať si znalosti získané experimentálne a tieto znalosti ďalej využívať. Charakteristickou črtou neurónovej siete je jej štruktúra tvorená jednotlivými neurónmi pospájanými synaptickými prepojeniami. Nad takto vytvorenou štruktúrou môžeme postaviť viacero algoritmov učenia. Tieto algoritmy potom nastavujú parametre (váhy) jednotlivých synaptických prepojení, pokiaľ nie je zaručená správna funkčnosť neurónovej siete.


Samotnú činnosť neurónovej siete môžeme rozdeliť na dve fázy:

fáza učenia, kedy sa znalosti uchovávajú v podobe nastavovania váh synaptických prepojení.

fáza života, kedy sa získané vedomosti využívajú na činnosť, pre ktorú bola neurónová sieť

konštruovaná, napr. v riadení, rozpoznávaní písma a podobne.

Ako bolo spomenuté, základným prvkom neurónovej siete je neurón, ktorý pozostáva z nasledujúcich častí [14] (viď. obr. 1.9):



Obrázok 1.9 Štruktúra neurónu.

Vstup do neurónu je funkciou jednotlivých prichádzajúcich vstupov a predstavuje najčastejšie súčet všetkých vstupov do neurónu, kde w_{ij} sú synaptické váhy, ou_j sú výstupy predošlých neurónov a θ je prah neurónu (hodnota, ktorá prispieva ku vstupom do neurónu).


Aktivačná funkcia neurónu, ktorej výsledkom je stav neurónu popísaný: $x_i = f(in_i)$. Funkcia f nazývaná aj aktivačná funkcia má rôzne formy. Medzi tie najčastejšie patria lineárna, signum, po častiach lineárna a sigmoidálna funkcia [14].

Výstupná funkcia, ktorej výstup je celkovým výstupom z neurónu má tvar: $ou_i = f(x_i)$.

Jednotlivé neuróny sú pospájané prepojeniami, ktoré spolu s neurónmi môžu vytvoriť ľubovoľnú štruktúru (topológiu). Podľa topológie rozlišujeme aj najzákladnejšie typy NS:

a) Dopredné NS, kde sa signál šíri len dopredu (jedným smerom).

b) Rekurentné NS, kde sa signál šíri v oboch smeroch.



Obrázok 1.10 Typy topológie NS

Rovnako môžeme neurónové siete rozdeliť podľa typov učiacich algoritmov. Rozoznávame dve skupiny algoritmov [14]:

a) Učenie kontrolované – s učiteľom

V tomto prípade v procese učenia sú ponúknuté vstupy do neurónovej siete a k nim prislúchajúce výstupy. Podľa následného spracovania týchto dát môžeme potom kontrolované učenie rozdeliť na:

- Učenie na základe opravy chyby.
- Učenie stochastické.
- Učenie s hodnotením činnosti (reinforcement učenie).

b) Učenie nekontrolované – bez učiteľa

V tomto prípade sú v procese učenia ponúknuté vstupy do neurónovej siete, ktorá ich sama spracuje a určí výstup.

Spojenie fuzzy systému s neurónovými sieťami môžeme rozdeliť do viacerých skupín podľa prepojenia s neurónovými sieťami, podľa algoritmov učenia alebo časovej charakteristiky učenia.

Podľa topológie:

- *kooperatívny systém*, v ktorom sú neurónová sieť a fuzzy regulátor oddelené a pracujú nezávisle od seba.
- *hybridný systém*, v ktorom sú neurónová sieť a fuzzy regulátor spojené do jedného celku. Tu je fuzzy systém definovaný ako špeciálna neurónová sieť. Nevýhodou hybridného systému je fakt, že fuzzy - neurónová sieť je špeciálna sieť, ktorá má svoje obmedzenia (problém derivovania funkcií v neuróne, nemožnosť použitia ľubovoľného učiaceho algoritmu). Je potrebné použiť konkrétny druh fuzzy regulátora a špeciálne typy neurónov v sieti. Výhodou je jednoduchosť a rýchlosť.

Podľa cieľov učenia (ladenia fuzzy regulátora):


- učenie pravidiel,
- učenie parametrov funkcií príslušností,
- kombinácia predošlých.

Typu učenia:

- *off-line* učenie, v ktorom sa parametre fuzzy regulátora získavajú po nameraní vstupno-výstupných dát a ich použití v učiacom algoritme,
- *on-line* učenie, v ktorom sa parametre fuzzy regulátora získavajú priebežne pomocou nameraných dát pri bežiacom regulačnom procese.

Metódy učenia:


- učenie s učiteľom na základe korekcie chyby, najčastejšie to býva učenie so spätným šírením chyby (back propagation) a jeho obmeny,
- reinforcement učenie.




Obrázok 1.11 Hybridné systémy

- a, on-line učenie hybridného systém založené na základe spätného šírenia chyby
 b, on-line učenie hybridného systém na základe hodnotenia činnosti


U Anfis-u, ako hybridného neuro-fuzzy systému, pri učení doprednej neurónovej siete dochádza aj k zmenám parametrov samotného fuzzy regulátora. Po naučení siete je možné tieto parameter spätne získať, alebo použiť naučenú sieť priamo na riadenie.



Obrázok 1.12 Prepis nenalađeného fuzzy regulátora do neurónovej siete.



Obrázok 1.13 Trénovanie neuro-fuzzy.



Obrázok 1.14 Spätný prepis neurónovej siete do fuzzy regulátora.

2. Experimentálna časť

2.1 Rektifikačná kolóna


V rektifikačných kolónach prebiehajú procesy s prestupom látky, ktoré sú pre chemický priemysel veľmi dôležité. Rektifikácia je proces delenia binárnej zmesi, založený na rôznych parciálnych tlakoch zložiek tvoriacich zmes [9].

Riadenie rektifikačných kolón prináša so sebou veľa zložitých problémov. Etážové rektifikačné kolóny majú veľké časové konštanty, takže ich dynamická odozva je pomalá. Medzi veličinami charakterizujúcimi kolónu sú silné interakcie a v kolónach sa často vyskytujú nemerateľné poruchové veličiny. Kolóna, riadená v tejto diplomovej práci delí binárnu zmes metanol-voda, má jediný vstup (nástrek) a výstup len z varáka (zvyšok) a zásobníka kondenzátu (destilát). Kvapalina, ktorá steká kolónou (spätný tok), vchádza do varáka, kde sa spája s kvapalnou zádržou varáka. Vo varáku prebieha odparovanie a pary idú do kolóny. Pary z hlavy kolóny kondenzujú a dopĺňajú zádrž kvapaliny v zásobníku kondenzátu. Časť kondenzátu sa vracia späť do kolóny ako vonkajší spätný tok.

Postup hľadania vhodných parametrov regulátora nám umožňuje syntéza riadiaceho systému, ktorou hľadáme štruktúru regulátora a parametre, aby sme zabezpečili nielen stabilitu ale aj požadovanú kvalitu uzavretého systému. Cieľom riadenia kolóny je dosiahnutie požadovaného výstupného zloženia reakčnej zmesi pri daných parametroch kolóny.

2.1.1 Matematický model etážovej rektifikačnej kolóny

Za účelom kvantitatívneho vyjadrovania vlastností procesov sa využívajú matematické opisy. Tieto opisy nazývame matematické modely. Matematický model je matematickou abstrakciou reálneho procesu. Poskytuje možnosť určiť výstupy procesu, ak sú známe vstupy. Matematický model môže byť použitý pri riadení spojitých technologických celkov, pri skúmaní dynamických vlastností procesov, pri optimálnom návrhu procesov a pri určení optimálnych prevádzkových podmienok procesu.



Obrázok 2.1 Schéma etážovej rektifikačnej kolóny.

V 6-etážovej rektifikačnej kolóne sa delí kvapalná binárna zmes metanol – voda. V prichádzajúcom nástreku F je mólový zlomok metanolu x_F . Na každej etáži dochádza k prestupu látky, pričom parná fáza G sa obohacuje o prchavejšiu zložku ako postupuje pozdĺž kolóny. Mólový zlomok metanolu v parnej fáze na i -tej etáži je y_i . V kvapalnej fáze sa hromadí menej prchavá zložka.

Ak rektifikačná kolóna pracuje v rovnovážnom stave, musia byť toky látkových množstiev F , D , W , L a G v rovnováhe. Pri zachovaní celkovej látkovej bilancie kolóny platí, že súčet toku látkového množstva destilátu a zvyšku dáva tok látkového množstva nástreku.

$$F = D + W$$

$$G = L + D$$

Zároveň musí byť zachovaná celková látková bilancia kondenzátora, v ktorej platí, že súčet toku látkového množstva destilátu a spätného toku dáva tok látkového množstva parnej fázy.

Rektifikačná kolóna patrí k najzložitejším systémom v chemickej technológii, preto boli pri odvodení matematického modelu použité nasledovné zjednodušenia [2]:

- ❖ kvapalná fáza sa na etážach, v zásobníku kondenzátu aj vo varáku dokonale mieša,
- ❖ k výmene látky dochádza len na etážach,
- ❖ kolóna je tepelne izolovaná,
- ❖ straty tepla do okolia a teplotné zmeny pozdĺž kolóny sú zanedbateľné,
- ❖ zádrže parnej fázy na etážach sú zanedbateľné,
- ❖ zádrže kvapaliny na etážach a vo varáku sa časom nemenia,
- ❖ nástrek sa privádza kvapalný v konštantnom množstve a na bode varu,
- ❖ prietok kvapalnej fázy pozdĺž kolóny je konštantný a stabilizovaný,
- ❖ tlak je pozdĺž kolóny konštantný,
- ❖ pary odchádzajú z hlavy kolóny sa v kondenzátore úplne kondenzujú,
- ❖ para odchádzajúca z teoretickej etáže je v rovnováhe s kvapalinou na etáži a táto závislosť je opísaná rovnovážnou krivkou:


$$y_e^* = f_{\text{nel}}(x_e) = (a + c * x_e + e * x_e^2) / (1 + b * x_e + d * x_e^2) \quad (2.1)$$

kde index e znamená e=0 pre varák a e=1,.....,6 pre etáže,

- ❖ sú definované Murphreeho účinnosti etáží v parnej fáze:


$$\eta_e = (y_e - y_{e-1}) / (y_e^* - y_{e-1}) \quad (2.2)$$

čitateľ zlomku reprezentuje skutočné obohatenie sa parnej fázy a menovateľ teoretické obohatenie sa parnej fázy o prchavejšiu zložku.



Obrázok 2.2 Rovnovážny x-y diagram.

Body na obrázku 2.2 reprezentujú dvojice rovnovážnych hodnôt z tabuliek.



Obrázok 2.3 Rovnovážny y-t diagram.

Body reprezentujú dvojice rovnovážnych hodnôt y-t z tabuliek. Závislosť teploty t od zloženia parnej fázy y popisuje polynomickeá funkcia:

$$t[^\circ\text{C}] = a + b \cdot y + c \cdot y^2 + d \cdot y^3, \quad (2.3)$$

konštanty pre tepelnú rovnovážnu krivku sú:

$$a=99.944373, b=-23.707679, c=-11.7484, d=-0.2125127.$$

V dynamickom stave je rektifikačná kolóna opísaná sústavou nelineárnych diferenciálnych rovníc 1.-ho rádu, ktoré majú nasledovný tvar:

- Varák: $y_0^*(t) = f_{nel}(x_0(t)) \quad (2.4)$

$$y_0(t) = \eta_0 y_0^*(t) \quad (2.5)$$

$$\frac{d[H_0 x_0(t)]}{dt} = (L + F)x_1(t) - G \cdot y_0(t) - W \cdot x_0(t) \quad (2.6)$$

- 1. etáž (ochudobňovacia časť kolóny)

$$y_1^*(t) = f_{nel}(x_1(t)) \quad (2.7)$$

$$y_1(t) = \eta_0 y_1^*(t) + (1 - \eta_e) y_0(t) \quad (2.8)$$

$$\frac{d[H_1 x_1(t)]}{dt} = G \cdot y_0(t) + (L + F)x_2(t) - G \cdot y_1(t) - (L + F)x_1(t) \quad (2.9)$$

- 2.etáž (ochudobňovacia časť kolóny)

$$y_2^*(t) = f_{nel}(x_2(t)) \quad (2.10)$$

$$y_2(t) = \eta_0 y_2^*(t) + (1 - \eta_e) y_1(t) \quad (2.11)$$

$$\frac{d[H_2 x_2(t)]}{dt} = G \cdot y_1(t) + (L + F) x_3(t) - G \cdot y_2(t) - (L + F) x_2(t) \quad (2.12)$$

- 3. etáž (ochudobňovacia časť kolóny)

$$y_3^*(t) = f_{nel}(x_3(t)) \quad (2.13)$$

$$y_3(t) = \eta_0 y_3^*(t) + (1 - \eta_e) y_2(t) \quad (2.14)$$

$$\frac{d[H_3 x_3(t)]}{dt} = G \cdot y_2(t) + (L + F) x_4(t) - G \cdot y_3(t) - (L + F) x_3(t) \quad (2.15)$$

- 4.etáž (nástreková)

$$y_4^*(t) = f_{nel}(x_4(t)) \quad (2.16)$$

$$y_4(t) = \eta_0 y_4^*(t) + (1 - \eta_e) y_3(t) \quad (2.17)$$

$$\frac{d[H_4 x_4(t)]}{dt} = F \cdot x_4(t) + G \cdot y_3(t) + L \cdot x_5(t) - G \cdot y_4(t) - (L + F) x_4(t) \quad (2.18)$$

- 5.etáž (obohacovacia časť kolóny)

$$y_5^*(t) = f_{nel}(x_5(t)) \quad (2.19)$$

$$y_5(t) = \eta_0 y_5^*(t) + (1 - \eta_e) y_4(t) \quad (2.20)$$

$$\frac{d[H_5 x_5(t)]}{dt} = G \cdot y_4(t) + L \cdot x_6(t) - G \cdot y_5(t) - L \cdot x_5(t) \quad (2.21)$$

- 6.etáž (obohacovacia časť kolóny)

$$y_6^*(t) = f_{nel}(x_6(t)) \quad (2.22)$$

$$y_6(t) = \eta_0 y_6^*(t) + (1 - \eta_e) y_5(t) \quad (2.23)$$

$$\frac{d[H_6 x_6(t)]}{dt} = G \cdot y_5(t) + L \cdot x_D(t) - G \cdot y_6(t) - L \cdot x_6(t) \quad (2.24)$$

- kondenzátor :

$$\frac{d[H_7 x_D(t)]}{dt} = G \cdot y_6(t) - (L + D) \cdot x_D(t) \quad (2.25)$$

kde:

H_0 - mólová zádrž kvapaliny vo varáku [mol]

H_i - mólová zádrž kvapaliny na etážach ($i=1,\dots,6$) [mol]

L - mólový prietok spätného toku [mol/min]

F - mólový prietok nástreku [mol/min]

G - mólový prietok parnej fázy kolónou [mol/min]

W - mólový prietok zvyšku [mol/min]

D - mólový prietok destilátu [mol/min]

x_i - mólový zlomok prchavejšej zložky v parnej fáze na i -tej etáži [-]

y_i - mólový zlomok prchavejšej zložky v kvapalnej fáze na i -tej etáži [-]

x_D - mólový zlomok prchavejšej zložky v destiláte [-]

x_W - mólový zlomok prchavejšej zložky vo zvyšku [-]

x_F - mólový zlomok prchavejšej zložky v nástreku [-]

η_e - účinnosť etáže [-]

η_0 - účinnosť varáka [-].

2.1.2 Parametre etážovej rektifikačnej kolóny

Pri výpočtoch sa použili nasledovné údaje [10]:

$H_0 = 1262,6$ mol,

$H_1 = H_2 = H_3 = H_4 = H_5 = H_6 = 1.699$ mol,

$\eta_e = 0.6$, $\eta_0 = 1$,

$x_F = 0.11$,

$F = 4.8107$ mol/min,

$D = 0.939$ mol/min,

$W = 3.8747$ mol/min,

$L = 1.699$ mol/min,

$G = 2.635$ mol/min.

Matematický model kolóny v ustálenom stave je opísaný týmito rovnicami:

- Pre varák:

$$0 = (L + F)x_1(t) - G.y_0(t) - W.x_0(t) \quad (2.26)$$

- Pre 1. etáž (ochudobňovacia časť kolóny)

$$0 = G.y_0(t) + (L + F)x_2(t) - G.y_1(t) - (L + F)x_1(t) \quad (2.27)$$

- Pre 2. etáž (ochudobňovacia časť kolóny)

$$0 = G.y_1(t) + (L + F)x_3(t) - G.y_2(t) - (L + F)x_2(t) \quad (2.28)$$

- Pre 3. etáž (ochudobňovacia časť kolóny)

$$0 = G.y_2(t) + (L + F)x_4(t) - G.y_3(t) - (L + F)x_3(t) \quad (2.29)$$

- Pre 4. etáž (nástreková)

$$0 = F.x_4(t) + G.y_3(t) + L.x_5(t) - G.y_4(t) - (L + F)x_4(t) \quad (2.30)$$

- Pre 5. etáž (obohacovacia časť kolóny)

$$0 = G.y_4(t) + L.x_6(t) - G.y_5(t) - L.x_5(t) \quad (2.31)$$


- Pre 6. etáž (obohacovacia časť kolóny)

$$0 = G.y_5(t) + L.x_D(t) - G.y_6(t) - L.x_6(t) \quad (2.32)$$

a rovnicami rovnovážnej krivky.


2.1.3 Simulácia dynamických vlastností rektifikačnej kolóny

Dynamické vlastnosti etážovej rektifikačnej kolóny boli sledované pomocou jej prechodovej charakteristiky. Výpočet začiatočných hodnôt potrebných na vytvorenie s-funkcií je uvedený v prílohe č.1 [10]. Na simuláciu prechodovej charakteristiky etážovej rektifikačnej kolóny v prostredí simulačného jazyka Matlab-Simulink bola použitá matlabovska s-funkcia, ktorá je uvedená v prílohe č.2 [10]. V prílohe č.3 je druhá s-funkcia na sledovanie teploty pár na hlave kolóny [10]. Obrázok 2.4 znázorňuje blokovú schému, ktorá bola použitá na simuláciu prechodovej charakteristiky na sledovanie odozvy zloženia destilátu. Bloková schéma simulácie prechodovej charakteristiky na sledovanie teploty pár na hlave kolóny je podobná ako uvedená schéma na obrázku 2.4, líši sa len s-funkciou.




Obrázok 2.4 Bloková schéma na simuláciu prechodovej charakteristiky.

Pre simuláciu bola zvolená vstupná veličina – mólový prietok spätného toku L . V prílohe č.2 a č.3 sú s-funkcie dynamického matematického modelu kolóny, v ktorých je vstupnou veličinou L . Pri skokovej zmene bola sledovaná odozva zloženia destilátu a teploty pár na hlave kolóny. Výsledkom simulácie prechodovej charakteristiky je grafická závislosť na obrázku 2.5 a 2.6 na skokovú zmenu vstupnej veličiny.




Obrázok 2.5 Prechodová charakteristika rektifikačnej kolóny.



Obrázok 2.6 Prechodová charakteristika rektifikačnej kolóny.

2.2 Riadenie rektifikačnej kolóny

Z možností riadenia etážovej rektifikačnej kolóny bolo vybrané riadenie zloženie destilátu a teplotu pár na hlave etážovej rektifikačnej kolóny. Riadiaca veličina je mólový prietok spätného toku. Príloha č.2 a č.3 obsahuje s-funkcie, príloha č.4 obsahuje program na návrh parametrov neuro-fuzzy regulátora pomocou štruktúry Anfis. Vstupné údaje na tréovanie neurónovej siete boli získané použitím klasického PID regulátora. Na obrázku 2.7 je jadro simulačnej schémy programu Matlab – Simulink na riadenie rektifikačnej kolóny neuro-fuzzy regulátorom s navrhnutými parametrami pomocou štruktúry Anfis.



Obrázok 2.7 Fuzzy regulátor s animovaním pravidiel.

2.2.1 Identifikácia rektifikačnej kolóny a návrh regulátora na riadenie

Identifikácia je experimentálne nájdenie statických a dynamických charakteristík rektifikačnej kolóny a ich vyhodnotenie. Poznanie statických a dynamických charakteristík kolóny je potrebné na návrh parametrov regulátora. Časový priebeh výstupnej veličiny, ktorý je odozvou na skokovú zmenu jednej zo vstupných veličín, voláme reálnou prechodovou charakteristikou. Identifikácia bola robená graficky použitím prechodových charakteristík na obrázkoch 2.5 a 2.6. Údaje získané z identifikácie sú v tabuľke č.1. a č.2.

Z	T_n	T_u	n
0.28	4.19	0.51	2

Tabuľka č.1 Údaje získané z identifikácie pre zloženie destilátu.

Z	T _n	T _u	n
-12.06	4.30	0.71	2

Tabuľka č.2 Údaje získané z identifikácie pre teplotu pár na hlave kolóny.

Z identifikácie sú určené konštanty: zosilnenie Z, doba nábehu T_n, doba priet'ahu T_u a rád sústavy n. Na základe vybraných experimentálnych metód boli určené hodnoty parametrov P, I a D, ktoré sú uvedené v tabuľke č.3 a č.4. Použité experimentálne metódy boli: Ziegler –Nicholsova metóda, Strejcova a Cohen – Coonova metóda.

	P	I	D
Ziegler – Nicholsova metóda	29.340	-	-
	26.400	1.698	-
	35.208	1.022	0.255
Strejcova metóda	3.571	-	-
	3.571	2.061	-
Cohen – Coonova metóda	30.531	-	-
	26.704	1.354	-
	40.014	1.194	0.184

Tabuľka č.3 Navrhnuté parametre regulátorov - zloženie destilátu.


	P	I	D
Ziegler – Nicholsova metóda	-0.502	-	-
	-0.452	1.342	-
	-0.602	1.420	0.355
Strejcova metóda	-0.082	-	-
	-0.082	2.109	-
Cohen – Coonova metóda	-0.529	-	-
	-0.458	1.760	-
	-0.692	1.653	0.350

Tabuľka č.4 Navrhnuté parametre regulátorov - teplota pár na hlave kolóny.


Simulačná schéma vytvorená pomocou programu Matlab – Simulink na riadenie rektifikačnej kolóny pomocou navrhnutých regulátorov je na obrázku 2.8 a 2.9.

V simulačnej schéme je zložený blok, ktorá umožňuje realizovať obmedzenie prietoku. Akčná veličina nemá nadobudnúť zápornú hodnotu, preto bolo treba určiť hranice mólového prietoku spätného toku. Platí zachovanie celkovej materiálovej bilancie kondenzátora: $G=L+D$. Ak by bolo odoberané maximálne množstvo destilátu, do kolóny by nevtekal žiadny spätný tok. Ak by sa neodoberal žiadny destilát, do kolóny by vtekal maximálny spätný tok. Mólový prietok spätného toku L sa môže pohybovať v rozmedzí $<0; 2.635>$ mol/min [10].

Zloženie destilátu a teplota pár na hlave rektifikačnej kolóny sa menia pri zmene akčnej veličiny L . Zmena spätného toku L v rozmedzí $<0; 2.635>$ mol/min spôsobuje zmenu zloženia destilátu v rozmedzí $<0.21; 0.84>$ a zmenu teploty pár na hlave rektifikačnej kolóny v rozmedzí $<71.6; 94.4>^{\circ}\text{C}$ [10]. Voľba žiadanej veličiny zloženia destilátu je 0.8 a teploty pár na hlave kolóny je jej ekvivalentná hodnota 73.4°C pri hodnote spätného toku 2.4 mol/min.




Obrázok 2.8 Simulačná schéma riadenia zloženia destilátu rektifikačnej kolóny.




Obrázok 2.9 Simulačná schéma riadenia teploty pár na hlave rektifikačnej kolóny.


Grafické zobrazenie simulácie riadenia rektifikačnej kolóny sú na obrázkoch 2.10 až 2.15.




Obrázok 2.10 Výsledky simulácie riadenia zloženia destilátu P-regulátorom s navrhnutými parametrami pomocou metódy Ziegler-Nicholsa, Strejca a Cohen-Coona.




Obrázok 2.11 Výsledky simulácie riadenia zloženia destilátu PI-regulátorom s navrhnutými parametrami pomocou metódy Ziegler-Nicholsa, Strejca a Cohen-Coona.




Obrázok 2.12 Výsledky simulácie riadenia zloženia destilátu PID-regulátorom s navrhnutými parametrami pomocou metódy Ziegler-Nicholsa a Cohen-Coona.



Obrázok 2.13 Výsledky simulácie riadenia teploty pár na hlave kolóny P-regulátorom s navrhnutými parametrami pomocou metódy Ziegler-Nicholsa, Strejca a Cohen-Coona.



Obrázok 2.14 Výsledky simulácie riadenia teploty pár na hlave kolóny PI-regulátorom s navrhnutými parametrami pomocou metódy Ziegler-Nicholsa, Strejca a Cohen-Coona.



Obrázok 2.15 Výsledky simulácie riadenia teploty pár na hlave kolóny PID-regulátorom s navrhnutými parametrami pomocou metódy Ziegler-Nicholsa a Cohen-Coona.

2.2.2 Posúdenie kvality riadenia rektifikačnej kolóny

Kvalita riadenia sa dá posúdiť pomocou ukazovateľov kvality. Použité ukazovatele kvality:

- ❖ doba regulácie – čas, za ktorý sa riadená veličina dostane do okolia žiadanej veličiny a zostáva v ňom.
- ❖ regulačná odchýlka – rozdiel medzi $y_{\text{žiadaná}}$ a y_{∞} .
- ❖ integrálne kritéria kvality :
 - pre absolútnu hodnotu regulačnej plochy

$$I_{IAE} = \int_0^{t_{\text{reg}}} |w - y| dt \quad (2.33)$$

- pre kvadratickú regulačnú plochu

$$I_{ISE} = \int_0^{t_{\text{reg}}} (w - y)^2 dt \quad (2.34)$$

Hodnoty okolia žiadanej veličiny boli vybraté: 0.005 pre zloženie destilátu a 0.200°C pre teplotu pár na hlave kolóny. Kvalita riadenia rektifikačnej kolóny podľa predchádzajúcich kritérií pomocou navrhnutých regulátorov je v tabuľke č.5. a č.6.

		t_{reg} [min]	Regulač. odch. [-]	I_{IAE} [-]	I_{ISE} [-]
Ziegler – Nicholsova metóda	P	7.30	0.016	0.5588	0.0841
	PI	21.07	-	1.0184	0.1005
	PID	23.25	-	1.0615	0.1023
Strejcova metóda	P	9.00	0.081	0.8810	0.1273
	PI	18.40	-	0.7328	0.0872
Cohen – Coonova metóda	P	7.30	0.015	0.5574	0.0841
	PI	21.07	-	1.0339	0.1013
	PID	21.24	-	1.0076	0.1001

Tabuľka č.5 Kvalita riadenia zloženia destilátu rektifikačnej kolóny.

		t_{reg} [min]	Regulač. odch.[°C]	I_{IAE} [°C]	I_{ISE} [°C]
Ziegler – Nicholsova metóda	P	8.40	0.90	27.06	157.38
	PI	23.47	-	47.02	188.37
	PID	23.32	-	49.25	193.63
Strejcova metóda	P	11.00	3.40	42.71	254.11
	PI	21.44	-	36.72	167.69
Cohen – Coonova metóda	P	8.40	0.86	26.93	157.15
	PI	23.08	-	47.99	190.97
	PID	23.30	-	46.86	182.91

Tabuľka č.6 Kvalita riadenia teploty pár na hlave rektifikačnej kolóny.

V ďalšej časti „riadenie rektifikačnej kolóny neuro-fuzzy regulátorom“ budú použité údaje z klasického riadenia ako vstupné údaje trénovania neurónovej siete. Nakoľko pri použití P-regulátorov na riadenie rektifikačnej kolóny výsledky simulácií vykazujú trvalú regulačnú odchýlku, z porovnávaní fuzzy riadení rektifikačnej kolóny tento typ regulátora bude vynechaný.

Najlepšie ukazovatele kvality majú PI regulátory s navrhnutými parametrami Strejcovou metódou, preto pri porovnávaní fuzzy riadení zloženia destilátu aj teploty pár na hlave rektifikačnej kolóny budú použité PI-regulátory s navrhnutými parametrami Strejcovou metódou na porovnávanie použitia neuro-fuzzy regulátorov na riadenie zloženia destilátu a teploty pár na hlave rektifikačnej kolóny.

2.2.3 Riadenie rektifikačnej kolóny neuro-fuzzy regulátorom

Anfis využíva schopnosť hybridného určenia algoritmov k identifikácii parametrov funkcii príslušnosti jednoduchého výstupu, ako je Sugenov typ fuzzy systémov. Pre „tréning“ FIS členov na určenie parametrov funkcii príslušnosti sa používa kombinácia metódy najmenších štvorcov a metódy spätného šírenia. Neuro – fuzzy model typu Sugeno sa mení pri použití počtu funkcii príslušnosti a typu funkcie príslušnosti.

Možnosti v Matlabe pri použití mriežkového rozdelenia vstupných dát voľba počtu funkcii príslušnosti je od 2 do 9, a voľba typu funkcie príslušnosti: trimf, trapmf, gbellmf, gaussmf, gauss2mf, dsigmf, pimf. Pri riadení bola snaha použiť čo najjednoduchší výpočet a najkratší čas výpočtu, preto bola volená počet funkcii príslušnosti čo najnižší: maximálne 3, v závislosti od výsledku riadenia a najjednoduchší typ funkcie príslušnosti Trimf (trojuholníkový).


Podľa štruktúry fuzzy regulátora bol použitý typ fuzzy regulátora [6]:

PD-regulátor, ktorý aproximuje vzťah:

$$u(t) = K_P e(t) + K_D \Delta e(t). \quad (2.35)$$

Vstupné údaje regulátora sú regulačná odchýlka ($e(t)$) a jej derivácia podľa času (de/dt). Počet pravidiel závisí od zvoleného počtu funkcii príslušností oboch vstupov. Napríklad: pri zvolenom počte funkcii príslušnosti 3 a daného počtu vstupov 2, počet pravidiel bude 9.

Na obrázku 2.16 je uvedená simulačná schéma vytvorená v prostredí Simulink na riadenie zloženia destilátu rektifikačnej kolóny neuro-fuzzy regulátorom. Simulačná schéma na riadenie teploty pár na hlave kolóny je veľmi podobná, líši sa len konštantnými hodnotami a s-funkciou.



Obrázok 2.16 Simulačná schéma riadenia zloženia destilátu rektifikačnej kolóny.

Kvalita riadenia rektifikačnej kolóny pomocou navrhnutých regulátorov podľa doby regulácie, integrálnych kritérií a počtu pravidiel na identifikáciu parametrov neuro-fuzzy regulátora je v tabuľke č.7. a č.8.

Mriežkové rozdelenie dát	t_{reg} [min]	Regulačná odchýlka [-]	I_{IAE} [-]	I_{ISE} [-]	Počet použitých pravidiel
Neuro-fuzzy regulátor	6.85	-	0.5270	0.0802	4

Tabuľka č.7 Kvalita riadenia zloženia destilátu rektifikačnej kolóny.

Mriežkové rozdelenie dát	t_{reg} [min]	Regulačná odchýlka [°C]	I_{IAE} [°C]	I_{ISE} [°C]	Počet použitých pravidiel
Neuro-fuzzy regulátor	5.61	-	25.70	148.90	9


Tabuľka č.8 Kvalita riadenia teploty pár na hlave rektifikačnej kolóny.

2.2.4 Grafické zobrazenie riadenia rektifikačnej kolóny


Nasledujúce obrázky sú grafickými zobrazeniami výsledku simulácie riadenia zloženia destilátu a teploty pár na hlave rektifikačnej kolóny podľa simulačnej schémy vytvorenej v prostredí simulačného jazyka Matlab – Simulink.

Obrázok 2.17 zobrazuje výsledok simulácie riadenia zloženia destilátu rektifikačnej kolóny neuro-fuzzy regulátorom s počtom funkcií príslušnosti 2 a typom Trimf.

Obrázok 2.18 zobrazuje výsledok simulácie riadenia teploty pár na hlave rektifikačnej kolóny neuro-fuzzy regulátorom s počtom funkcií príslušnosti 3 a typom Trimf.




Obrázok 2.17 Riadenie zloženia destilátu rektifikačnej kolóny.




Obrázok 2.18 Riadenie teploty pár na hlave kolóny.

Obrázok 2.19 je grafické zobrazenie povrchu výstupnej FIS matice pri riadení zloženia destilátu neuro-fuzzy regulátorom, keď na návrh parametrov regulátora boli použité 4 pravidlá. Obrázok 2.20 je grafické zobrazenie povrchu výstupnej FIS matice pri riadení teploty pár na hlave kolóny neuro-fuzzy regulátorom, keď na návrh parametrov regulátora bolo použité 9 pravidiel.



Obrázok 2.19 Povrch výstupnej FIS matice pri riadení zloženia destilátu.



Obrázok 2.20 Povrch výstupnej FIS matice pri riadení teploty pár na hlave kolóny.

2.2.5 Použitie metódy subtraktívneho zhlukovania vstupných dát.

Použitie príkazu v Matlabe Genfis2 generuje fuzzy inferenčný systém (FIS) Sugenovského typu použitím metódy subtraktívneho zhlukovania vstupných dát pomocou funkcie *SUBCLUST* na predpokladanie počtu funkcií príslušnosti a určenie pravidiel.

Možnosti v Matlabe pri použití príkazu Genfis2 je zadanie vstupných údajov, hodnoty hranice dosahu vplyvu centra zhuku pre vstup a výstup, poprípade hodnoty potláčacieho faktora.

Simulačné schémy na riadenie zloženia destilátu a teploty pár na hlave kolóny neuro-fuzzy regulátorom navrhnutým pri použití metódy subtraktívneho zhlukovania vstupných údajov sú totožné so simulačnými schémami pri použití metódy mriežkového rozkladu dát.

Z tabuliek z č.9 a č.10 vidíme, že na návrh parametrov neuro-fuzzy regulátora na riadenie zloženia destilátu rektifikačnej kolóny bolo použité 1 pravidlo a na návrh parametrov neuro-fuzzy regulátora na riadenie teploty pár na hlave rektifikačnej kolóny boli použité 3 pravidlá. Obrázok 2.21 je grafické zobrazenie povrchu výstupnej FIS matice pri riadení zloženia destilátu rektifikačnej kolóny neuro-fuzzy regulátorom, keď na návrh parametrov regulátora bolo použité 1 pravidlo. Obrázok 2.22 je grafické zobrazenie povrchu výstupnej FIS matice pri riadení teploty pár na hlave kolóny neuro-fuzzy regulátorom, keď na návrh parametrov regulátora boli použité 3 pravidlá.


Kvalita riadenia rektifikačnej kolóny pomocou navrhnutých neuro-fuzzy regulátorov podľa doby regulácie, integrálnych kritérií a počtu pravidiel je v tabuľke č.9. a č.10.

Subtraktívne zhlukovanie	t_{reg} [min]	Regulačná odchýlka [-]	I_{IAE} [-]	I_{ISE} [-]	Počet použitých pravidiel
Neuro-fuzzy regulátor	6.00	-	0.5351	0.0802	1


Tabuľka č.9 . Kvalita riadenia zloženia destilátu rektifikačnej kolóny.

Subtraktívne zhlukovanie	t_{reg} [min]	Regulačná odchýlka [°C]	I_{IAE} [°C]	I_{ISE} [°C]	Počet použitých pravidiel
Neuro-fuzzy regulátor	5.75	-	25.01	148.91	3

Tabuľka č.10 Kvalita riadenia teploty pár na hlave rektifikačnej kolóny.




Obrázok 2.21 Povrch výstupnej FIS matice pri riadení zloženia destilátu.



Obrázok 2.22 Povrch výstupnej FIS matice pri riadení teploty pár na hlave kolóny.

Nasledujúce obrázky sú grafickými zobrazeniami výsledku simulácie riadenia zloženia destilátu a teploty pár na hlave rektifikačnej kolóny neuro-fuzzy regulátorom navrhnutými parametrami pomocou štruktúry Anfis pomocou subtraktívneho zhlukovania vstupných dát.


Obrázok 2.23 je porovnanie výsledkov simulácie riadenia zloženia destilátu rektifikačnej kolóny neuro-fuzzy regulátorom s navrhnutými parametrami pomocou Anfis s mriežkovým rozdelením alebo subtraktívneho zhlukovania vstupných údajov.



Obrázok 2.23 Porovnanie neuro-fuzzy regulátorov.

Pri porovnaní výsledkov simulácie riadenia zloženia destilátu rektifikačnej kolóny neuro-fuzzy regulátormi s parametrami navrhnutými pomocou štruktúry Anfis použitím metódy mriežkového rozdelenia a subtraktívneho zhlukovania vstupných údajov sa dá zistiť, že dobu regulácie má kratšiu riadenie použitím metódy subtraktívneho zhlukovania. Podľa porovnania ukazovateľov kvality regulácie rozdiel sa dá sledovať len pri hodnotách absolútnej regulačnej plochy, nižšiu má riadenie neuro-fuzzy regulátorom použitím metódy subtraktívneho zhlukovania vstupných dát. Tento typ regulátora má jedno pravidlo, kým na návrh parametrov neuro-fuzzy regulátora použitím metódy mriežkového rozkladu vstupných dát bolo použité 4.

Obrázok 2.24 je porovnanie výsledkov simulácie riadenia teploty pár na hlave rektifikačnej kolóny neuro-fuzzy regulátorom s navrhnutými parametrami pomocou Anfis s mriežkovým rozdelením alebo subtraktívneho zhlukovania vstupných údajov.



Obrázok 2.24 Porovnanie neuro-fuzzy regulátorov.

Pri porovnaní výsledkov simulácie riadenia teploty pár na hlave rektifikačnej kolóny neuro-fuzzy regulátormi s parametrami navrhnutými pomocou štruktúry Anfis použitím metódy mriežkového rozdelenia a subtraktívneho zhlukovania vstupných údajov sa dá zistiť, že dobu regulácie majú takmer rovnakú. Podľa porovnania ukazovateľov kvality regulácie rozdiel sa dá sledovať pri hodnotách absolútnej aj kvadratickej regulačnej plochy, najnižšiu má riadenie neuro-fuzzy regulátorom použitím metódy subtraktívneho zhlukovania vstupných dát. Tento typ regulátora má 3 pravidiel, kým na návrh parametrov neuro-fuzzy regulátora použitím metódy mriežkového rozkladu vstupných dát bolo použité 9.

2.2.6 Porovnanie výsledkov simulácie riadenia rektifikačnej kolóny

Posledné obrázky a tabuľky tejto diplomovej práce sú porovnávaním výsledkov simulácie riadenia rektifikačnej kolóny regulátormi s navrhnutými parametrami podľa experimentálnych metód a neuro-fuzzy regulátormi s navrhnutými parametrami pomocou štruktúry Anfis. Pomocou nich sa dá poukázať na výhody použitia neuro-fuzzy regulátorov pri riadení rektifikačnej kolóny. Na porovnanie výsledkov simulácie riadenia rektifikačnej kolóny z regulátorov s navrhnutými parametrami podľa experimentálnych metód boli vybrané PI-regulátory s navrhnutými parametrami podľa Strejca, lebo riadenie rektifikačnej kolóny pomocou nich má najlepšie ukazovatele kvality.

Kvalita riadenia rektifikačnej kolóny pomocou navrhnutých regulátorov podľa doby regulácie, integrálnych kritérií kvality a počtu pravidiel je v tabuľke č.11. a č.12.


Zloženie destilátu		t_{reg} [min]	Regulačná odchýlka [-]	I_{IAE} [-]	I_{ISE} [-]	Počet použitých pravidiel
Klasický PI-regulátor Strejcova metóda		18.40	-	0.7328	0.0872	-
Neuro-fuzzy regulátor	(Genfis1)	6.85	-	0.5270	0.0802	4
	(Genfis2)	6.00	-	0.5301	0.0802	1

Tabuľka č.11 Kvalita riadenia zloženia destilátu rektifikačnej kolóny.


Teplota pár na hlave kolóny		t_{reg} [min]	Regulačná odchýlka [°C]	I_{IAE} [°C]	I_{ISE} [°C]	Počet použitých pravidiel
Klasický PI regulátor Strejcova metóda		21.44	-	36.72	167.79	-
Neuro-fuzzy regulátor	(Genfis1)	5.61	-	25.70	148.90	9
	(Genfis2)	5.75	-	25.01	148.91	3

Tabuľka č.12 Kvalita riadenia teploty pár na hlave rektifikačnej kolóny.

Obrázok 2.25 je porovnanie výsledkov simulácie riadenia zloženia destilátu rektifikačnej kolóny navrhnutými regulátormi. Obrázok 2.26 je porovnanie výsledkov simulácie riadenia teploty pár na hlave rektifikačnej kolóny navrhnutými regulátormi. Na oboch obrázkoch zelená čiara znázorňuje priebeh riadenia pomocou PI-regulátora s navrhnutými parametrami podľa Strejca, modrá čiara je znázornením priebehu riadenia pomocou neuro-fuzzy regulátora s navrhnutými parametrami pomocou štruktúry Anfis mriežkovým rozdelením vstupných údajov a červená čiara znázorňuje priebeh riadenia pomocou neuro-fuzzy regulátora s navrhnutými parametrami pomocou štruktúry Anfis použitím subtraktívneho zhlukovania vstupných údajov.



Obrázok 2.25 Porovnanie výsledkov simulácie.



Obrázok 2.26 Porovnanie výsledkov simulácie.

Záver

Táto diplomová práca sa zaoberala využitím vybranej časti teórie fuzzy riadenia pri návrhu regulátora - aplikáciou Anfis štruktúry.

Fuzzy regulátory sa vytvárajú ako reprezentácie klasických regulátorov, ale aj ako samostatné objekty, navrhnuté podľa aktuálnych podmienok regulovaného procesu. O fuzzy regulátoroch je možné tvrdiť, že sú univerzálnymi aproximátormi ľubovoľnej spojitkej funkcie. Jazykové fuzzy regulátory sú fuzzy systémy s bázou znalostí, ktoré pomocou fuzzifikácie, vhodného spôsobu odvodzovanie záverov a defuzzifikácie priradujú hodnotám veličín sledovaných na vstupe hodnoty veličín sledovaných na výstupe. Z matematického hľadiska vytvárajú funkcie aproximujúce neznáme závislosti medzi sledovanými vstupnými a výstupnými veličinami.

Medzi hybridné systémy, ktoré kombinujú neurónové siete a fuzzy systémy, patrí aj špeciálna trieda adaptívnych sietí Anfis. Pomocou nej sa navrhujú parametre regulátora Sugenovho typu. Pri návrhu neuro-fuzzy regulátora na riadenie zloženia destilátu a teploty pár na hlave etážovej rektifikačnej kolóny som využila poznatky z návrhu regulátorov navrhnutých vybranými experimentálnymi metódami. Zisťovala som ako vplýva počet a typ funkcie príslušnosti, použitie mriežkového rozkladu alebo subtraktívneho zhľukovania vstupných údajov učenia neurónovej siete na priebeh riadenia zloženia destilátu a teploty pár na hlave etážovej rektifikačnej kolóny neuro-fuzzy regulátormi.

Porovnanie výsledkov simulácie riadenia zloženia destilátu a teploty pár na hlave etážovej rektifikačnej kolóny som skúmala z troch hľadísk:

❖ podľa doby regulácie:

- zloženie destilátu: najkratší čas regulácie pri porovnaní simulácií riadenia regulátormi s navrhnutými parametrami experimentálnymi metódami malo riadenie PI regulátorom podľa Strejca, 18.40 minút, pri riadení neuro-fuzzy regulátormi použitím mriežkového rozkladu 6.85 minút, a subtraktívneho zhľukovania vstupných dát tento čas bol 6.00 minút.
- teplota pár na hlave kolóny: najkratší čas regulácie pri porovnaní simulácií riadenia regulátormi s navrhnutými parametrami experimentálnymi metódami

malo riadenie PI regulátorom podľa Strejca, 21.44 minút, pri riadení neuro-fuzzy regulátormi navrhnutými použitím metódy mriežkového rozkladu 5.61minút a subtraktívneho zhukovania vstupných dát tento čas bol 5.71 minút.

❖ podľa integrálnych kritérií kvality regulácie:

- zloženie destilátu: pri porovnaní simulácií riadenia regulátormi s navrhnutými parametrami experimentálnymi metódami najmenšie hodnoty integrálnych kritérií kvality malo riadenie PI regulátorom podľa Strejca: hodnota IAE bola 0.7328, hodnota ISE bola 0.0872. Porovnanie simulácií riadenia kolóny neuro-fuzzy regulátormi najmenšie hodnoty dosiahla riadenie zloženia destilátu etážovej rektifikačnej kolóny neuro-fuzzy regulátorom s navrhnutými parametrami pomocou metódy mriežkového rozkladu vstupných dát neurónovej siete. Hodnota IAE bola 0.5270, hodnota ISE bola 0.0802.
- teplota pár na hlave kolóny: pri porovnaní simulácií riadenia regulátormi s navrhnutými parametrami experimentálnymi metódami najmenšie hodnoty integrálnych kritérií kvality malo riadenie PI regulátorom podľa Strejca: hodnota IAE bola 36.72, hodnota ISE bola 167.69. Porovnanie simulácií neuro-fuzzy regulátormi najmenšie hodnoty dosiahla riadenie kolóny neuro-fuzzy regulátorom s navrhnutými parametrami pomocou metódy subtraktívneho zhukovania vstupných dát neurónovej siete. Hodnota IAE bola 25.03, hodnota ISE bola 148.91.

❖ podľa počtu pravidiel neuro-fuzzy regulátorov:

- zloženie destilátu: najmenší počet pravidiel bol použitý pri návrhu parametrov neuro-fuzzy regulátorov pomocou metódy subtraktívneho zhukovania vstupných údajov. Počet bol 1. Podľa tohto hľadiska je vhodnejšie použiť metódu subtraktívneho zhukovania ako mriežkového rozkladu vstupných údajov.
- teplota pár na hlave etážovej rektifikačnej kolóny: najmenší počet pravidiel bol použitý pri návrhu parametrov neuro-fuzzy regulátorov pomocou metódy subtraktívneho zhukovania vstupných údajov. Počet bol 3. Podľa tohto hľadiska je vhodnejšie použiť metódu subtraktívneho zhukovania ako mriežkového rozkladu vstupných údajov.

Z porovnaní výsledkov simulácií riadenia etážovej rektifikačnej kolóny navrhnutými regulátormi je zrejmé, že sa dajú navrhnuť neuro-fuzzy regulátory, ktoré majú lepšie ukazovatele kvality ako klasické regulátory s navrhnutými parametrami vybranými experimentálnymi metódami. Metóda subtraktívneho zhukovania je pri návrhu vhodná preto, že sa zníži počet pravidiel.

LITERATÚRA

- [1] Bakošová, M. a kol.: Základy automatizácie. Laboratórne cvičenie zo základov automatizácie. Vydavateľstvo STU, Bratislava 2003
- [2] Mikleš, J., Dostál, P., Mészáros, A.: Riadenie technologických procesov. Vydavateľstvo STU, Bratislava 1994
- [3] Mészáros, A. a kol.: Základy automatizácie. Vydavateľstvo STU, Bratislava 1997
- [4] Fikar a kol. Identifikácia systémov. Vydavateľstvo STU v Bratislave, 1999.
- [5] Modrlák, O. Fuzzy řízení a regulace. 2002
- [6] Vysoký, P. Fuzzy řízení. Vydavatel'stvo ČVUT, Praha 1996
- [7] Kolesárová A.; Kováčová, M.: Fuzzy množiny a ich aplikácie. Vydavateľstvo STU v Bratislave, 2004.
- [8] Jura, P: Základy fuzzy logiky pro řízení a modelování. Brno: VUTIUM, 2003.
- [9] Szűcssová, A: Návrh regulátora pre riadenie etážovej rektifikačnej kolóny. (Bakalárska práca) Bratislava, 2003.
- [10] Mikulíková, J: Adaptívne λ -sledovanie nelineárnych chemickotechnologických systémov. (Diplomová práca) Bratislava, 2000.
- [11] Holíš, M: Použitie neuro – fuzzy systémov pri riadení kontinuálnych procesov v podmienkach neurčitosti (Dizertačná práca) Bratislava 2001
- [12] Vasičkaninová, A.; Bakošová, M.; Dvoran, J. : Tvorba neuro-fuzzy modelov metódou Anfis. AT&P journal 11/2006
- [13] www.mathworks.com – Documentation
- [14] Sinčák P., Andrejková G.: Neurónové siete 1. a 2. diel, Alfa s.r.o., 1996.

PRÍLOHY

Príloha č.1: Výpis programu pre iteračný výpočet ustáleného stavu rektifikačnej kolóny.

```
% konstanty funkcie rovnovaznej krivky metanol-voda
a=-0.0009812865; b=7.4724241; c=7.6605464; d=-4.8722389; e=-4.0466528;

F=4.8107; % [mol/min] molovy prietok nastreku
G=2.635; % [mol/min] molovy prietok parnej fazy kolonou
L=1.699; % [mol/min] molovy prietok spatneho toku
D=G-L; % [mol/min] molovy prietok destilatu
W=F-D; % [mol/min] molovy prietok zvysku
xf=0.11; % [-] molovy prietok prchavejsej zlozky v nastreku
uv=1; % [-] ucinnost varaka
ue=0.6; % [-] ucinnost etaze

x0s=0.00001; dif=1; t=0; k=0.00001; presnost=0.005;

while (dif>presnost&t<=300)

y0t=(a+c*x0s+e*x0s^2)/(1+b*x0s+d*x0s^2);
y0s=uv*y0t;

x1s=(G*y0s+W*x0s)/(L+F);
y1t=(a+c*x1s+e*x1s^2)/(1+b*x1s+d*x1s^2);
y1s=ue*(y1t-y0s)+y0s;

x2s=x1s+G*(y1s-y0s)/(L+F);
y2t=(a+c*x2s+e*x2s^2)/(1+b*x2s+d*x2s^2);
y2s=ue*(y2t-y1s)+y1s;

x3s=x2s+G*(y2s-y1s)/(L+F);
y3t=(a+c*x3s+e*x3s^2)/(1+b*x3s+d*x3s^2);
y3s=ue*(y3t-y2s)+y2s;

x4s=x3s+G*(y3s-y2s)/(L+F);
y4t=(a+c*x4s+e*x4s^2)/(1+b*x4s+d*x4s^2);
y4s=ue*y4t+(1-ue)*y3s;

x5s=((L+F)*x4s-F*xf+G*(y4s-y3s))/L;
y5t=(a+c*x5s+e*x5s^2)/(1+b*x5s+d*x5s^2);
y5s=ue*y5t+(1-ue)*y4s;

x6s=x5s+G*(y5s-y4s)/L;
y6t=(a+c*x6s+e*x6s^2)/(1+b*x6s+d*x6s^2);
y6s=ue*y6t+(1-ue)*y5s;

x7s=x6s+G*(y6s-y5s)/L;
xds=(F*xf-W*x0s)/D;

dif=abs(x7s-xds);
x0s=x0s+k;
t=t+1;

end
[x0s x1s x2s x3s x4s x5s x6s x7s xds t dif]
```


Príloha č.2: Výpis s-funkcie pre simuláciu prechodových charakteristík zloženia destilátu dynamického modelu etážovej rektifikačnej kolóny pre skokovú zmenu mólové prietoku spätného toku L

```
function[sys,x0]=sfl11(t,x,u,flag)
F=4.8107;  %[mol/min] molovy prietok nastreku
G=2.635;   %[mol/min] molovy prietok parnej fazy kolonou
xf=0.11;   %[-]      molovy prietok prchavejsej zložky v nastreku
uv=1;      %[-]      ucinnost varaka
ue=0.6;    %[-]      ucinnost etaze
H1=1.618;  %[mol]     molova zadrz kvapaliny na etazach
H0=1262.6; %[mol]     molova zadrz kvapaliny vo varaku
```

```
% konstanty funkcie rovnovaznej krivky metanol-voda
a=-0.0009812865;
b=7.4724241;
c=7.6605464;
d=-4.8722389;
e=-4.0466528;
```

```
if flag==0,
    x0(1)=0.0023;
    x0(2)=0.008;
    x0(3)=0.0177;
    x0(4)=0.0366;
    x0(5)=0.0680;
    x0(6)=0.1100;
    x0(7)=0.2786;
    x0(8)=0.5538;
    sys=[8,0,1,1,0,0];
```

```
elseif flag==1,
    D=G-u;
    W=F-D;
```

```
% diferencialne rovnice pre varak
y1=(a+c*x(1)+e*x(1)^2)/(1+b*x(1)+d*x(1)^2);
dx(1)=((u+F)*x(2)-G*y1-W*x(1))/H0;
```

```
% ----- pre 1.etaz
y2t=(a+c*x(2)+e*x(2)^2)/(1+b*x(2)+d*x(2)^2);
y2=0.6*y2t+0.4*y1;
dx(2)=(G*y1+(u+F)*x(3)-G*y2-(u+F)*x(2))/H1;
```

```
% ----- pre 2.etaz
y3t=(a+c*x(3)+e*x(3)^2)/(1+b*x(3)+d*x(3)^2);
y3=0.6*y3t+0.4*y2;
dx(3)=(G*y2+(u+F)*x(4)-G*y3-(u+F)*x(3))/H1;
```

```
% ----- pre 3.etaz
y4t=(a+c*x(4)+e*x(4)^2)/(1+b*x(4)+d*x(4)^2);
y4=0.6*y4t+0.4*y3;
dx(4)=(G*y3+(u+F)*x(5)-G*y4-(u+F)*x(4))/H1;
```

```
% ----- pre 4.etaz
y5t=(a+c*x(5)+e*x(5)^2)/(1+b*x(5)+d*x(5)^2);
y5=0.6*y5t+0.4*y4;
dx(5)=(F*xf+G*y4+u*x(6)-G*y5-(u+F)*x(5))/H1;

% ----- pre 5.etaz
y6t=(a+c*x(6)+e*x(6)^2)/(1+b*x(6)+d*x(6)^2);
y6=0.6*y6t+0.4*y5;
dx(6)=(G*y5+u*x(7)-G*y6-u*x(6))/H1;

% ----- pre 6.etaz
y7t=(a+c*x(7)+e*x(7)^2)/(1+b*x(7)+d*x(7)^2);
y7=0.6*y7t+0.4*y6;
dx(7)=(G*y6+u*y7-G*y7-u*x(7))/H1;

% ----- pre kondenzator
dx(8)=(G*y7-(u+D)*x(8))/H1;

% vypis hodnot derivacie
sys=dx;

elseif flag==3,
    sys=x(8);

else
    sys=[];
end
```

Príloha č.3: Výpis s-funkcie pre simuláciu prechodových charakteristík teploty pár na
hlave dynamického modelu etážovej rektifikačnej kolóny pre skokovú
zmenu mólovej prietoku spätného toku L

```
function[sys,x0]=kolsf(t,x,u,flag)
F=4.8107;    %[mol/min] molovy prietok nastreku
G=2.635;    %[mol/min] molovy prietok parnej fazy kolonou
xf=0.11;    %[-] molovy prietok prchavejsej zložky v nastreku
uv=1;       %[-] ucinnost varaka
ue=0.6;     %[-] ucinnost etaze
H1=1.618;   %[mol] molova zadrz kvapaliny na etazach
H0=1262.6;  %[mol] molova zadrz kvapaliny vo varaku

% konstanty funkcie rovnovaznej krivky metanol-voda
a=-0.0009812865;
b=7.4724241;
c=7.6605464;
d=-4.8722389;
e=-4.0466528;

if flag==0,
    x0(1)=0.0023;
    x0(2)=0.008;
    x0(3)=0.0177;
    x0(4)=0.0366;
    x0(5)=0.0680;
    x0(6)=0.1100;
    x0(7)=0.2786;
    x0(8)=0.5538;
    sys=[8,0,1,1,0,0];

elseif flag==1,
    D=G-u;
    W=F-D;

% diferencialne rovnice pre varak
y1=(a+c*x(1)+e*x(1)^2)/(1+b*x(1)+d*x(1)^2);
dx(1)=((u+F)*x(2)-G*y1-W*x(1))/H0;

% ----- pre 1.etaz
y2t=(a+c*x(2)+e*x(2)^2)/(1+b*x(2)+d*x(2)^2);
y2=0.6*y2t+0.4*y1;
dx(2)=(G*y1+(u+F)*x(3)-G*y2-(u+F)*x(2))/H1;

% ----- pre 2.etaz
y3t=(a+c*x(3)+e*x(3)^2)/(1+b*x(3)+d*x(3)^2);
y3=0.6*y3t+0.4*y2;
dx(3)=(G*y2+(u+F)*x(4)-G*y3-(u+F)*x(3))/H1;

% ----- pre 3.etaz
y4t=(a+c*x(4)+e*x(4)^2)/(1+b*x(4)+d*x(4)^2);
y4=0.6*y4t+0.4*y3;
dx(4)=(G*y3+(u+F)*x(5)-G*y4-(u+F)*x(4))/H1;
```

```
% ----- pre 4.etaz
y5t=(a+c*x(5)+e*x(5)^2)/(1+b*x(5)+d*x(5)^2);
y5=0.6*y5t+0.4*y4;
dx(5)=(F*xf+G*y4+u*x(6)-G*y5-(u+F)*x(5))/H1;

% ----- pre 5.etaz
y6t=(a+c*x(6)+e*x(6)^2)/(1+b*x(6)+d*x(6)^2);
y6=0.6*y6t+0.4*y5;
dx(6)=(G*y5+u*x(7)-G*y6-u*x(6))/H1;

% ----- pre 6.etaz
y7t=(a+c*x(7)+e*x(7)^2)/(1+b*x(7)+d*x(7)^2);
y7=0.6*y7t+0.4*y6;
dx(7)=(G*y6+u*y7-G*y7-u*x(7))/H1;

% ----- pre kondenzator
dx(8)=(G*y7-(u+D)*x(8))/H1;

sys=dx;

elseif flag==3,

at=99.944373;bt=-23.707679;ct=-11.7484;dt=-0.2125127;
td=at+bt*x(8)+ct*x(8)^2+dt*x(8)^3;

sys=td;
else
sys=[];
end
```

Príloha č.4: Krátky program na použitie štruktúry Anfis na návrh parametrov neuro-fuzzy regulátora pomocou príkazu Genfis1 a Genfis2

```
% edeu zo simulacie pri pouziti vybraného klasickeho regulátora

e=edeu(:,2); de=edeu(:,3); u=edeu(:,4); x=[0:length(edeu)-1];

% pomocou príkazu Genfis1_ mriezkove rozdelenie dat
% možnosti pre numMFs : 3,4,5,6,7,8,9
% možnosti pre mfType : trimf, trapmf, gbellmf, gaussmf, gauss2mf, dsigmf, psigmf, pimf

trnData = [e de u];

numMFs = 2; mfType = 'trimf'; epoch_n = 20;

in_fismat = genfis1(trnData,numMFs,mfType)
out_fismat = anfis(trnData,in_fismat,20);
writefis(out_fismat,'fs1.fis');
a=readfis('fs1.fis');
plotmf(a,'input',1),title('vstup e'), pause
plotmf(a,'input',2),title('vstup de'), pause
gensurf(a),title('povrch vystupnej fis matice, input1=e, input2=de, output=u')
ew=evalfis([e de],out_fismat);
fismat=readfis('fs1.fis')
ruleview('fs1.fis')
surfview('fs1.fis')

sim('kolona',15);
tA1=koncX(:,1); yA1=koncX(:,2); wA1=koncX(:,3); e1A1=koncX(:,4); e2A1=koncX(:,5);
plot(tA1,yA1,'r',tA1,wA1,'g');

% pomocou príkazu Genfis2_ subtraktívne zhľukovanie dat
trnData2 = [e de];

out_fismat2 = genfis2(trnData2,u,0.9);
writefis(out_fismat2,'fs2.fis');
a=readfis('fs2.fis');
plotmf(a,'input',1),title('vstup e')
plotmf(a,'input',2),title('vstup de')
gensurf(a),title('povrch vystupnej fis matice, input1=e, input2=de, output=u')
ew=evalfis([e de],out_fismat2);
fismat=readfis('fs2.fis')
ruleview('fs2.fis')
surfview('fs2.fis')

sim('kolona',15);
tA2=koncX(:,1); yA2=koncX(:,2); wA2=koncX(:,3); e1A2=koncX(:,4); e2A2=koncX(:,5);
plot(tA2,yA2,'r',tA2,wA2,'g');
```

Príloha č.5: Výpis „fs1.fis“ - neuro-fuzzy regulátor – Mriežkové rozdelenie vstupných dát

```
[System]
Name='fs1'
Type='sugeno'
Version=2.0
NumInputs=2
NumOutputs=1
NumRules=4
AndMethod='prod'
OrMethod='max'
ImpMethod='prod'
AggMethod='max'
DefuzzMethod='wtaver'

[Input1]
Name='input1'
Range=[-0.0700067143903794 0.2443]
NumMFs=2
MF1='in1mf1': 'trimf', [-0.384313428780759 -0.0883366529204591 0.261113254846325]
MF2='in1mf2': 'trimf', [-0.0465802923743947 0.232618738234131 0.558638517301635]

[Input2]
Name='input2'
Range=[-0.286199707378177 0.0500495087224606]
NumMFs=2
MF1='in2mf1': 'trimf', [-0.62245096044652 -0.279770522131033 0.0441095351684674]
MF2='in2mf2': 'trimf', [-0.292022354155352 0.0567066469064804 0.386298724823098]

[Output1]
Name='output'
Range=[-0.735395541920989 9.7754202]
NumMFs=4
MF1='out1mf1': 'linear', [-40.2627023036573 -20.2805118144787 0.0851098905916543]
MF2='out1mf2': 'linear', [18.9021766285328 -3.06996112553798 0.375625628264528]
MF3='out1mf3': 'linear', [7.00301244262612 -7.07729227395444 6.84412233187484]
MF4='out1mf4': 'linear', [39.4529206425945 -4.01850102903584 0.77270241349764]

[Rules]
1 1, 1 (1) : 1
1 2, 2 (1) : 1
2 1, 3 (1) : 1
2 2, 4 (1) : 1
```

Príloha č.6: Výpis „fs2.fis“ - neuro-fuzzy regulátor - Subtraktívne zhlukovanie

```
[System]
Name='fs2'
Type='sugeno'
Version=2.0
NumInputs=2
NumOutputs=1
NumRules=1
AndMethod='prod'
OrMethod='probor'
ImpMethod='min'
AggMethod='max'
DefuzzMethod='wtaver'

[Input1]
Name='in1'
Range=[-0.0700067143903794 0.0115065919802555]
NumMFs=1
MF1='in1mf1':gaussmf',[0.0288193058458063 -0.000120342605317458]

[Input2]
Name='in2'
Range=[-0.163514218010673 0.0500495087224606]
NumMFs=1
MF1='in2mf1':gaussmf',[0.0755061796942348 0.00147518299223581]

[Output1]
Name='out1'
Range=[-0.735395541920989 3.06070775476206]
NumMFs=1
MF1='out1mf1':linear',[12.5345188949394 -15.1843425156967 0.580063406534554]

[Rules]
1 1, 1 (1) : 1
```