

SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE
FAKULTA CHEMICKEJ A POTRAVINÁRSKEJ TECHNOLOGIE
Radlinského 9, 812 37 Bratislava
KATEDRA INFORMATIZÁCIE A RIADENIA PROCESOV

Bc. Jozef Gocian

DIPLOMOVÁ PRÁCA

Riadenie systémov pomocou adaptívnych
neurónových regulátorov.

Vedúci diplomovej práce:

Prof. Ing. Alojz Mészáros, PhD.

Bratislava 2009

Vyhlásenie:

Týmto prehlasujem, že túto prácu som vypracoval samostatne, s pomocou literatúry uvedenej v zozname použitej literatúry a pod odborným dohľadom vedúceho diplomového projektu.

V Bratislave, máj 2009

Pod'akovanie:

Pod'akovanie za odbornú pomoc a rady pri písaní diplomovej práce by som rád vyjadril svojmu diplomovému vedúcemu Prof. Ing. Alojz Mészáros, PhD.

V Bratislave, máj 2009

ABSTRAKT

V diplomovej práci je uvedený popis a následne využitie umelých neurónových sietí pri riadení nelineárnych a lineárnych systémov. Využitie umelých neurónových sietí je založené na použití priamej metódy inverzného riadenia, rozšírením inverzného riadenia o fuzzy integračnú zložku a adaptívne riadenie s robustnými vlastnosťami. Navrhnutie UNS v Neural Network Toolboxe v prostredí MATLAB, je popísaný stručný opis tvorby siete v tomto prostredí, rozšírený o konkrétne obrázky z grafického prostredia. Súčasťou práce je aj porovnanie použitých metód na lineárnom, ako aj na nelineárnom systéme s adaptívnym riadením.

ABSTRACT

A characterization of an ANN and an application in control of non-linear and linear systems, is presented in this master thesis. The application ANN is based on direct inverse method of control, extension of inverse control about fuzzy integral part and adaptive control with robust properties. ANN is designed using Neural Network Toolbox/MATLAB, brief description network creation is described in GUI. This thesis includes comparison of used control methods applied on linear and non-linear systems with adaptive control.

OBSAH	7
ÚVOD	9
1.Teoretická časť	11
1.1 Umelé neurónové siete	11
1.1.1 Stručný prehľad vývoja umelých neurónových sietí	11
1.1.2 Základné pojmy	12
1.1.3 Štruktúra neurónu a umelej neurónovej siete, učenie neurónovej siete	13
1.1.4 Návrh a popis umelej neurónovej siete v Neural Network Toolboxe v prostredí MATLAB	20
1.2 Fuzzy systémy	26
1.3 Adaptívne riadenie	32
1.4 Aplikácia umelých neurónových sietí pri riadení systémov	34
1.4.1 Riadenie systémov pomocou inverzného regulátora	35
1.4.2 Použitie fuzzy systémov v riadení procesov.....	35
1.4.3 Robustné riadenie s použitím neurónovej siete	36
1.4.4 Neurčitosti systémov	37
1.5 Opis nelineárneho modelu prietokového biochemického reaktora	37
2.Experimentálna časť	41
2.1 Riadenie nominálneho a perturbovaného lineárneho systému	41
2.1.1 Riadenie systému inverzným regulátorom	41
2.1.2 Riadenie systému inverzným reg. rozšíreným o I zložku ako fuzzy.....	43
2.1.3 Riadenie systému regulátorom s robustnými vlastnosťami.....	44
2.1.4 Riadenie systému adaptívnym regulátorom	46
2.2 Riadenie nominálneho a perturbovaného nelineárneho systému	47
2.2.1 Riadenie systému inverzným regulátorom	47
2.2.2 Riadenie systému inverzným reg. rozšíreným o I zložku ako fuzzy.....	50
2.2.3 Riadenie systému regulátorom s robustnými vlastnosťami.....	52
2.2.4 Riadenie systému adaptívnym regulátorom	54
2.3 Porovnanie použitých regulátorov v nelineárnych a lineárnych systémoch.....	55
Záver	57
Literatúra	59

Zoznam skratiek

GUI	– Grafické užívateľské prostredie (Graphical User Interface)
ST	– samonastavujúce sa (selftuning)
MIT	– Massachusetts Institute of Technology
TRO	– trvalá regulačná odchýlka
NN	– neurónová sieť (neural network)
UNS (ANN)	– umelá neurónová sieť (Artificial Neural Network)
FS	– fuzzy systém
IAE	– integrál absolútnej hodnoty regulačnej odchýlky
ISE	– integrál kvadrátu regulačnej odchýlky

ÚVOD

Neustála potreba človeka veci zdokonaľovať, vylepšovať sa nevyhla ani oblasti riadenia procesov. Inteligentné systémy riadenia sú jej typickým príkladom. Práve do tohto odvetvia neodmysliteľne patria umelé neurónové siete. Prvotnou inšpiráciou pre ich vznik pochádza priamo zo snahy namodelovať ľudský mozog a vnímanie. Vlastnosti umelej neurónovej siete ju predurčujú k riešeniu dôležitých problémov, a to napr. problém aproximácií funkcií, riešenie predikčných problémov, transformáciu signálov a v neposlednom rade riešenie problémov riadenia procesov.

Použitie neurónových sietí je všestranné, je takmer nemožné špecifikovať odvetvie, v ktorom by neurónové siete mali najväčšie uplatnenie. Ich výskum smeruje tak k „jemnejším“ odvetviam ako je medicína, farmaceutický priemysel, ale aj k odvetviam ako je napr. riadenie procesov. V oblasti riadenia procesov je výhodné využitie umelých neurónových sietí najmä v zložitých nelineárnych systémoch. K takýmto procesom patrí aj chemický priemysel. Na základe nedostatku informácií o systéme je veľmi zložitá a ťažké navrhnúť akýkoľvek typ regulátora, ktorý by bol schopný plniť svoju funkciu dostatočne. Regulátor navrhnutý pomocou neurónovej siete si vystačí so vstupnými a k nim zodpovedajúcimi výstupnými dátami. Aj táto vlastnosť kladie umelé neurónové siete do prvotných priečok v oblasti riadenia.

Vhodnosť použitia neurónovej siete ako efektívneho riadiaceho celku, či už v úlohe inverzného regulátora alebo regulátora rozšíreného o integračnú zložku je uvedená aj v tejto práci. Dobre nastavená a najmä vhodne natrénovaná neurónová sieť by mala dokázateľne opisovať dynamiku systému.

Aplikácia rôznych uvedených typov riadenia je obmedzená aj na výskyt neurčitostí v systémoch. V práci je k jednotlivým riadeniam pridaná perturbácia systému a to v lineárnom systéme 2. rádu a aj v nelineárnom systéme biochemického prietokového reaktora. Vytvorené adaptívne riadenie slúži na porovnanie výhod a kvalít jednotlivých typov riadení s použitím umelej neurónovej siete vytvorenej a navrhnutej v grafickom prostredí Neural Network Toolbox

Kapitola umelé neurónové siete pozostáva zo stručného rozpisu dejín a vzniku neurónových sietí, zaoberá sa prehľadom základných pojmov a používanej terminológie. Taktiež je tu preberaná štruktúra neurónu a neurónovej siete. Posledným bodom tejto

kapitoly je návrh neurónovej siete v Neural Network Toolboxe v prostredí MATLAB, prierez návrhom siete je obohatený o reálne obrázky z tohto prostredia.

Fuzzy systémy sú v jednoduchosti popísané základné vlastnosti takéhoto systému, základné typy funkcií príslušnosti a taktiež sú tu uvedené základy fuzzy riadenia.

Adaptívne riadenie popisuje základne rozdelenie takéhoto typu riadenia a vysvetľuje v jednoduchosti jeho základné vlastnosti. Taktiež popisuje úplný základ riadenia s využitím MIT pravidiel.

Aplikácia umelých neurónových sietí pri riadení systémov sa zaoberá teoretickým popisom v práci použitých typov riadenia a to použitie inverzného regulátora, fuzzy systém použitý ako integračná zložka, riadenie regulátorom s robustnými vlastnosťami a neurčitosti systémov.

Opis nelineárneho modelu prietokového biochemického reaktora uvádza použité konštanty a matematický model systému, ktorý bol použitý v práci.

V experimentálnej časti práce uvádzame aplikáciu umelej neurónovej siete na lineárny systém 2. rádu a nelineárny model bioprocesu a to v podobe nominálneho ako aj perturbovaného systému. Perturbácia lineárneho systému bola vykonaná na zmene veličín koeficientu tlmenia a zosilnenia. V nelineárnom systéme sa menila koncentrácia substrátu na vstupe, zried'ovacia rýchlosť kvapaliny a saturačná konštanta substrátu. Uvedené systémy boli riadené pomocou inverzného neurónového regulátora, inverzného neurónového regulátora doplneného o integračnú zložku vo forme fuzzy systému, regulátora s robustnými vlastnosťami a adaptívneho regulátora. Porovnania jednotlivých typov riadení sú v grafickej podobe. Ďalej sú tu uvedené vybrané porovnania jednotlivých riadení a to v lineárnom a nelineárnom modeli. Na vyhodnotenie jednotlivých typov riadenia boli použité dva druhy integrálnych kritérií kvality a to IAE a ISE. Výsledky dosiahnuté porovnaním pomocou integrálnych kritérií kvality sú zhrnuté v tabuľke 1 a 2.

1. TEORETICKÁ ČASŤ

1.1 Neurónové siete.

Je množstvo definícií, ktoré charakterizujú menej či viac významne pojem umelá neurónová sieť. Počet a charakter definícií sa postupom získavania nových informácií zväčšuje a zdokonaľuje. Definícia podľa [1] : umelá neurónová sieť je masívny paralelný procesor, ktorý má sklon k uchovávaniu experimentálnych znalostí a ich ďalšieho využívania.

Jednou zo základných vlastností umelej neurónovej siete je schopnosť abstrakcie pravidiel medzi vstupnými a výstupnými hodnotami a v ďalšom kroku aplikáciou získaných pravidiel na akákoľvek vstupné hodnoty. Ďalšou podstatne významnou vlastnosťou je , že svojim spôsobom je univerzálnym aproximátorom funkcií. V praxi ako aj v teoretickej rovine môže nastať problém, že sa dostaneme k systému ktorého popis je zložitý, náročný resp. nemožný. Tento systém nám však poskytne vstupné a k nim odpovedajúce výstupné hodnoty. Práve takto zvolený model nám umožňuje použiť a navrhnúť vhodnú umelú neurónovú sieť.

Pri štúdiu neurónových sietí je možné ich rozdeliť na tri časti :

- Teória neurónových sietí
- Simulácia neurónových sietí
- Implementácia neurónových sietí

Základnou myšlienkou neurónovej siete je snaha o napodobnenie ľudského rozmýšľania a tým aj riešenia problémov. Základným prvkom umelej neurónovej siete je neurón, resp. neuróny a ich vzájomné spojenia. V umelej neurónovej sieti nastavovaním týchto medzi-neurónových spojení (synaptických váh) a spojení siete s vonkajším okolím, sieť možno učiť resp. trénovať a tým z nej získať potrebné vlastnosti pre nami zadáný projekt.

1.1.1 Stručný prehľad vývoja umelých neurónových sietí

V roku 1943 začiatok teórie neurónových sietí pod vedením amerických vedcov McCullocha a Pittsa. Rok 1948-1949 Wiener naznačuje koncepty neurónovej siete vo svojej knihe Kybernetika, Hebb v knihe The Organization of Behavior prvýkrát zaviedol pojem učenia. O tri roky neskôr dr. Ashby napísal knihu, ktorá zásadne zasiahla do rozvoja

neurónových sietí. Táto kniha niesla názov *Design of Brain: The Origin of Adaptive Behavior*, 1954 dr. Minsky vypracoval dizertačnú prácu s témou *Neurónové siete* a sedem rokov potom napísal článok *Step Toward Artificial Intelligence*. Prvá simulácia neurónovej siete vznikla vďaka pánom Rochester, Holland, Habit a Duda v roku 1956. Rok 1958 dr. Rosenblat prišiel s novým prístupom k rozpoznávaniu pomocou tzv. perceptrónu a neskôr prichádza s novou teóriou perceptrónu. Významné obdobie v oblasti neurónových sietí nastalo v 60. rokoch 20. storočia. Teoretická báza neurónových sietí napredovala vďaka Widrow a Hoff a tzv. Adaline – Adaptive linear element, dva roky neskôr Widrow prišiel s tzv. Madaline – Multiple adaptive element. Rok 1968, dr. Grossberg predstavil svoj adaptívny model neurónu, 1969 dr. Minsky a dr. Papert popisujú činnosť viacvrstvového perceptrónu. Roky 1970-1980 neprinesli významnejšie objavy, toto obdobie sa skôr považuje za obdobie útlmu v oblasti neurónových sietí. V roku 1980 Grossberg prišiel s rozvojom tzv. Competitive learning. Rok 1982 dr. Hopfield použil termín energie neurónových sietí pre pochopenie rekurentných sietí. Na základe toho postupne vzniká trieda tzv. Hopfieldových sietí. Dr. Rumelhart a kolektív v roku 1986 prišli s metódou učenia spätným šírením chyby. Táto metóda je jednou z najrozšírenejších metód učenia neurónových sietí. Broomhead a Lowe v roku 1988 prišli s procedúrou Radial Basic Functions, pre dopredné siete.

V snahe rozobrať podrobnejšie prvky uvedené v zadaní diplomovej práce nie je možné rozoberať históriu vývoja podrobnejšie, preto uvedený rozbor neposkytuje úplný popis vývoja neurónových sietí.

1.1.2 Základné pojmy

Činnosť neurónových sietí vo všeobecnosti môžeme rozdeliť do dvoch fáz.

- 1 Fáza učenia, znalosti sa ukladajú do synaptických váh neurónovej siete. Synaptické váhy sa počas učenia menia. Definujme pojem učenie: je to proces, v ktorom sa parametre neurónových sietí (synaptické váhy) menia na základe nejakých pravidiel, ktoré vyvolajú zmeny synaptických váh neurónovej siete. Učenie je adaptácia neurónovej siete, ktorá po jeho ukončení bude vlastniť znalosti získané počas učenia.
- 2 Fáza života. V tejto fáze sa získané znalosti využívajú v prospech riešenia problému. Synaptické váhy sa nemenia.

Spomínané učenie je základnou a podstatnou vlastnosťou neurónových sietí. V dobách pred využívaním neurónových sietí bolo potrebné na riešenie problému vytvoriť

algoritmus, na základe ktorého sa daný problém vypočítal. Avšak pri neurónových sieťach je navrhnutý všeobecný algoritmus a ten daná sieť používa vo fáze učenia. Správnosť a vhodnosť tohto algoritmu určuje kvalitu a rýchlosť učenia.

Štúdium neurónových sietí je možné rozdeliť do troch oblastí.

1. Teória neurónových sietí – matematické a teoretické rozboru návrhu neurónovej siete
2. Simulácia, učenie navrhnutých neurónových sietí pomocou počítačových systémov.
3. Implementácia naučenej neurónovej siete.


K nemenej dôležitým pojmom z hľadiska základných princípov neurónovej siete je tzv. konekcionizmus. Chápe sa podľa [2] ako spôsob paralelného spracovania informácie, na rozdiel od symbolického prístupu, kde sa pracuje so symbolmi pomocou hierarchicky usporiadaných logických pravidiel. Paralelné spracovanie sa v tomto prístupe uplatňuje na základe jednoduchých výpočtov realizovaných neurónmi. Konekcionizmus vychádza z predpokladu, že základným stavebným prvkom ľudského mozgu je neurón. Ten signály prijíma z okolia, prijaté signály spracováva a ďalej spracované signály odosiela iným neurónom vo svojom okolí.

1.1.3 Štruktúra neurónu a umelej neurónovej siete

Štruktúra neurónu

Neurónová sieť je tvorená skupinou neurónov, tie sú navzájom poprepájané pomocou rozvetvených vstupných a výstupných orgánov jednotlivých neurónov. Neurón predstavuje základný prvok umelej neurónovej siete. Základné časti neurónu sú:

- vstup do neurónu tzv. dendrit
- prah neurónu
- aktivačná funkcia neurónu f , ktorá prispieva ku vstupu z externého sveta
- výstupná funkcia neurónu
- synaptické váhy, sú na tzv. synapsiách (synaptických spojeniach), spájajú neuróny do neurónovej siete a majú svoj smer.




Obr.1.1 Vľavo zobrazená typická neurónová bunka, napravo zobrazené vzájomné prepojenie neurónov.

Prostredníctvom dendrického systému do neurónu vstupujú signály z iných neurónov a prostredníctvom axónu z neurónu vystupuje signál charakterizujúci stav neurónu.

Neuróny je možné rozdeliť do dvoch skupín. Rozdeľujeme ich z hľadiska toku signálu po synapsii na:

- predsynaptické (zdrojové - pred synapsiou)
- postsynaptické (cieľové - po synapsii)



Obr.1.2 Rozdelenie neurónov podľa toku signálu po synapsii


Od konekcionistických modelov sa požadujú vlastnosti:

- model je zložený z umelých neurónov
- neuróny majú stav aktivácie
- model vlastní sieť spojov medzi neurónmi
- neuróny sú charakterizované aktivačnými pravidlami a tie opisujú výstupnú aktiváciu neurónu pomocou jeho vstupných aktivít
- model obsahuje pravidlo učenia sa na základe, ktorého sa nastavujú váhy spojov v sieti neurónov tak, aby výstupné aktivity boli blízke požadovaným
- model je aktívny v nejakom prostredí, z ktorého prijíma vstupné signály.

Spomínaný model potom obsahuje tzv. aktivačnú energiu. Pomocou aktivačnej energie sa transformujú signály na výstupný signál. Jednoduchý model tejto aktivačnej funkcie má tvar:

$$y = s(\xi) = s\left(\sum_{i=1}^p w_i x_i + \theta\right) \quad (1.1)$$

$$s(\xi) = \begin{cases} 1 & \xi \geq 0 \\ 0 & \xi < 0 \end{cases} \quad (1.2)$$



Obr.1.3 a) znázornenie práce neurónu, b) priebeh krokovej funkcie

Neurón obsahuje spoje s p inými neurónmi. Neurón sa nachádza buď v stave reprezentovanom 0, v tomto stave nevysiela signály do okolia pomocou axónu, alebo je v stave 1, vtedy vysiela signály do okolia. Ak váhovaná suma vstupných aktivít je väčšia ako prah θ , potom stav neurónu je $y=1$. V prípade ak váhovaná suma je menšia ako prah θ , tak neurón je v stave $y=0$.

Podľa [3] uvažujme predpoklad, že máme synchronnú neurónovú sieť, zloženú z K vrstiev po N formálnych neurónoch. Potom o_j^k reprezentuje výstup z j -teho neurónu v k -tej vrstve $\in [0, u]$, kde u predstavuje hornú hranicu frekvencie akčných potenciálov. w_{ij}^k označuje váhu spojenia medzi j -tym formálnym neurónom k -tej vrstvy a i -tym neurónom $k+1$ vrstvy $\in R$. Potom je výstup i -teho formálneho neurónu $k+1$ vrstvy daný vzťahom:


$$o_i^{k+1} = f\left(\sum_{j=1}^N w_{ij}^k \cdot o_j^k - \theta_i^{k+1}\right) \quad (1.3)$$

Pričom θ vyjadruje prah excitácie formálneho neurónu $\in R$. f je vstupno-výstupná aktivačná funkcia (napr. sigmodiálna funkcia, jej saturačná hodnota odpovedá u).

Typy niektorých aktivačných funkcií a príkazy na použitie v neurónových sieťach v Matlabe:


- **symetrická, silno obmedzená aktivačná funkcia** – obmedzuje výstupné hodnoty neurónu na dve výstupné hodnoty

$$\varphi(a) \equiv \begin{cases} 1 & \text{pre } a < 0 \\ -1 & \text{pre } a \geq 0 \end{cases}$$




- **silno obmedzená aktivačná funkcia** – obmedzuje výstupné hodnoty neurónu na dve výstupné hodnoty.

$$\varphi(a) \equiv \begin{cases} 0 & \text{pre } a < 0 \\ 1 & \text{pre } a \geq 0 \end{cases}$$




- **logsigmoidálna aktivačná funkcia** – veľmi často sa využíva v mnohovrstvových perceptrónových sieťach, a to z dôvodu, že funkcia je diferencovateľná.

$$\varphi(a) \equiv \frac{1}{1 + e^{-\beta a}}$$




- **tansigmoidálna aktivačná funkcia** – rozsah výstupných hodnôt má $[-1, 1]$.

$$\sigma(a) = \tanh\left(\frac{a}{2}\right) = \frac{1 - e^{-a}}{1 + e^{-a}}$$



- **lineárna aktivačná funkcia** – má lineárny vzťah medzi vstupnou a výstupnou hodnotou neurónu. Používa sa väčšinou v poslednej vrstve neurónovej siete.

$$\sigma(a) = a$$



Neurónová sieť


V jednoduchosti je možné sieť popísať orientovaným grafom pomocou vrcholov a orientovaných hrán. Jednoduchosť takejto siete však komplikuje analýzu jej vlastností kvôli svojej zložitosti. Preto sú študované najmä siete s pravidelnou štruktúrou. K takýmto sieťam patrí aj viacvrstvová štruktúra.

V neurónových sieťach rozlišujeme nasledujúce vrstvy:

- Vstupnú vrstvu – neuróny dostávajú vstup len z vonkajšieho sveta a výstup pokračuje k ďalšiemu neurónu.
- Skrytá vrstva – neuróny dostávajú vstup z ostatných neurónov alebo aj z externého sveta. Vstup prichádza cez prahové prepojenia a ich výstupy pokračujú ďalej do neurónovej siete.
- Výstupná vrstva – je podobná ako skrytá vrstva, výstupy však vyúsťujú do externého sveta.

Neurónové siete rozdeľujeme do dvoch základných skupín:



- Dopredné neurónové siete (feed-forward, Obr.1.4) – signál sa šíri po orientovaných synaptických prepojeniach len jedným smerom a to dopredu
- Rekurentné neurónové siete (Obr. 1.5) – v tomto prípade ide o dosť ťažké rozdelenie vrstiev a neurónov, niekedy totiž neuróny predstavujú vstupné, ale aj výstupné typy neurónov a tým aj vrstiev, obsahujú aspoň jednu spätnú väzbu v rámci tej istej vrstvy alebo v rámci rôznych vrstiev.



Obr. 1.4 Dopredná neurónová sieť

Obr. 1.5 Rekurentná neurónová sieť

Okrem týchto dvoch základných skupín poznáme aj špecifické typy neurónových sietí, ako sú tzv. Kohonenove siete (Obr. 1.6) a Hopfieldove siete (Obr. 1.7). [4]

Obr. 1.6 Kohonenova sieť – mriežková
štruktúra

Obr. 1.7 Hopfieldova sieť

Učenie neurónových sietí

Je to významná a základná vlastnosť umelej neurónovej siete, pri procese učenia dochádza k prenastaveniu resp. k zmene parametrov neurónovej siete. Cieľom týchto nastavení je dosiahnutie žiadanej zhody medzi výstupmi zo sústavy a výstupmi z neurónovej siete. Vo väčšine prípadov sa proces učenia sústreďuje na adaptáciu váh spojení medzi neurónmi. Ďalšími možnými nastaviteľnými parametrami siete je strmosť aktivačných funkcií prípadne zmena štruktúry neurónovej siete. Učenie siete je možné charakterizovať istým algoritmom, ktorý určuje akým spôsobom dochádza k zmene nastaviteľných parametrov neurónovej siete [5].

Hebbov zákon učenia

Je základom všetkých súčasných algoritmov učenia. Popisuje algoritmus modifikácie hodnôt synaptických spojení v neurónových systémoch živých organizmov. Základ predstavuje predpoklad, že ak dva spolu prepojené neuróny sú v tom istom okamihu aktívne, potom ich vzájomné väzby sú zosilnené. Keď sú obidva neuróny neaktívne dôjde k oslabeniu ich vzájomnej väzby. V prípade aktivity jedného neurónu, synapsie nie sú modifikované. Potom každý uvažovaný neurón má iba dva stavy a to aktívny a neaktívny. Uvedený Hebbov zákon sa dá vyjadriť nasledujúcim matematickým vzťahom:

$$\Delta w_{i,j} = \alpha x_i \cdot x_j - k \cdot w_{i,j} \quad (1.4)$$

kde x_j je presynaptický stav neurónu j a x_i je postsynaptický stav i -teho neurónu. α predstavuje tzv. zosilnenie procesu učenia (rýchlosť učenia).

Učenie je možné realizovať dvoma spôsobmi a to induktívnou alebo deduktívnou metódou. V prvom spôsobe určujeme platné závery na základe pozorovania množiny javov. V prípade učenia deduktívnou metódou ide o pozorovanie jedného javu a jeho následná analýza. Najčastejšie sa však využíva metóda induktívna. V prvom prípade sa jedná o takzvané učenie s učiteľom, v druhom prípade učenie bez učiteľa. Pri učení bez učiteľa učiaci systém nedostáva informáciu o správnom výstupe od učiteľa, ale odvodzuje si ju od svojho výstupu prostredníctvom spätnej väzby.

1. Učenie s učiteľom – chybové učenie

Predstavuje v praxi najbežnejší spôsob učenia. Hľadaná transformačná funkcia umelej neurónovej siete je vždy daná dvojicou hodnôt. Hodnotou vstupnej premennej x_i na jednej strane, a k nej požadovaným výstupom y_i daným učiteľom na druhej strane.

Výstupné hodnoty sa počas učiaceho procesu porovnávajú so skutočným výstupom siete $\hat{y}_i$ (skutočný výstup vznikne ako odozva neurónovej siete na daný vstupný signál). Počas procesu učenia dochádza k modifikácii váh spojení za účelom dosiahnutia čo najväčšej možnej zhody medzi skutočným a požadovaným výstupom. Tzn. že v procese učenia hľadáme minimum chybovej funkcie v tvare

$$E(s) = \sum_{i=1}^M [y_i(s,k) - \hat{y}_i(s,k)]^2 \quad (1.5)$$

kde s je poradové číslo epochy tréningovania, M je počet vzorov tréningovej množiny, k je poradové číslo vzoru tréningovej množiny, $y(k)$ je žiadaná hodnota na výstupe z neurónovej siete a $\hat{y}(s,k)$ je skutočná hodnota výstupu z neurónovej siete. Veľkosť zmeny váhy spojenia Δw_{ij} je potom úmerná veľkosti chyby medzi žiadanými a vypočítanými hodnotami.

2. Učenie bez učiteľa – samoorganizujúce, mapy

Základom tohto typu učenia je schopnosť neurónovej siete rozoznávať vo svojich vstupoch podobné, alebo rovnaké vlastnosti podľa týchto vlastností triediť predkladané vektory. Podobné vektory sa potom združujú do tzv. zhlukov – máp (podobnosť s ľudským mozgom).


Pritom algoritmus učenia nemá informáciu o žiadaných hodnotách výstupných neurónov. Neurónovej siete poskytujeme iba hodnoty vstupných premenných. Princípom učenia je výpočet vzdialenosti medzi vzormi a aktuálnymi hodnotami. Sú hľadané minimálne vzdialenosti vzoru. Proces samoorganizácie sa používa v prípadoch, keď nemáme učiacu množinu.

1.1.4 Návrh a popis umelej neurónovej siete v Neural Network toolboxe v prostredí MATLAB

Neurónovú sieť je možné vytvoriť v rôznych programoch, je však potrebná osobitná znalosť jednotlivých prostredí a príkazov. Neurónovú sieť je možné pomerne jednoducho vytvoriť aj v programe MATLAB a to použitím Neural Network Toolboxu. Sieť je možné vytvoriť buď použitím príkazov, ktoré sa zadávajú priamo do príkazového


riadku, alebo jednoduchšou variantou je použitie GUI. Samozrejmosťou tohto prostredia je možnosť exportovať výsledky získané v tomto prostredí do pracovného priestoru MATLAB-u, tak ako aj možnosť importovať údaje z GUI.

Príkazom `ntool` spustíme užívateľské prostredie pre tvorbu neurónovej siete.




Obr.1.8 Prostredie MATLAB

Po zadaní príkazu `nntool` otvorí sa nové okno, prostredníctvom ktorého vieme importovať zadané alebo simuláciou získané údaje z MATLABU resp. z Workspace.



Obr.1.9 Prostredie Neural Network Toolbox


Po kliknutí na položku `New` a zadáním parametrov vytvoríme nami zvolenú sieť.



Obr.1.10 Okno pre tvorbu siete


Ďalej nastavíme príslušné parametre. V kolónke *Name* zvolíme názov siete, *Network type* – zvolíme typ siete. Najčastejšie používaným typom je *Feed-forward backprop* ide o doprednú sieť, ktorá pri adaptácii váhových koeficientov používa metódu spätného šírenia chýb. *Input ranges* – vstupné intervaly, to znamená interval nami zadaných vstupných hodnôt. *Training function* – trénovacia funkcia určujúca spôsob aktualizácie hodnôt váh a biasov na základe jednej z optimalizačných metód. *Adaption learning function* – adaptačná učiacia funkcia určujúca spôsob podľa ktorého sa sieť bude učiť, t.j. ako budú nastavené hodnoty váh a biasov. *Performance function* – výkonová funkcia určujúca akým spôsobom sa bude kontrolovať výsledok učenia siete. Podľa zvolenej metódy sa bude prepočítavať chyba trénovania. Parametre zadávané ďalej už určujú priame nastavenie siete. *Number of layers* – udáva počet vrstiev. Nastavujeme tu však len počet skrytých vrstiev a výstupnú vrstvu, v MATLAB-e totiž vstupné vrstvy predstavujú nami zadané vstupy do siete. Ďalej nastavujeme každú vrstvu osobitne. *Properties for* – zadáme, ktorú vrstvu chceme upraviť. *Number of neurons* – počet neurónov na vrstve. *Transfer function* – aktivačná funkcia danej vrstvy. Kliknutím na ikonu *create* vytvoríme sieť podľa

vyššie uvedených parametrov. Ideálnym popisom je popis na konkrétny príklad. Zvolia sa teda vstupné parametre siete, v tomto prípade ide o údaje získané z lineárneho systému. Ako vstupné údaje boli zvolené, prvá história vstupu do modelu $u(k-1)$, aktuálny výstup $y(k)$ a jeho prvá história $y(k-1)$ a výstup $y(k+1)$. Následne boli hodnoty importované do pracovného prostredia *neural network toolboxu*. Priradili sme hodnoty na vstup do siete t.j. *UNS_input* a k nemu zodpovedajúci výstup *UNS_target*. Dobré je zvoliť ďalšie testovacie dáta a to z dôvodu lepšieho natrénovania siete. Ďalšie nastavenie siete bolo nasledovné. *Network type* je nastavené ako *Feed forward backprop* čiže ide o doprednú sieť, pri adaptácii váhových koeficientov využívajúci metódu spätného šírenia chýb. Vstupný interval bol určený na základe zadaných vstupných hodnôt. *Training function* zvolená *TRAINLM* čiže metóda využívajúca optimalizačnú metódu Levenberg-Marquardtovej optimalizácie. *Adaption learning function* nastavená funkcia *LEARNGDM* využíva algoritmus najstrmšieho spádu gradientu účelovej funkcie. *Performance function* – funkcia *MSE* počíta priemernú strednú kvadratickú odchýlku. Nasleduje zadanie počtu vrstiev neurónov a tiež aj typu vrstiev. V tomto prípade to je na vstupnej vrstve sú 4, v skrytej vrstve 3 a výstupnej vrstve 1 neurón, čiže neurónová sieť bude mať celkovú štruktúru {4,3,1}. Aktivačná funkcia nastavená na skrytej vrstve ako *TANSIG* a výstupná vrstva ako *PURELIN*. Takto ukončíme nastavenie parametrov neurónovej siete a vytvoríme sieť, ktorú je potrebné ďalej natrénovať. Po kliknutí na názov našej siete v prostredí *neural network toolboxu* získame grafický náčrt vytvorenej siete. Okrem tejto položky sa tu nachádzajú ďalej položky *Train*, *Simulate*, *Adapt*, *Reinitialize Weights*, *View/Edit Weights*.



Obr.1.11 Okno pre nastavenie a tréning NN *Train/Training info*.

Položky *Train* a *Adapt* slúžia na voľbu tréningu a na zadávanie parametrov pre tréning siete. V časti *Train – Training Info* nastavíme vstupné a výstupné tréningové dáta a v stĺpci *Training Results* v položke *Outputs* sa zadá názov, pod ktorým bude uložený výstup siete, v položke *Errors* sa zadá názov a pod ním sa uložia chyby tréningu. Ďalej tu nastavíme validačné a testovacie dáta položke *Validation and Testing*. V položke *Training Parameters* nastavíme počet epoch *epochs*, hodnotu účelovej funkcie, ktorú chceme dosiahnuť *Goal* a tiež hodnotu minima gradientu účelovej funkcie *Min_grad*. Parameter *Show* udáva v akých epochách sa bude graf obmieňať, hodnota je prednastavená na 25. Parametre *mu*, *mu_dec*, *mu_inc*, *mu_max* súvisia s parametrom η vystupujúci v Levenberg Marquardtovej rovnici na výpočet zmeny hodnoty váh biasov.




Obr.1.12 Okno zobrazujúce položku *Training Parameters*.


Záložka *Adapt* obsahuje *Adapt Info* a *Adaption Parameters* zadávanie parametrov je totožné so zadávaním parametrov v položke *Train*. V tejto položke však nastavujeme parameter *Passes*, tento parameter je funkciou zhodný s funkciou *Epochs*.

Pred samotným spustením tréningu je vhodné reinitializovať váhy na iné hodnoty, túto operáciu vykonávame v položke *Reinitialize Weights*. Je však potrebné poznamenať, že samotné tréningovanie je založené na vhodných pokusoch. Parametre siete meníme a prestavujeme dovtedy pokiaľ sieť vykazuje čo najmenšiu chybu.


Simulate je ďalšia položka, pomocou ktorej je možné sieť simulovať. Simuluje sieť bez toho, aby sa exportovala do prostredia MATLAB-u. Na základe tejto vlastnosti je možné sieť trénovať a vylepšovať jej prvotné nastavenia.

Obr.1.13 Okno zobrazujúce položku *Adapt/Adaption Info*

Po natrénovaní siete získané sú výsledky zobrazené v grafickom prostredí *neural network toolboxu*. Po zvolení možnosti *Export* sa zobrazí nové okno, odkiaľ je možné nami zvolený získaný údaj exportovať do *Workspace* v MATLAB-e, príp. máme ďalšiu možnosť uloženia na disk PC voľbou *Save*. Pre ďalšie použitie siete v MATLAB-e je potrebné danú sieť vygenerovať ako simulinkový blok. Dosiahneme to pomocou príkazu `gensim`(názov siete, perióda vzorkovania).



Obr.1.14 Okno pre exportovanie údajov do Workspace v MATLAB-e



Obr.1.15 Vytvorená sieť ako simulinkový blok

Simulinkový blok je ďalej možné použiť prekopírovaním do pracovného listu.


1.2 Fuzzy systémy

Fuzzy logika je matematická metóda riadenia a regulácie. Fuzzy logika vychádza z teórie fuzzy množín a pravdepodobnosti. Je vyjadrením nepresných informácií vyskytujúcich sa v reálnom svete. Dôležitosť fuzzy logiky vyplýva z faktu, že väčšina spôsobov ľudského myslenia a predovšetkým myslenie zdravého rozumu, sú prirodzene približné. Slovo fuzzy znamená neostrý, matný, hmlistý, neurčitý [6].


Základný pojem fuzzy logiky je fuzzy množina (A). Je to množina prvkov $x \in X$ (tzv. univerzum), každý prvok má svoj priradený stupeň príslušnosti $\mu_A(x)$, v intervale $\langle 0,1 \rangle$. Matematický zápis je:

$$A = \{x, \mu_A(x) \mid x \in X\} \quad (1.6)$$


Funkcia príslušnosti je funkcia, ktorá každému prvku fuzzy množiny priradí stupeň príslušnosti. Základné tvary funkcií príslušnosti sú zobrazené na obr. 1.16 až 1.19.




Obr. 1.16 Trojuholníková funkcia
príslušnosti



Obr. 1.17 Lichobežníková funkcia
príslušnosti



Obr.1.18 Gaussova funkcia príslušnosti




Obr. 1.19 Zvonová funkcia príslušnosti

Ďalším základným pojmom fuzzy logiky je lingvistická premenná (Obr. 1.20). Je spojením symbolickej a číselnej formy vyjadrenia reality. Jej hodnoty sú výrazy nejakého jazyka. Hodnotu lingvistickej premennej môžeme interpretovať ako fuzzy množiny. Je charakterizovaná ako päťica


$$\langle Y, T(Y), X, G, M \rangle \quad (1.7)$$

kde Y je meno lingvistickej premennej, $T(Y)$ je množina slovných hodnôt lingvistickej premennej, X je univerzum jej hodnôt, G je gramatika, obsahujúca syntaktické pravidlá na vytváranie hodnôt lingvistickej premennej, $M : T(Y) \rightarrow F(X)$ je sémantické pravidlo, ktoré každej slovnej hodnote priradí fuzzy podmnožinu univerza X , čím sa definuje jej význam.



Obr. 1.20 Lingvistická premenná

Základné operácie s fuzzy množinami podľa [4], uvažujeme fuzzy množiny $A, B \in F(X)$ (Obr. 1.21)



Obr. 1.21 Fuzzy množiny A a B

- Prienik fuzzy množín A, B je fuzzy množina $A \cap B \in F(X)$ (Obr. 1.22) s funkciou príslušnosti


$$\mu_C = \mu_{A \cap B}(x) \equiv \min[\mu_A(x), \mu_B(x)] \quad (1.8)$$

- Zjednotenie fuzzy množín A, B je fuzzy množina $A \cup B \in F(X)$ (Obr. 1.23) s funkciou príslušnosti


$$\mu_D = \mu_{A \cup B}(x) \equiv \max[\mu_A(x), \mu_B(x)] \quad (1.9)$$

- Doplnok fuzzy množiny A je fuzzy množina $\bar{A} \in F(X)$ (Obr. 1.24) s funkciou príslušnosti


$$\mu_E = \mu_{\bar{A}}(x) \equiv 1 - \mu_A(x) \quad (1.10)$$



Obr. 1.22 Prienik fuzzy množín



Obr.1.23 Zjednotenie fuzzy množín




Obr.1. 24 Doplnok množiny

Základy fuzzy riadenia

Modely systémov sú postavené na základe vzťahu medzi vstupom a výstupom systému. Fuzzy modely toto pojetie pretransformujú do skupiny pravidiel. Lingvisticky popísaný model je vyjadrený ako skupina pravidiel AK – POTOM s neurčitým tvrdením. Je teda založený na znalostiach (Obr. 1.25) [4].

Fuzzy systém pri riadení

- predstavuje riadiaci alebo rozhodovací systém, alebo predstavuje model objektu riadenia
- umožňuje pracovať so systémami formou podobnou prirodzenému ľudskému jazyku a ľudskému uvažovaniu
- možnosť ľahko aplikovať znalosti (skúsenosti, intuíciu, technický cit ...) ľudského typu – „expertné znalosti“
- fuzzy veličiny sú kvantifikovateľné lingvistickými hodnotami (fuzzy množinami opísanými pomocou funkcií príslušnosti).



Obr. 1.25 Fuzzy systém

Fuzzy pravidlo je vyjadrené formou implikácie dvoch fuzzy výrokov ako:

AK <fuzzy výrok> POTOM <fuzzy výrok>


Prvý fuzzy výrok je množina, ktorou je často zložený výrok a nazýva sa predpoklad (antecedent), kde jednotlivé časti výrokov sú viazané logickými spojkami. Druhý fuzzy výrok je dôsledok (konsekvent). Množina všetkých pravidiel v danej aplikácii sa nazýva „báza pravidiel“.

Priebeh regulácie je ovplyvnený bázou pravidiel, zvolenými tvarmi funkcií príslušnosti a zvolenou metódou defuzzifikácie.

Fuzzifikácia je proces, v ktorom sa merané hodnoty vstupujúcich veličín priradujú do fuzzy množín na základe funkcií príslušnosti.


Inferenčný mechanizmus obsahuje dve časti. V jednej časti sa určuje výsledný stupeň príslušnosti každého pravidla. V druhej časti sa jednotlivé výsledky z predchádzajúcej časti zjednocujú. Uplatňujú sa všetky pravidlá, ktorých funkcie príslušnosti boli adresované.

Defuzzifikácia je proces, v ktorom sa aproximujú fuzzy množiny ostrou hodnotou výstupnej veličiny. Existujú rôzne metódy defuzzifikácie. Medzi dve najčastejšie používané metódy (Obr. 1.26) patria metódy ťažiska (výstupnú veličinu určia výpočtom ako najlepší kompromis) a metódy najvýznamnejšieho maxima (metódy hľadajúce prijateľné riešenie) [7].



Obr. 1.26 Základné metódy defuzzifikácie

Štruktúra fuzzy regulátorov je zobrazená na (Obr.1.27) a jeho základné časti sú fuzzifikácia, inferenčný mechanizmus a defuzzifikácia. Ich typ, vstupy, výstupy a báza pravidiel sa navrhujú na mieru danej aplikácie, ladenie a tvorba štruktúry sa uskutočňuje experimentálne na základe správania sa riadeného systému. Charakteristickým znakom fuzzy riadenia je možnosť použitia empirických znalostí človeka – operátora v riadenom systéme.




Obr.1.27 Štruktúra fuzzy regulátora

Parametre fuzzy regulátorov sa navrhujú pomocou vypozerovania činnosti operátora, automatizovaným generovaním fuzzy regulátora (na základe umelých neurónových sietí, genetických algoritmov a pod.), prepočtom z už navrhnutého iného typu


regulátora alebo experimentálne (pokus/omyl). Neexistuje všeobecná metóda, ktorá platí pre všetky typy procesov. Fuzzy regulátory sa používajú, ak sa nedajú použiť iné jednoduchšie algoritmy návrh regulátorov alebo keď klasické regulátory nevedia zabezpečiť požadovaný cieľ. Prípadne, ak nepoznáme model riadeného procesu, ale jeho správanie vieme opísať slovne, alebo ak nemáme k dispozícii presné merania, ale iba približné odhady o stavoch procesu.

Nevýhodou fuzzy regulátorov je ich veľký počet parametrov, na základe čoho je ich optimalizácia zložitá. Ich výpočty sú zložitejšie a majú väčšie hardwarové a softwarové požiadavky. Ďalšou nevýhodou je, že pri návrhu nie je k dispozícii univerzálne platná metodika a sú potrebné skúsenosti s riadením daného procesu a časovo náročné experimenty.

Fuzzy systémy sa dajú použiť v regulačnom obvode aj v inej funkcii ako spätnoväzbový regulátor, napríklad na kompenzáciu poruchových veličín (Obr. 1.28), na korekciu akčného zásahu regulátora (Obr. 1.29), ako dopredný regulátor (Obr. 1.30) a pod. Toto sa využíva napr. na potlačanie preregulovania, skrátenie doby regulácie a potlačenie porúch.




Obr. 1.28 Kompenzácia poruchovej veličiny



Obr. 1.29 Korekcia akčného zásahu klasického PID regulátora

Ak stav systému je A potom koriguj žiadanú hodnotu regulátora



Obr. 1.30 Dopredný regulátor realizovaný fuzzy logikou

1.3 Adaptívne riadenie

Adaptívne spätnoväzbové riadenie procesov je riadenie, ktoré sa prispôsobuje neznámym meniacim sa vlastnostiam riadeného procesu [8].

Principiálne adaptívne riadenie je realizovateľné rôznymi spôsobmi. A to, riadenie pomocou ST regulátorov, prípadne riadenie pomocou ST regulátorov založené na priebežnej explicitnej identifikácii riadeného procesu pomocou lineárnych dynamických modelov.

Je známych viacero dôvodov pre použitie ST regulátorov:

1. Zmeny pracovných režimov technologických procesov, ktoré sú nelineárne – lineárny dynamický model nelineárneho procesu je v každom pracovnom bode iný a pri riadení ho treba prispôbovať.
2. Zmeny fyzikálnych vlastností procesov – môžu byť zapríčinené starnutím materiálov, opotrebovaním materiálov a pod.
3. Eliminácia nemerateľných porúch, šumov procesov a nemodelovaných dynamických vlastností procesov.

ST systém je zložený z dvoch uzavretých obvodov, jeden uzavretý obvod tvorí lineárny riadený systém a lineárny spätnoväzbový regulátor. Pomocou druhého uzavretého regulačného obvodu sa nastavujú parametre regulátora a to na základe priebežného odhadu parametrov modelu. Syntézu ST regulátora môže byť urobená rôznymi metódami. Odhad parametrov sa realizuje pomocou metódy najmenších štvorcov.

Pri zahájení štartu adaptívneho regulátora je vhodné použiť vhodne zvolený nominálny regulátor, ktorý stabilizuje proces. Keď parametre skkonvergujú potom, je možné nominálny regulátor prepnúť na adaptívny regulátor používajúc niektorú z metód beznárazového prechodu. ST adaptívne riadenie je realizovateľné na základe diskretných a spojitých modelov.


Diskrétna adaptívne riadenie

Tento druh riadenia je založený na diskretnom modeli procesu (Obr.1.31). Zvolený algoritmus je zložený z troch krokov.

1. Odhad parametrov modelu procesu.
2. Výpočet parametrov regulátora na základe zvolenej návrhovej metódy.

3. Výpočet zo zákona riadenia a realizácia akčných zásahov do procesu. Následné opakovanie krokov v každej perióde vzorkovania.

V okamihoch vzorkovania sa realizuje identifikačný a riadiaci algoritmus. Získaná akčná veličina a identifikované parametre sa udržiavajú konštantné počas celej nasledujúcej periódy vzorkovania.




Obr. 1.31 Štruktúra ST diskrétného systému riadenia procesu

Spojité adaptívne riadenie procesov

Jeho realizácia je nasledovná: vlastné spätnoväzbové riadenie procesu je spojité (Obr. 1.32), prestavovanie regulátora je vykonávané na základe priebežnej identifikácie parametrov spojitého modelu procesu diskrétné. Vstupy identifikačného bloku sú vstupné a výstupné veličiny procesu a ich derivácie. Tieto hodnoty sa získajú na základe vhodne zvolených filtrov. Merané vstupné a výstupné veličiny vstupujú do týchto filtrov a ich vzorkované výstupy sú údaje pre identifikačný blok.

Algoritmus riadenia je realizovaný tiež v troch krokoch tak ako je to uvádzané v diskretnom adaptívnom riadení.



Obr. 1.32 Štruktúra ST spojitého systému riadenia procesu

Adaptívne riadenie využitím pravidla MIT

Základné pravidlo MIT:

$$\frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta} = -\gamma \varepsilon \frac{\partial \varepsilon}{\partial \theta} \quad (1.11)$$

kde γ je koeficient adaptačného zosilnenia (nastaviteľný parameter adaptácie) a výraz $\frac{\partial \varepsilon}{\partial \theta}$ predstavuje tzv. *citlivostnú deriváciu*, ktorá vyjadruje citlivosť zmeny ε od parametrov regulátora, θ je vektor parametrov, J je účelová funkcia.

1.4 Aplikácia umelých neurónových sietí pri riadení systémov.

V oblasti riadenia systémov podľa [8] je použitie neurónových sietí rozmanité, obmedzením môže byť jednotlivá štruktúra riadenia. Parametre siete predstavujú napr. dynamiku regulovanej sústavy alebo dynamiku regulátora. Základom pre použitie a dodatočný vývoj neurónových sietí je identifikácia neznámeho nelineárneho systému. Po identifikácii nasleduje návrh metódy pre riadenie a tvorba neurónového regulátora. Metódy pre riadenie regulátora rozdeľujeme do dvoch skupín: priama metóda riadenia, nepriama metóda riadenia.

Priama metóda riadenia

Tento typ metódy je špecifický tým, že neurónová sieť predstavuje samotný regulátor. Regulátor realizovaný touto metódou je vhodný pre riadenie systému, ktorého nároky na realizáciu neumožňujú zložité riešenie regulačného obvodu. Avšak návrh regulátora je zložitejší proces, a to z hľadiska opätovného zavedenia a trénovania siete pokiaľ dôjde k modifikácii parametrov systému.

Uvedené sú niektoré doposiaľ navrhnuté a využívané metódy:

- Priame inverzné riadenie
- Riadenie s vnútorným modelom
- Dopredné riadenie s inverzným modelom
- Optimálne riadenie.

Nepriama metóda riadenia

Základom tejto metódy je využitie neurónovej siete pre model systému, ktorý má byť riadený. V tomto prípade je model zvyčajne trénovaný skôr, ale regulátor je trénovaný on-line. Táto metóda je výhodnejšia vďaka svojej pružnosti pre väčšinu úloh riadenia.

Uvedené sú niektoré metódy nepriameho riadenia.

- Aplikácia okamžitej linearizácie na riadenie (aproximácia umiestnenia pólov, aproximácia minimálneho rozdielu)
- Nelineárne prediktívne riadenie.

1.4.1 Riadenie systémov pomocou priameho inverzného regulátora


Metóda bola navrhnutá ako jedna z prvých metód pre riadenie neznámych nelineárnych systémov. Predpokladom je, že regulovaná sústava je zapísaná nasledovne

$$y[t+1] = g[y[t], \dots, y[t-n+1], u[t], \dots, u[t-m]] \quad (1.12)$$

Následnou úpravou vzťahu získame vstupný vektor pre požadovanú neurónovú sieť regulátora, ktorá je zostavená zo žiadanej veličiny, aktuálnych a minulých hodnôt výstupnej a akčnej veličiny.

$$u[t] = g^{-1}[y[t+1], y[t], \dots, y[t-n+1], u[t], \dots, u[t-m]] \quad (1.13)$$

Potom inverzné riadenie systému je zobrazené na obr.1.33



Obr. 1.33 Inverzné riadenie systému

1.4.2 Použitie fuzzy systémov v riadení procesov

V prípade že hovoríme o priamom fuzzy riadení je podľa [9] fuzzy systém použitý ako prvok regulačného obvodu, ktorý priamo ovplyvňuje riadený objekt.

Vstupmi pri fuzzy riadení sú obyčajne:

- $e(t)$ alebo $y(t)$

- $\frac{de(t)}{dt}$ resp. $\Delta e(k)$ (de)
- $\frac{d^2e(t)}{dt^2}$ resp. $\Delta^2 e(k)$ (d^2e)
- $\int e(t)dt$ resp. $\sum e$ (Je).

Prípadne iné veličiny podľa typu aplikácie ako poruchy, žiadané hodnoty, pomocné informácie ...

Jeho výstupy sú vo forme:

- absolútnej (polohovej): výstup z FS je priamo $u(t)$ resp. $u(k)$
- alebo prírastkovej (rýchlostnej): výstup z FS je $\frac{du(t)}{dt}$ $\Delta u(k)$
- vstup do riadeného systému je $u(k) = u(k-1) + \Delta u(k)$
- Ťažisková defuzzifikácia

Ako už bolo uvedené v [10], integračná zložka je nevyhnutná súčasť regulačného obvodu. Avšak sú prípady, keď aj napriek jej prítomnosti výsledky nie sú dostatočné, či uspokojivé. A to najmä z hľadiska doby regulácie a preregulovania. Vyplýva to z charakteristiky adaptéra ako jednoduchého integračného člena, ako aj z nesprávneho časovania adaptácie.

Vhodným spôsobom riešenia tohto problému je spojenie regulátorov použitím UNS a fuzzy regulátorov. Fuzzy regulátory pomocou fuzzifikácie, vhodného spôsobu odvodzovania záverov a defuzzifikácie priradujú hodnotám veličín sledovaných na vstupe hodnoty veličín sledovaných na výstupe.


1.4.3 Robustné riadenie s použitím neurónovej siete

Zabezpečenie zamedzenia vzniku TRO je potrebné regulátor upraviť, tak aby sa získala presná inverzia systému. Pomocou adaptácie prahových neurónov je možné nastavovať výstup z neurónovej siete. Predpoklad, že príčinou odchýliek výstupu zo systému a žiadanej hodnoty je nesprávna hodnota vstupu do prahového neurónu inverzného regulátora. Na základe tohto faktu je možné predpokladať, že jeho správnym nastavením možno túto TRO odstrániť. Vhodným signálom pre nastavenie vstupu je integrál TRO. Pokiaľ bude existovať TRO, výstup z adaptéra sa bude meniť a tým sa bude inverzný regulátor adaptovať. TRO dosiahne nulovú hodnotu, v takom prípade sa adaptácia

zastaví a neurónový regulátor je možné predpokladať za presnú inverziu dopredného modelu systému. Takto opísaný adaptér predstavuje jednoduchý integračný člen.

$$B = 1 + \beta \sum (w - y) \quad (1.14)$$

B predstavuje vstup do prahového neurónu, w je žiadaná hodnota, y je výstup z riadeného systému a β adaptačné zosilnenie.



Obr. 1.34 Adaptívny regulačný obvod s inverzným neurónovým regulátorom

1.4.4 Neurčitosti systémov

Pri návrhu takmer každého priemyselného procesu je snaha o vytvorenie najjednoduchšieho modelu procesu, či už z ekonomického, alebo praktického hľadiska. V takomto prípade však dochádza pri jeho tvorbe takmer vždy k vzniku neurčitostí. K ich vzniku dochádza najmä v zanedbaní niektorých vlastností, ktoré neplnia podstatnú úlohu v procese. Jedná sa predovšetkým o oblasť rýchlych dynamických javov, nelinearit či časovo premenných charakteristík procesu. V prípade lineárnych systémov je taktiež dokázateľná prítomnosť neurčitostí, pretože fyzikálne parametre nie sú nikdy známe presne, prípadne sa môžu na prevádzkových podmienkach meniť. Zásadným problémom je či regulátor, ktorý bude navrhnutý, si zachová určité požadované vlastnosti regulačného obvodu aj pre systém reálny, ktorý spadá do istého okolia nominálneho systému.

1.5 Opis nelineárneho modelu prietokového biochemického reaktora

V práci je uvedený nelineárny systém, ktorý je použitý pri rôznych druhoch riadenia systému. Nelineárny systém predstavuje model bioprocesu popisujúci rast kultúry *Saccharomyces* na glukóze v biochemickom prietokovom reaktore. Použitý matematický model bol získaný z práce [11].

Použité symboly:

$c_i \text{ mol.l}^{-1}$	koncentrácia
$D \text{ h}^{-1}$	zried'ovacia rýchlosť
f_{ic}	faktor indukcie alebo potlačenia
$k_i \text{ mol.l}^{-1}$	saturačná konštanta
$k_I \text{ mol.l}^{-1}$	inhibičná konštanta
$k_m \text{ mol.l}^{-1}$	saturačná konštanta substrátu
$k_n \text{ mol.l}^{-1}$	saturačná konštanta glukózy
$k_{La} \text{ h}^{-1}$	objemový koeficient prenosu na objem kvapaliny
$m \text{ mol.mol}^{-1}$	distribučný koeficient plyn – kvapalina
$Q_i \text{ mol..C.mol.DW}^{-1} \text{ h}^{-1}$	špecifická rýchlosť spotreby, alebo produkcie
$q \text{ l.h}^{-1}$	prietoková rýchlosť
$Y_{ij} \text{ mol.mol}^{-1}$	koeficient výťažku
$V \text{ l}$	objem
$\mu \text{ h}^{-1}$	špecifická rýchlosť rastu
$\tau_i \text{ h}$	časová konštanta

Zoznam indexov:

c	oxid uhličitý CO ₂	o	kyslík
e	etanol	ox	oxidácia
g	plynná fáza	p	parameter symetrie rastu
I	inhibícia	pr	produkcia
i	komponent i	red	redukcia
in	vstup	s	substrát
l	kvapalina	x	biomasa
lim	limitná kapacita		
max	maximum		

Kinetický model procesu

Mechanizmus	Rovnica
Spotreba glukózy	$Q_s = Q_{s,max} \frac{c_s}{k_s + c_s}$
Oxidačná kapacita	$Q_{o,lim} = Q_{o,max} \frac{c_o}{k_o + c_o}$
Oxidačný metabolizmus glukózy	$Q_s = \min \left\{ \frac{Q_s}{Y_{os} \cdot Q_{o,lim}} \right\}$
Redukčný metabolizmus glukózy	$Q_{s,red} = Q_s - Q_{s,ox}$
Spotreba etanolu	$Q_e = Q_{e,max} \frac{c_e}{k_e + c_e} \frac{k_I}{k_I + c_s}$
Oxidačný metabolizmus etanolu	$Q_{e,ox} = \min \left\{ \frac{Q_e}{Y_{oe} \cdot [Q_{o,lim} - Q_{s,ox} \cdot Y_{so}]} \right\}$
Produkcia etanolu	$Q_{s,pr} = Y_{se} \cdot Q_{s,red}$
Rast	$\mu = Y_{sx}^{ox} \cdot Q_{s,ox} + Y_{sx}^{red} \cdot Q_{s,red} + Y_{ex} \cdot Q_e$
Produkcia CO ₂	$Q_c = Y_{sx}^{ox} \cdot Q_{s,ox} + Y_{sx}^{red} \cdot Q_{s,red} + Y_{ec} \cdot Q_e$
Spotreba O ₂	$Q_o = Y_{so} \cdot Q_{s,ox} + Y_{eo} \cdot Q_{s,ox}$
Prenos O ₂	$Na = k_L a \left[\frac{c_g}{m} - c_o \right]$
Maximálna rýchlosť spotreby	$\frac{dQ_{i,max}}{dt} = \frac{1}{\tau_i} [Q_{i,max}^p f_{ic} - Q_{i,max}]$
Indukčné alebo represívne faktory sú definované nasledovne:	$f_{oc} = \frac{c_o}{k_o + c_o} \frac{2 \cdot c_s + c_e}{k_m [2 \cdot c_s + c_e]}$ $f_{sc} = \frac{c_s}{k_n + c_s}$ $f_{ec} = \frac{c_e}{k_e + c_e} \frac{k_I}{k_I + c_s} \frac{c_o}{k_o + c_o}$

Dynamický model procesu

Koncentrácia biomasy

$$\frac{dc_x}{dt} = D_l [c_{x,in} - c_x] + \eta \cdot c_x \quad (1.15)$$

Koncentrácia glukózy (substrátu)

$$\frac{dc_s}{dt} = D_l [c_{s,in} - c_s] - Q_s c_x \quad (1.16)$$

Koncentrácia etanolu (produktu)

$$\frac{dc_e}{dt} = D_l [c_{e,in} - c_e] + Q_{e,pr} - Q_e c_x \quad (1.17)$$

Koncentrácia oxidu uhličitého

$$\frac{dc_c}{dt} = D_g [c_{c,in} - c_c] + Q_c c_x \quad (1.18)$$

Koncentrácia rozpusteného kyslíka

$$\frac{dc_o}{dt} = D_g [c_{o,in} - c_o] + Na - Q_o c_x \quad (1.19)$$

Koncentrácia plynnej fázy kyslíka

$$\frac{dc_g}{dt} = D_g [c_{g,in} - c_g] + Na \frac{V_l}{V_g} \quad (1.20)$$

$$\text{kde} \quad D_l = \frac{q_l}{V_l} \quad \text{a} \quad D_g = \frac{q_g}{V_g} \quad (1.21), (1.22)$$

Počiatkové podmienky

$$c_{x,0} = 0,001 \text{ Cmol.l}^{-1}$$

$$c_{c,0} = 0,00155 \text{ mol.l}^{-1}$$

$$c_{s,0} = 0,000242 \text{ mol.l}^{-1}$$

$$c_{o,0} = 0,00000243 \text{ mol.l}^{-1}$$

$$c_{e,0} = 0,001 \text{ mol.l}^{-1}$$

$$c_{g,0} = 0,0000872 \text{ mol.l}^{-1}$$

2. Experimentálna časť


2.1 Riadenie nominálneho a perturbovaného lineárneho systému

2.1.1 Riadenie systému inverzným regulátorom.

Použitý lineárny systém bol definovaný prenosom $G_s = \frac{2}{2,89s^2 + 8,5s + 1}$. Prenos systému bol experimentálne stanovený, spĺňajúc základnú požiadavku a to fyzikálnu realizovateľnosť. Na riadenie nominálneho a perturbovaného systému bola navrhnutá inverzná neurónová sieť so štruktúrou {3,4,1} znamená to, že na vstupnej vrstve boli 3 neuróny, na skrytej vrstve 4 a na výstupnej vrstve bol 1 neurón. Ako vstupné dáta boli použité, hodnota aktuálneho výstupu $y(t)$, jeho prvá história $y(t-1)$ a prvá história hodnoty vstupu $u(t-1)$, výstup siete bola aktuálna hodnota vstupu $u(t)$. Sieť bola trénovaná off-line s počtom epoch 1000 a chyba trénovania bola menšia ako $1 \cdot 10^{-4}$. Trénovacie dáta sa získali zo sledovania dynamiky uvedeného lineárneho systému pri náhodných hodnotách vstupnej veličiny v intervale $\langle 1,3 \rangle$. Interval je zadaný na základe zvolených vstupných hodnôt. Perióda vzorkovania bola 0,5. Sieť bola natrénovaná pomocou grafického prostredia Neural Network Toolboxu ako je popísané v kapitole 1.1.4. Navrhnutá neurónová sieť bola vložená do uzavretého regulačného obvodu ako regulátor a riadenie nominálneho systému je uvedené na obr. 2.1


Robustnosť natrénovaného regulátora bola skúšaná taktiež na systéme definovaným vyššie uvedeným prenosom 2. rádu. Perturboval sa koef. tlmenia ζ a zosilnením systému Z .

Koeficient tlmenia bol ohraničený intervalom $\langle 1,7,2,9 \rangle$. Interval je zadaný v okolí hodnoty koeficienta tlmenia. Riadenie s perturbovaným koeficientom tlmenia systému je uvedené na obr. 2.1.



Obr.2.1 Riadenie nominálneho a perturbovaného lineárneho systému. Perturovaný systém sa získal zmenou koeficientu tlmenia.


V prípade perturbovaného zosilnenia bol interval v ohraničení ± 50 . Riadenie s perturbovaným zosilnením systému je uvedené na obr. 2.2.



Obr.2.2 Riadenie nominálneho a perturbovaného lineárneho systému. Perturovaný systém sa získal zmenou zosilnenia.


1.1.2 Riadenie systému inverzným regulátorom rozšíreným o I zložku ako fuzzy

Regulátor v tomto type riadenia bol použitý s predošlého riadenia, čiže spôsob a typ tréningu je totožný. Regulátor bol rozšírený o integračnú zložku a to v podobe fuzzy. Pridaním I zložky sa dosiahlo doladenie regulátora a odstránenie trvalej regulačnej odchýlky. Na základe vstupných a výstupných dát sa nastavili intervaly fis matice, funkcie príslušnosti a určili jednotlivé fuzzy pravidlá.



Obr. 2.3 Riadenie nominálneho a perturbovaného inverzného regulátora rozšíreného o integračnú zložku. Perturovaný systém so zmenou koeficientu tlmenia.



Perturboval sa koeficientom tlmenia ζ a zosilnením systému Z . Koeficient tlmenia bol ohraničený intervalom $\langle 1.7, 2.9 \rangle$ a perturbácia zosilnenia bola v ohraničení $\pm 50\%$. Riadenie nominálneho a perturbovaného inverzného regulátora rozšíreného o integračnú zložku v prípade perturbovaného systému so zmenou koeficientu tlmenia je uvedené na obr. 2.3 a perturbovaný systém so zmenou zosilnenia je na obr.2.4




Obr. 2.4 Riadenie nominálneho a perturbovaného inverzného regulátora rozšíreného o integračnú zložku. Perturovaný systém so zmenou zosilnenia.

2.1.3 Riadenie systému regulátorom s robustnými vlastnosťami.

Tak, ako bolo rozoberané v kapitole 1.4.4, nedostatok v podobe trvalej regulačnej odchýlky je možné odstrániť adaptáciou prahového koeficienta výstupného neurónu. Navrhnutý adaptačný koeficient sa vhodne volil tak, aby pri riadení nevznikla trvalá regulačná odchýlka. Pri zvolenej väčšej hodnote adaptačného koeficientu bolo riadenie rýchlejšie, avšak nevýhodou bolo rozkmitanie sa systému. Priebehy riadenia nominálneho systému so zmenou hodnoty β v intervale $\langle 0,0005, 0,004 \rangle$ sú uvedené na obr.2.5. Interval je zvolený na základe experimentálnych znalostí. Perturbácia systému je totožná s predošlými typmi riadenia. Riadenie perturbovaného systému so zvolenou najvhodnejšou hodnotou adaptačného koeficienta $\beta=0,002$ je uvedená na obr. 2.6 a obr.2.7


Obr. 2.5 Riadenie nominálneho robustného regulátora so zmenou hodnoty β .

Obr. 2.6 Riadenie nominálneho a perturbovaného robustného regulátora.. Perturbovaný systém so zmenou koeficientu tlmenia




Obr. 2.7 Riadenie nominálneho a perturbovaného robustného regulátora.. Perturbovaný systém so zmenou zosilnenia.

2.1.4 Riadenie systému adaptívnym regulátorom



Obr. 2.8 Riadenie nominálneho a perturbovaného adaptívneho regulátora.. Perturbovaný systém so zmenou koeficientu tlmenia.

Adaptívny regulátor sa nastavoval pomocou priebežnej spojitej identifikácie systému. Identifikácia bola robená na základe metódy najmenších štvorcov pomocou toolboxu lddif. Perturovaný systém je totožný s predošlými typmi riadenia. Riadenie je uvedené na obr.2.8



Obr. 2.9 Riadenie nominálneho a perturbovaného adaptívneho regulátora.. Perturovaný systém so zmenou zosilnenia.


2.2 Riadenie nominálneho a perturbovaného nelineárneho systému

Použité symboly sú vysvetlené v časti 1.5. Údaje a symboly sú čerpané na základe odporúčaní z už vytvorenej práce [11].

2.2.1 Riadenie systému inverzným regulátorom.


Použitý nelineárny systém biochemický prietokový reaktor je bližšie popísaný v kapitole 1.5. Na riadenie nominálneho a perturbovaného systému bola navrhnutá inverzná neurónová sieť so štruktúrou {5,6,4,1}. Znamená to, že na vstupnej vrstve bolo 5 neurónov, na prvej skrytej vrstve 6, na druhej skrytej vrstve 4 a na výstupnej vrstve bol 1 neurón. Ako vstupné dáta boli použité, hodnota aktuálneho výstupu $y(t)$, jeho prvá história $y(t-1)$, jeho druhá história $y(t-2)$ a prvá história hodnoty vstupu $u(t-1)$, druhá história vstupu $u(t-2)$ výstup siete bola aktuálna hodnota vstupu $u(t)$.

Sieť bola trénovaná off-line s počtom epoch 1000. Trénovacie dáta sa získali zo sledovania dynamiky uvedeného nelineárneho systému pri náhodných hodnotách vstupnej veličiny v intervale $<4 \cdot 10^{-6}, 1.2 \cdot 10^{-5}>$. Perióda vzorkovania bola 0,5. Sieť bola natrénovaná pomocou grafického prostredia Neural Network Toolboxu ako je popísané v kapitole 1.1.4. Navrhnutá neurónová sieť bola vložená do uzavretého regulačného obvodu ako regulátor a riadenie nominálneho systému je uvedené na obr. 2.10




Obr. 2.10 Riadenie nominálneho systému inverzným neurónovým regulátorom


Robustnosť natrénovaného regulátora bola skúšaná taktiež na systéme definovaným vyššie uvedeným modelom. Perturovaný systém vznikol zmenou parametrov, koncentrácia substrátu na vstupe $c_{s,in}$, zmenou zried'ovacej rýchlosti D_l a zmenou saturačnej konštanty substrátu k_s . Zmena perturbácie bola v rozmedzí $\pm 20\%$ perturbovanej veličiny. Riadenie perturbovaných systémov je na obr. 2.11 až 2.13.



Obr. 2.11 Riadenie nominálneho a perturbovaného systému inverzným neurónovým regulátorom. Perturovaný systém je vytvorený zmenou $c_{s,in}$, v rozmedzí $\pm 20\%$.




Obr. 2.12 Riadenie nominálneho a perturbovaného systému inverzným neurónovým regulátorom. Perturovaný systém je vytvorený zmenou D_I , v rozmedzí $\pm 20\%$.




Obr. 2.13 Riadenie nominálneho a perturbovaného systému inverzným neurónovým regulátorom. Perturbovaný systém je vytvorený zmenou k_s , v rozmedzí $\pm 20\%$.

2.2.2 Riadenie systému inverzným regulátorom rozšíreným o I zložku ako fuzzy


Regulátor v tomto type riadenia bol použitý s predošlého riadenia, čiže spôsob a typ tréovania je totožný. Regulátor bol rozšírený o integračnú zložku a to v podobe fuzzy. Pridaním I zložky sa dosiahlo doladenie regulátora a odstránenie trvalej regulačnej odchýlky. Na základe vstupných a výstupných dát sa nastavili intervaly fis matice, funkcie príslušnosti a určili jednotlivé fuzzy pravidlá. Perturbovaný systém je totožný s vyššie uvedeným. Riadenie nominálneho a perturbovaného systému je uvedené na obr. 2.14 až 2.16.



Obr. 2.14 Riadenie nomin. a perturbovaného systému inverzným neurónovým regulátorom rozš. o I zložku ako fuzzy. Perturbovaný systém je vytvorený zmenou $c_{s,in}$, v rozmedzí $\pm 20\%$.




Obr. 2.15 Riadenie nominálneho a perturbovaného systému inverzným neurónovým regulátorom rozšíreným o I zložku ako fuzzy. Perturbovaný systém je vytvorený zmenou D_I , v rozmedzí $\pm 20\%$.




Obr. 2.16 Riadenie nominálneho a perturbovaného systému inverzným neurónovým regulátorom rozšíreným o 1 zložku ako fuzzy. Perturbovaný systém je vytvorený zmenou k_s , v rozmedzí $\pm 20\%$.

2.2.3 Riadenie systému regulátorom s robustnými vlastnosťami.




Obr. 2.17 Riadenie nominálneho a perturbovaného systému robustným regulátorom. Perturbovaný systém je vytvorený zmenou $c_{s,in}$, v rozmedzí $\pm 20\%$.

Princíp robustného regulátora pri nelineárnom systéme je rovnaký s lineárnym systémom. Perturovaný systém je rovnaký s vyššie uvedeným. Riadenie nominálneho a perturovaného systému je uvedené na obr. 2.17 až 2.19.



Obr. 2.18 Riadenie nominálneho a perturovaného systému robustným regulátorom.

Perturovaný systém je vytvorený zmenou D_I , v rozmedzí $\pm 20\%$.




Obr. 2.19 Riadenie nominálneho a perturovaného systému robustným regulátorom.

Perturovaný systém je vytvorený zmenou k_s , v rozmedzí $\pm 20\%$.


2.2.4 Riadenie systému adaptívnym regulátorom.

V prípade adaptívneho regulátora v nelineárnom systéme platí to isté ako v prípade lineárneho systému. Perturovaný systém je totožný s predošlými typmi riadenia. Riadenie je uvedené na obr.2.20 až obr. 2.22




Obr. 2.20 Riadenie nominálneho a perturovaného systému adaptívnym regulátorom.

Perturovaný systém je vytvorený zmenou $c_{s,in}$ v rozmedzí $\pm 20\%$.



Obr. 2.21 Riadenie nominálneho a perturovaného systému adaptívnym regulátorom.

Perturovaný systém je vytvorený zmenou D_I v rozmedzí $\pm 20\%$.




Obr. 2.22 Riadenie nominálneho a perturbovaného systému adaptívnym regulátorom.

Perturbovaný systém je vytvorený zmenou k_s , v rozmedzí $\pm 20\%$.

2.3 Porovnanie použitých regulátorov v nelineárnych a lineárnych systémoch.

Porovnanie jednotlivých riadení v nelineárnom systéme




Obr. 2.23 Porovnanie riadenia nominálneho systému vo všetkých typoch riadenia.

Tabuľka 1. Intergrálne kritéria kvality pri riadení nelineárneho systému

	ISE	IAE
Neuro-fuzzy regulátor	$8,1682 \cdot 10^{-11}$	$3,7176 \cdot 10^{-5}$
Regulátor s robustnými vlastnosťami	$7,8852 \cdot 10^{-11}$	$4,6221 \cdot 10^{-5}$
Adaptívny regulátor	$5,5653 \cdot 10^{-11}$	$3,3510 \cdot 10^{-5}$

Porovnanie jednotlivých riadení v lineárnom systéme



Obr. 2.24 Porovnanie riadenia nominálneho systému vo všetkých typoch riadenia.

Tabuľka 2. Integrálne kritéria kvality pri riadení lineárneho systému

	ISE	IAE
Inverzný neurónový regulátor	20,6559	32,2875
Neuro-fuzzy regulátor	17,1351	27,3128
Regulátor s robustnými vlastnosťami	20,4647	31,8707
Adaptívny regulátor	4,1096	8,9599

ZÁVER

Diplomová práca je venovaná problematike modelovania a riadenia procesov pomocou umelých neurónových sietí. Zaoberá sa návrhom a tvorbou siete a tiež porovnaním s klasickým typom adaptívneho riadenia.

V grafickom prostredí Neural network toolboxu bola navrhnutá a vytvorená neurónová sieť, ktorá bola použitá pri riadení inverzným regulátorom, inverzným regulátorom rozšíreným o fuzzy zložku ako integračnú a regulátorom s robustnými vlastnosťami. Popis tvorby a návrhu siete rozšíreným o reálne obrázky sú v kapitole 1.1.4. Prednosť grafického prostredia pre návrh UNS je v jeho jednoduchosti, pretože nie je potrebná väčšia znalosť programovania, či znalosť samotných vyvolávacích príkazov. Ďalším významným pozitívom je jednoduchý export či import potrebných údajov z workspace v MATLAB-e

Navrhnutá neurónová sieť bola použitá v riadení nominálneho a perturbovaného lineárneho systému 2. rádu a nelineárneho systému biochemického prietokového reaktora. Umelá neurónová sieť predstavovala inverzný model systému, ktorý sa použil ako spätnoväzbový nominálny neurónový regulátor.

Nominálny neurónový regulátor sa použil tak pri riadení nominálneho, ako aj perturbovaného lineárneho systému. Riadenie nominálneho systému bolo poznačené zanechaním trvalej regulačnej odchýlky. V prípade perturbovaného systému, ktorý sa nastavil zmenou koeficientu tlmenia a zmenou zosilnenia, vykazoval systém rovnakú trvalú regulačnú odchýlku. Jej veľkosť však bola zanedbateľne malá. Trvalá regulačná odchýlka bola odstránená rozšírením inverzného regulátora o integračnú zložku v podobe fuzzy regulátora. Vďaka tejto integračnej zložke bola odstránená TRO pri nominálnom aj perturbovanom systéme.

Adaptácia výstupu neurónovej siete cez výstupný neurón, predstavoval ďalší typ riadenia uvedený v práci, a to regulátor s robustnými vlastnosťami. Postupným nastavovaním a zadávaním adaptačného koeficientu sa dosiahlo taktiež odstránenie TRO. Pri vyšších hodnotách adaptačného koeficienta bol priebeh riadenia kmitavejší ako pri nižších hodnotách adaptačného koeficienta. Ale pri nižších hodnotách adaptačného koeficienta doba regulácie bola vyššia. So zmenou zosilnenia v perturbovanom systéme vznikla zanedbateľne malá TRO. Z hľadiska použitia adaptívneho riadenia je možné

konštatovať, že riadenie je kmitavejšie než pri predchádzajúcich metódach a z tohto dôvodu dlhšiu dobu regulácie.

Pri nelineárnom modeli prietokového biochemického reaktora bola neurónová sieť natrénovaná obdobným spôsobom ako v prípade lineárneho systému. Inverzný neurónový regulátor pri riadení nominálneho a perturbovaného systému javí väčšiu TRO, ale s prihliadnutím na rozsah výstupných hodnôt je tiež pomerne nízka. Vo všeobecnosti sa však dá konštatovať, že vzniknuté rozdiely medzi nominálnymi a perturbovanými systémami sú väčšie, čo môže byť spôsobené iným vzťahom perturbácie k riadenému systému. Pri menších zmenách perturbovaného systému reakcia riadeného systému bola výraznejšia ako v prípade lineárneho systému.

Grafickým porovnaním jednotlivých typov riadenia s použitím umelej neurónovej siete a adaptívneho riadenia bolo použitie umelej neurónovej siete výhodné vzhľadom na periodicitu a dobu regulácie. Na základe integrálnych kritérií kvality, tabuľka 1 a 2, vhodným typom je adaptívne riadenie. S ohľadom na obidve možnosti porovnania výhodným typom riadenia v prípade nominálneho lineárneho aj nelineárneho systému bol inverzný regulátor rozšírený o integračnú zložku ako fuzzy regulátor. V prípade perturbovaných systémov bolo výhodné riadenie regulátorom s robustnými vlastnosťami. V práci je rozpracovaných niekoľko riadení s použitím umelej neurónovej siete, rozsah použitia neurónovej siete otvára množstvo možností pre ďalšiu prácu na tomto projekte.

LITERATÚRA

- [1]. Sinčák P., Andrejková G., 1996, Neurónové siete I (Inžiniersky prístup). [online]. Košice: FEI TU, PF UPJS Dostupné na internete: <http://www.ai-cit.sk/source/publications/books/NS1/html/all.html>
- [2]. Kvasnička, V. *História neurónových sietí a inšpirácie z neurobiológie*. <http://www2.fiit.stuba.sk/~kvasnicka/CognitiveScience/2.prednaska/Neuronove%20siete-kapitola01.pdf>.
- [3]. Kvasnička, V., Beňušková, Ľ., Farkaš, I., Kráľ, A., Pospíchal, J. a Tiňo, P.: *Úvod do teórie neurónových sietí*. IRIS, Bratislava, 1997.
- [4]. Sekaj I. *Fuzzy a neurónové systémy*. FEI STU v Bratislave.
- [5]. Drábek O., Seidl P. a Taufer I. Umělé neuronové sítě – základy teorie a aplikace (4). CHEMagazín, 2 (XVI), 2006, s. 33-36. ISSN 1210-7409
- [6]. Kolesárová, A. a Kováčova, M. *Fuzzy množiny a ich aplikácie*. Vydavateľstvo STU v Bratislave, 2004.
- [7]. Modrlák O. *Fuzzy řízení a regulace*. FM TU Liberec, 2004.
- [8]. Mikleš, J. a Fikar, M. [Modelovanie, identifikácia a riadenie procesov 2.](#), STU PRESS, Bratislava, 2004.
- [9]. Sekaj I., Fuzzy a neurónové systémy. [online]. Bratislava: FEI STU. Dostupné na internete: <http://www.kasr.elf.stuba.sk/predmety/fnr/>
- [10]. Mészáros, A.; Andrášik, A.; Šperka, Ľ.: Influence of the adaptation gain on robust neural control. In *Proc. 5th International Scientific Technical Conference on Process control*. Kouty nad Desnou, 2002.
- [11]. Šperka, Ľ.: Identifikácia a riadenie systémov pomocou umelých neurónových sietí. *Diplomová práca*. FCHPT STU, Bratislava, 2001.
- [12]. Mészáros, A., Vöröš, J. Design of Intelligent Controllers for Biotechnological Process. 2008.
- [13]. Šperka, Ľ., Mészáros, A., Mizsey, P., Andrášik, A. Control of pH in a laboratory fermenter using neuro-fuzzy logic technique. 2005.