

FAKULTA ELEKTROTECHNIKY A INFORMATIKY STU V BRATISLAVE

Študijný program Kybernetika



Bc. Juraj Vyskočil

Fuzzy-neuro a genetické prediktívne riadenie

Diplomová práca

Vedúci diplomovej práce: prof. Ing. Štefan Kozák, PhD.

Máj, 2007

Čestné prehlásenie:

Prehlasujem, že som túto prácu vypracoval sám a inú, ako uvedenú literatúru, som nepoužíval ani necitoval.

Bc. Juraj Vyskočil

V Bratislave dňa:

ANOTÁCIA

Slovenská technická univerzita v Bratislave
FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Študijný program: Kybernetika

Autor: Bc. Juraj Vyskočil

Diplomová práca: Fuzzy-neuro a genetické prediktívne riadenie

Vedúci diplomovej práce: prof. Ing. Štefan Kozák, PhD.

máj, 2007

Cieľom tejto práce bola integrácia viacerých moderných prístupov k riadeniu. Jadrom práce je použitie troch moderných metód: prediktívneho riadenia, fuzzy modelu ako interného modelu, a použitia genetických algoritmov ako optimalizačnej metódy. Poukázali sme na výhody použitia fuzzy modelov pri modelovaní nelineárnych dynamických systémov, na výhodu použitia substraktívnej zhlukovej analýzy pri ich tvorbe a doložili grafmi a simuláciami. Pri genetických algoritmoch sme načrtli ich základné vlastnosti a možnosť ich využitia v kontexte prediktívneho riadenia. V práci sú priložené porovnania efektívnosti a kvality prediktívneho riadenia oproti optimálnemu PID navrhnutého genetickými algoritmami.

Snahou autorov bolo vytvoriť komplexný koncept, ktorý by nebol samoúčelným združením uvedených metód, ale ktorý by ťažil z výhod každej svojej súčasti a zároveň by naznačil ďalšie smery vývoja.

Kľúčové slová: modelovanie nelineárnych procesov, fuzzy modelovanie, fuzzy zhluková analýza, substraktívna fuzzy zhluková analýza, genetické algoritmy, prediktívne riadenie

ANNOTATION

Slovak University of Technology in Bratislava
FACULTY OF ELECTRICAL ENGINEERING AND INFORMATION
TECHNOLOGY
Degree Course: Cybernetics

Author: Bc. Juraj Vyskočil
Diploma Thesis: Fuzzy-neuro and genetic predictive control
Supervisor: prof. Ing. Štefan Kozák, PhD.
2007, May

The aim of this thesis is to contribute to modern methods of controlling the nonlinear systems. The three main approaches described in this paper are predictive control, with fuzzy Takagi-Sugeno model used as internal model, and with genetic algorithms used as optimizing method. We pointed out the advantages of using fuzzy models in modelling of nonlinear dynamic systems and the strength of subtractive clustering in this operation. We supported our conclusions with graphs and simulations.

We also briefly described the main properties of the genetic algorithms and potentialities of their usage in the context of predictive controlling. Effectivity and quality comparisons of the predictive controlling compared to the optimal PID designed by genetic algorithms are attached.

The goal was a creation of the complex concept that is not just purposeless combination of methods mentioned above, but whose qualities emerge from the advantages of its individual constituents.

Keywords: Modelling of nonlinear processes, fuzzy modelling, fuzzy clustering, subtractive fuzzy clustering, genetic algorithms, predictive control

Vložit zadanie Diplomovej práce

Vložit zadanie Diplomového projektu

ANOTÁCIA – Diplomový projekt I

Slovenská technická univerzita v Bratislave
FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Študijný program: Kybernetika

Autor: Bc. Juraj Vyskočil

Diplomová práca: Fuzzy-neuro a genetické regulátory

Vedúci diplomovej práce: prof. Ing. Štefan Kozák, PhD.
máj, 2007

Diplomový projekt I sa zaoberá rozšírením znalostí o fuzzy modelovaní prostredníctvom fuzzy modelov typu Takagi – Sugeno z experimentálnych údajov. Zároveň bolo potrebné naštudovať metódy a princípy prediktívneho riadenia. Tie boli implementované a overované na jednoduchých lineárnych systémoch. Bol vytvorený základný predikčný algoritmus predikujúci hodnoty systému vo zvolenom predikčnom horizonte s použitím interného fuzzy Takagi – Sugeno modelu.

ANOTÁCIA – Diplomový projekt II

Slovenská technická univerzita v Bratislave
FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Študijný program: Kybernetika

Autor: Bc. Juraj Vyskočil

Diplomová práca: Fuzzy-neuro a genetické regulátory

Vedúci diplomovej práce: prof. Ing. Štefan Kozák, PhD.
máj, 2007

Diplomový projekt II sa zaoberá rozširovaním algoritmu prediktívneho riadenia. Bola pridaná možnosť zadať do prediktívneho riadenia ľubovoľnú dĺžku horizontu riadenia. Ďalej bolo treba naštudovať problematiku genetických algoritmov a možnosti a výhody ich implementácie ako negradientných optimalizačných metód do algoritmu prediktívneho riadenia.

ANOTÁCIA – Bakalárska práca

Slovenská technická univerzita v Bratislave
FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Študijný program: Kybernetika

Autor: Juraj Vyskočil

Bakalárska práca: Fuzzy clustering v neuro-fuzzy modelovaní nelineárnych systémov

Vedenie bakalárskej práce: prof. Ing. Štefan Kozák, PhD.

Rok odovzdania : 2005

Táto práca sa zaoberala problémom modelovania nelineárnych systémov metódou zhlukovej analýzy (fuzzy clustering) na základe ich vstupno-výstupných údajov, špeciálne v prípadoch neúplných dát, keď je k dispozícii len malé množstvo nameraných vzoriek a v malom pracovnom rozsahu, čo sú podmienky, kedy nemôže byť použitá neurónová sieť. Táto metóda je založená na rozklade vstupných dát na zhluky, v ktorých sú si dáta v istom zmysle podobné. Na základe týchto zhlukov je vytvorený fuzzy model typu Takagi-Sugeno.

Simulácie ukázali veľmi dobré interpolačné vlastnosti tohto systému, ktorý je schopný veľmi dobre modelovať systém aj v pracovných oblastiach, v ktorých tréningové dáta neležali. Zároveň sa ukázala výborná robustnosť fuzzy zhlukovej analýzy pri zašumených dátach.

Kľúčové slová: modelovanie nelineárnych procesov, fuzzy modelovanie, fuzzy zhluková analýza, substraktívna fuzzy zhluková analýza

Obsah

1. Úvod	12
2. Prediktívne riadenie	13
2.1 Základný koncept	13
2.2 Optimalizačný algoritmus	13
2.3 Vlastnosti a problémy prediktívneho riadenia	14
3. Fuzzy modelovanie	16
3.1 Fuzzy množiny	16
3.2 Fuzzy pravidlá	16
3.3 Fuzzy aproximácia	17
3.4 Takagi – Sugeno (T-S) fuzzy modely	18
3.5 Aproximácia funkcií T-S fuzzy modelmi	19
3.6 Lokálne modely	20
3.7 Substraktívna zhuková analýza	20
3.8 Nenáročnosť	21
3.9 Robustnosť	26
4. Genetické algoritmy	29
4.1 Princípy GA	29
4.2 Klasické metódy	29
4.3 Výhody GA	30
4.4 GA v prediktívnom riadení	32
5. Integrácia moderných metód	34
5.1 Porovnanie prediktívneho riadenia a PID regulácie	36
5.2 Časová a výpočtová náročnosť	40
5.3 Kompenzácia poruchy	41
6. Aplikačný systém	44
7. Záver	47

Zoznam skratiek

FNS	Fuzzy-Neurónový Systém
RBF	Radial Basis Function
ANFIS	Adaptive Neuro Fuzzy Inference System
HCM	Hard C-means
FCM	Fuzzy C-means
T-S	Takagi-Sugeno
QP	Kvadratické programovanie
H	Hesseho matica
GA	Genetický algoritmus
VT	Výpočtová technika
MPL	Viacvrstvová neurónová sieť
SP	Set point, hodnota žiadanej veličiny
GUI	Graphics User Interface

1. Úvod

S nástupom a rozvojom výpočtovej techniky sa popri klasických riadiacich metódach otvára priestor pre nové prístupy v riadení, z ktorých mnohé boli dlhé roky iba teóriou na papieri, pretože neexistovala dostatočná výpočtová sila, ktorá by splnila ich nároky. Rastúci výkon a dostupnosť umožňujú ich širšie skúmanie a použitie, a ich efektívnosť sa prejavuje predovšetkým pri zložitých a ťažko riaditeľných nelineárnych systémoch, pri ktorých sú klasické riadiace metódy málo účinné, alebo je nutné robiť rôzne zjednodušenia a kompromisy.

Táto práca sa zaoberá možnosťami, ktoré nám niektoré metódy využívajúce výpočtovú silu ponúkajú.

Prvou z nich je prediktívne riadenie. Je popísaný základný koncept prediktívneho prístupu k riadeniu, jeho vlastnosti a výhody.

Druhou metódou, ktorou sa zaoberá táto práca, je tvorba fuzzy modelov nelineárnych dynamických systémov. Popísaný je princíp fuzzy aproximácie nelineárnych funkcií, typ Takagi-Sugeno fuzzy modelu, systému pravidiel AK – POTOM, ich robustnosť a poukázanie na silu substraktívnej zhlukovej metódy pri vytváraní fuzzy modelov.

Genetické algoritmy predstavujú veľmi výkonný optimalizačný algoritmus. V tejto práci sa snažíme ukázať možnosti využitia ich vlastností v použití pri prediktívnom riadení.


Na záver sú ukázané porovnania efektivity riadenia prediktívneho riadenia oproti efektivite optimálneho PID regulátora nastaveného genetickými algoritmami.

2. Prediktívne riadenie

2.1 Základný koncept

Myšlienka prediktívneho riadenia vznikla zhruba pred tromi desiatkami rokov. Existuje veľké množstvo jej variácií, postupov a stratégií, ktorých spoločným menovateľom je určenie optimálneho riadiaceho zásahu do riadeného systému.

Princíp prediktívneho riadenia spočíva v tom, že výpočet riadiaceho zásahu nie je daný iba parametrami systému v čase vzorkovania, ale riadiaci systém zohľadňuje chovanie riadeného systému v blízkej budúcnosti. Pred každým akčným zásahom regulátor vypočíta podľa svojho interného modelu, ako sa systém za daných podmienok bude chovať, a tomu prispôsobí veľkosť akčného zásahu.



Obr. 1. Priebehy veličín pri prediktívnom riadení

Počet vzorkovacích periód, v rámci ktorých počíta správanie systému, sa nazýva *predikčný horizont*. Počet dopredu vypočítaných akčných zásahov sa nazýva *horizont riadenia*.

Akčný zásah resp. séria akčných zásahov v rozsahu riadiaceho horizontu je určená výsledkom optimalizačnej úlohy. V prípade výpočtu viacerých akčných zásahov je použitý v nasledovnej vzorkovacej perióde prvý zásah, a pri ďalšom vzorkovaní je znovu vygenerovaná nová séria riadiacich zásahov. Pri každej vzorkovacej perióde tak prebieha vždy nová optimalizácia, ktorá nanovo určí optimálny riadiaci zásah.

2.2 Optimalizačný algoritmus

Súčasťou prediktívneho regulátora je preto optimalizačný algoritmus, ktorý minimalizáciou kritériálnej funkcie nájde optimálny akčný zásah. Kritériálna funkcia minimalizovaná pri prediktívnom riadení vyzerá v základnom tvare spravidla nasledovne:

$$\text{Min}_{u(t)} J = \text{Min}_{u(t)} \left\{ \sum_{i=N_1}^{N_2} \|r(t+i) - y(t+i)\|^2 + \sum_{i=0}^{N_u} \lambda_i \|u(t+i)\|^2 + \sum_{i=0}^{N_u} \lambda'_i \|\Delta u(t+i)\|^2 \right\} \quad (1)$$

kde v prvom súčtovom člene sa minimalizuje štvorec rozdielu medzi výstupom systému $y(t+i)$ a jeho želanou hodnotou $r(t+i)$, a v druhom a treťom člene sa s príslušnými váhami optimalizuje veľkosť akčného zásahu $u(t+i)$ a jeho kmitanie.

Základným princípom prediktívneho riadenia je tak nájdenie optimálnej série riadiaceho zásahu tak, že sa s použitím interného modelu predikujú budúce výstupy riadeného systému v rámci predikčného horizontu a nájde sa séria riadiacich zásahov, ktorým odpovedá optimálny výstup zo systému.

V praxi sa často optimalizuje konvexná kritériálna funkcia a používa sa kvadratické programovanie.

V súčasnosti je nasadenie prediktívneho riadenia časté napríklad v riadení chemických alebo tepelných systémov, ako sú ropné rafinérie, žihacie pece, cementárne, destilačné kolóny, továrne na výrobu PVC, parné generátory alebo chemické reaktory, ale aj v robotických aplikáciách či aplikáciách klinickej anestézie [14].

2.3 Vlastnosti a problémy prediktívneho riadenia

Je zrejmé, že použitie a vlastnosti prediktívneho riadenia sú dané tak typom systému, ako aj použitým typom interného modelu a typom optimalizačného algoritmu. V praxi sa často používa konvexná kritériálna funkcia a ako interný model sú používané často lineárne modely aj pri riadení nelineárnych procesov.

Podľa zdroja [14]:

- väčšina aplikácií prediktívneho riadenia je založená na *lineárnych* modeloch.
- tvorba lineárnych modelov je *jednoduchá*, a tieto lineárne modely stačia pre reguláciu nelineárneho systému v blízkom okolí pracovného bodu, čo je častejšia požiadavka v priemysle, než zmena žiadanej hodnoty riadenej veličiny v širokom rozsahu nelineárnej charakteristiky
- použitie lineárnych modelov spolu s kvadratickými kritériálnymi funkciami vedie ku *konvexnému* problému (kvadratické programovanie - QP), ktorého riešenia sú preštudované a existuje množstvo optimalizovaných komerčných riešení na báze kvadratického programovania

Napriek tomu je však použitie lineárnych modelov diskutabilné pri systémoch so silnou nelinearitou v blízkom okolí ustálených stavov. Lineárne modely by neboli efektívne ani pri tých nelineárnych procesoch, ktorých regulácia nespočíva v stabilizácii do ustáleného stavu, ale v riadených prechodoch regulovanej veličiny, napríklad pri dávkových procesoch (nábehy, dobehy...).

Vyššie uvedený zdroj uvádza nasledovné problémy použitia nelineárnych modelov:

- problematické získavanie nelineárneho modelu z *experimentálnych* údajov
- optimalizačný problém je *nekonvexný*, jeho riešenie je oveľa komplikovanejšie než QP a je tu možnosť uviaznutia v lokálnom extréme
- nekonvexnosť problému vedie k významnému *zvýšeniu* výpočtového času, čo obmedzuje použitie prediktívneho riadenia len na pomalé procesy
- problém stability a robustnosti je v tejto oblasti oveľa *komplexnejší*

V tejto práci sme sa snažili nájsť riešenie, ktoré by aspoň čiastočne riešilo uvedené problémy.

Prvý spomenutý problém sme v tejto práci riešili použitím *fuzzy modelu* typu Takagi-Sugeno (T-S), vďaka jeho výborným aproximačným vlastnostiam. Problematické získavanie modelu procesu z experimentálnych údajov rieši *substraktívna zhuková analýza*, čo je spôsob, akým T-S model vytvárame.


S druhým problémom spočívajúcim v komplikovanosti nekonvexnej funkcie sa výborne vysporiadávajú *genetické algoritmy*. Ide o optimalizačné výpočty využívajúce princípy evolúcie a predstavujú výkonný nástroj predovšetkým v oblasti veľmi zložitých a mnohorozmerných multimodálnych problémov, kde klasické optimalizačné prístupy zlyhávajú, alebo majú veľké problémy. Oproti gradientovým metódam sú genetické algoritmy schopné neuviaznuť v lokálnych extrémoch kriteriálnej funkcie. Výsledné riešenie môže byť navyše pri klasických metódach silne podmienené voľbou počiatočného odhadu riešenia, čo nepredstavuje pri genetických algoritmoch problém.

3. Fuzzy modelovanie

3.1 Fuzzy množiny

Fuzzy logika je zovšeobecnením klasickej množinovej teórie poskytujúca matematický rámec, ktorý umožňuje namiesto presných hodnôt pracovať skôr s neurčitými dátami. V klasickej teórii množín môže prvok buď patriť alebo nepatriť do danej množiny, čiže príslušnosť prvku k množine je vyjadriteľná len číslami z množiny $\{0,1\}$ podľa toho, či do množiny patrí alebo nepatrí.

Fuzzy množina umožňuje, aby do nej patril prvok do istej miery, čiže jeho príslušnosť je vyjadriteľná číslom z množiny $\langle 0;1 \rangle$. Predstavuje rozšírenie klasickej množinovej teórie, ktorá je špeciálnym prípadom fuzzy množinovej teórie pri hodnotách z krajov intervalu.



Obr. 2. Fuzzy množiny opisujúce vlastnosť *rozmer*

Fuzzy množina umožňuje matematicky zapísať vágny výraz ľudskej reči. Napríklad pri opisovaní veľkosti respektíve rozmeru používame výrazy, ktoré nie sú opísateľné ostrými množinami, medzi výrazmi *malý*, *stredný* a *veľký* nie sú ostré rozdiely, neexistujú jednoznačné hranice, kedy objekt prestáva byť malým a začína byť stredným a je zrejmé, že existujú prípady, keď by sme objekt zaradili niekde medzi pojem malý a stredný. Fuzzy popis umožňuje zohľadniť tieto skutočnosti a predstavuje prostriedok, akým je možné takto zachytiť neurčité či vágne údaje.

3.2 Fuzzy pravidlá

Forma fuzzy pravidiel vyjadruje spôsob ľudskeho uvažovania, alebo formy popisu, ktorý je do veľkej miery založený na implikačnom tvare vo forme AK-POTOM pravidiel, na základe ktorých pri znalosti východzieho stavu popísaného fuzzy množinami dedukujeme následky z nich vyplývajúce. Celý proces uvažovania je možné vyjadriť sústavou AK-POTOM pravidiel v tvare:

AK **odchýlka je veľká**, POTOM nech **akčný zásah je veľmi veľký**.

kde *odchýlka* je vstupná premenná, *veľká* je fuzzy množina popisujúca tie veľkosti


premennej *odchýlka*, ktoré sa dajú označiť za veľké. *Akčný zásah* je výstupná premenná a *veľmi veľký* je fuzzy množina popisujúca tie veľkosti premennej *akčný zásah*, ktoré sa dajú označiť za veľmi veľké.

Takýmto spôsobom je možné pokryť rôzne prípady ktoré môžu nastať a vyjadriť ich následky tak, že pre každý prípad použijeme samostatné AK – POTOM pravidlo. Výsledný popis tak vznikne zjednotením jednotlivých pravidiel.

3.3 Fuzzy aproximácia

AK-POTOM pravidlami je možné opísať ako nelineárnu funkciu, tak reguláciu procesu, ako aj rozhodovanie pri parkovaní auta. Časť po AK sa nazýva antecedent, časť po POTOM sa nazýva konsekvent.

Podobným spôsobom je možné opísať aj nelineárnu funkciu:



Obr. 3. Fuzzy aproximácia nelineárnej funkcie

V tomto prípade stačia na popis funkcie tri nasledovné pravidlá:

AK je vstup malý,	POTOM je výstup malý
AK je vstup stredný,	POTOM je výstup stredný
AK je vstup veľký,	POTOM je výstup veľmi veľký

Vhodným tvarom a prekrytím fuzzy množín sme dosiahli zachytenie nelineárneho priebehu funkcie, ktorá geometricky narastá.

3.4 Takagi – Sugeno (T-S) fuzzy modely

Predchádzajúce fuzzy pravidlá mali tvar

AK x je A , POTOM nech y je B

kde A a B sú fuzzy množiny. Pravidlá v tvare Takagi – Sugeno zavádzajú do konsekventu namiesto fuzzy množiny funkciu premenných antecedentu:

$$\text{AK } \mathbf{x} \text{ je } A, \text{ POTOM nech } \mathbf{y} \text{ je } f(\mathbf{x})$$

resp. v prípade viacerých premenných


$$\text{AK } \mathbf{x}_1 \text{ je } A_1 \wedge \mathbf{x}_2 \text{ je } A_2 \wedge \dots \wedge \mathbf{x}_n \text{ je } A_n, \text{ POTOM nech } \mathbf{y} \text{ je } f(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)$$

kde $f(\mathbf{x})$ resp $f(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)$ sú funkcie vstupných premenných.

Výsledkom nie je výstupný popis fuzzy množinou, ale lineárna funkcia váhovaná hodnotou príslušnosti vstupnej premennej k fuzzy množine antecedentu.

Takagi-Sugeno fuzzy systémy majú výborné aproximačné vlastnosti a preto sú veľmi často používané pri fuzzy modelovaní nelineárnych funkcií a procesov. Tento typ fuzzy systému je používaný aj ďalej v tejto práci

3.5 Aproximácia funkcií T-S fuzzy modelmi



Obr. 4. Lokálne modely fuzzy T-S opisu a ich funkcie príslušnosti vzhľadom na pracovný bod

Obrázok predstavuje funkciu sínus opísanú piatimi pravidlami T-S fuzzy modelu. Úsečky predstavujú lineárne funkcie konsekventov jednotlivých pravidiel f1 až f5, dole je päť

antecedentných fuzzy množín A až E:

- | | |
|-------------------|--------------------|
| 1. AK je vstup A, | POTOM je výstup f1 |
| 2. AK je vstup B, | POTOM je výstup f2 |
| 3. AK je vstup C, | POTOM je výstup f3 |
| 4. AK je vstup D, | POTOM je výstup f4 |
| 5. AK je vstup E, | POTOM je výstup f5 |

Výstup z tohto fuzzy systému 5 pravidiel sa prekrýva s aproximovanou funkciou sínus. Lineárne funkcie sú váhované mierou príslušnosti vstupnej premennej k príslušným fuzzy množinám.

Toto je hlavná podstata aproximácie funkcií pomocou T-S modelov. Je možné samozrejme aproximovať aj funkcie viacerých premenných, zavedením viacerých premenných (a príslušných fuzzy množín) do antecedentov. Ak ako ďalšie premenné zavedieme hodnoty minulých výstupov, môžeme takýmto spôsobom modelovať správanie dynamického systému.

Ak paralelne k riadenému procesu pripojíme fuzzy model, a prepojíme jeho minulé výstupy so vstupmi fuzzy modelu, dostaneme model dynamického systému schopný predikovať jeho správanie v budúcnosti.

3.6 Lokálne modely

Pri modelovaní silne nelineárnych systémov je ich linearizácia často pridrahým kompromisom, než aby bola efektívna. Často navyše nie je k dispozícii ani analytický opis systému, a je možné vytvoriť iba *black box* model zo vstupno výstupných údajov. Preto sa často postupuje tak, že sa namiesto jedného vytvorí sústava lokálnych lineárnych modelov, ktoré sa prepínajú podľa polohy pracovného bodu. Takýmto spôsobom sa dajú pokryť viaceré pracovné body procesu.

Použitie fuzzy modelov pri modelovaní nelineárneho systému prináša niekoľko zásadných výhod. Jednotlivé AK – POTOM pravidlá v T-S fuzzy modeli fungujú podobne ako sústava lokálnych lineárnych modelov, ale aktívny model je popísaný mierou príslušnosti k fuzzy množine. Počet lokálnych modelov zodpovedá počtu fuzzy pravidiel. To má za následok veľmi plynulé prepínanie medzi jednotlivými modelmi a z toho vyplývajúce vynikajúce aproximačné vlastnosti. To však nie je jediná výhoda. T-S fuzzy model je možné obojsmerne previesť na funkčne ekvivalentnú neurónovú RBF sieť, ktorá ako neurónová sieť má schopnosť učenia sa, čo je veľmi vhodné na priebežné ladenie parametrov fuzzy modelu, ak sa riadený systém v čase mení ([3]).

Oproti modelu pomocou MPL neurónovej siete, kde sú informácie roztrúsené vo váhach neurónových spojení, sú informácie vo fuzzy modeli jasne interpretovateľné v lokálnych modeloch. To prináša výhodu poskytnutia predbežnej apriórnej informácie do fuzzy modelu, ak je k dispozícii, napríklad od experta, ktorý vie slovne opísať jeho správanie, alebo jednou z metód *zhlukovej analýzy*. Tieto metódy hľadajú v nameraných vstupno výstupných údajoch množiny navzájom blízkyh dát, zhluky (clustery), ktoré predstavujú lokálne modely T-S fuzzy modelu.

Vytvoriť lokálne modely v T-S fuzzy modeli je možné rôznymi cestami, v tejto práci sme sa z viacerých dôvodov priklonili k substraktívnej zhlukovej analýze (substraktívny clustering).

3.7 Substraktívna zhluková analýza

Využitie možnosti dodať apriórne informácie je diskutovaná v rôznych prácach rôzne. V literatúre sme sa stretli s rôznymi deleniami vstupného priestoru pri hľadaní zhlukov, napríklad [4], prostredníctvom zhlukových analýz (fuzzy clustering). Existuje množstvo algoritmov, fuzzy modifikácií základného C-Means clusteringu HCM ([1], [4], [12]), z ktorých sú odvodené fuzzy verzie FCM, ale mnohé majú spoločnú tú vlastnosť, že potrebujú apriórne zadaný počet zhlukov, ktorých centrá majú určiť. To značne komplikuje automatickú tvorbu modelu.

Substraktívny clustering (substraktívna zhluková analýza) poskytuje zásadnú výhodu automatického určenia počtu clusterov, čo znamená možnosť automatického generovania fuzzy modelu pri poskytnutí iba vstupno výstupných údajov, bez nutnosti explicitného zadávania počtu hľadaných zhlukov.

Táto metóda hľadá vo vstupno výstupných údajoch zhluky navzájom podobných údajov, pričom každý zhluk predstavuje samostatný lokálny model fuzzy systému. Výhodou substraktívneho clusteringu oproti mnohým iným metódam zhlukových analýz a samo organizujúcich sa máp je optimálny počet nájdených zhlukov, a automatické určenie ich počtu. Mnohé iné zhlukové metódy vyžadujú apriórne zadanie počtu zhlukov, a ďalej hľadajú iba ich umiestnenie. Substraktívna zhluková analýza ich optimálny počet určí sama.

Kľúčovým pojmom v tejto metóde je tzv. miera hustoty každého bodu vo vstupno výstupných údajoch. Okolo každého bodu sa kvantitatívne vyjadri hustota, s akou sú okolo neho rozložené okolité body. Bod s najväčšou hustotou predstavuje súradnicu prvého zhluku, čiže prvé nájdené fuzzy pravidlo.

$$D_k = \sum_{j=1}^N \exp \left(- \frac{\|\mathbf{u}_k - \mathbf{u}_j\|}{\left(\frac{r_a}{2}\right)^2} \right) \quad (2)$$

Parameter r_a je kladné číslo určujúce polomer oblasti, v ktorej sa má rátať miera hustoty okolo daného bodu. Symbol \mathbf{u}_k predstavuje súradnice počítaného bodu, a \mathbf{u}_j súradnice okolitého bodu v počítanej oblasti.

Pri hľadaní ďalších zhlukov sa miery hustôt ďalších bodov „oslabujú“ o hustotu už nájdených zhlukov:

$$D_k^* = D_k - \sum_{i=1}^K D_{C_i} \exp \left(- \frac{\|\mathbf{u}_k - \mathbf{u}_{C_i}\|}{\left(\frac{r_b}{2}\right)^2} \right) \quad (3)$$

kde K je počet dosiaľ nájdených zhlukov, D_{C_i} je miera hustoty i . zhluku a \mathbf{u}_{C_i} sú súradnice i -teho zhluku. Číslo r_b je kladné číslo určujúce polomer oblasti, v ktorej má dôjsť

k redukcii miery hustoty v okolí i -teho zhluk. Obyčajne sa volí väčšie ako r_a , aby sa predišlo vygenerovaniu zhlukov blízko pri sebe, často $r_b = 1,5 * r_a$ alebo aj viacej.


Výsledkom je optimálny počet automaticky nájdených zhlukov a preto aj automatické vytvorenie optimálneho fuzzy modelu bez potreby ďalšieho ladenia modelu gradientovými metódami. Viac o algoritmoch zhlukových analýz je možné nájsť v [1], [4] alebo [12].

Podstatné je, že schopnosť automaticky určiť optimálny počet zhlukov robí zo substraktívnej zhlukovej analýzy účinný nástroj, ako len z poskytnutia experimentálnych údajov nelineárneho systému vytvoriť bez dodania ďalších údajov fuzzy model. V nasledujúcej kapitole ukážeme jeho ďalšie výhody, medzi ktoré patrí robustnosť a malá náročnosť na rozsah a dynamiku tréningových dát.


3.8 Nenáročnosť

Veľký význam má tiež nízka náročnosť substraktívneho clusteringu na variabilitu a počet tréningových vzoriek. Jedná sa iba o zlomok oproti požiadavkám na tréningovanie MPL neurónových sietí, ktoré v praxi nie je možné vždy splniť.


Nasledujúce priebehy predstavujú tréningové a testovacie dáta modelu systému **magnetickej levitácie**. Všetky uvedené časové priebehy majú na časovej osi mierku v sekundách.



Obr. 5. Prevodová charakteristika procesu magnetickej levitácie




Obr. 6. Trénovacie dáta pri modelovaní procesu magnetickej levitácie



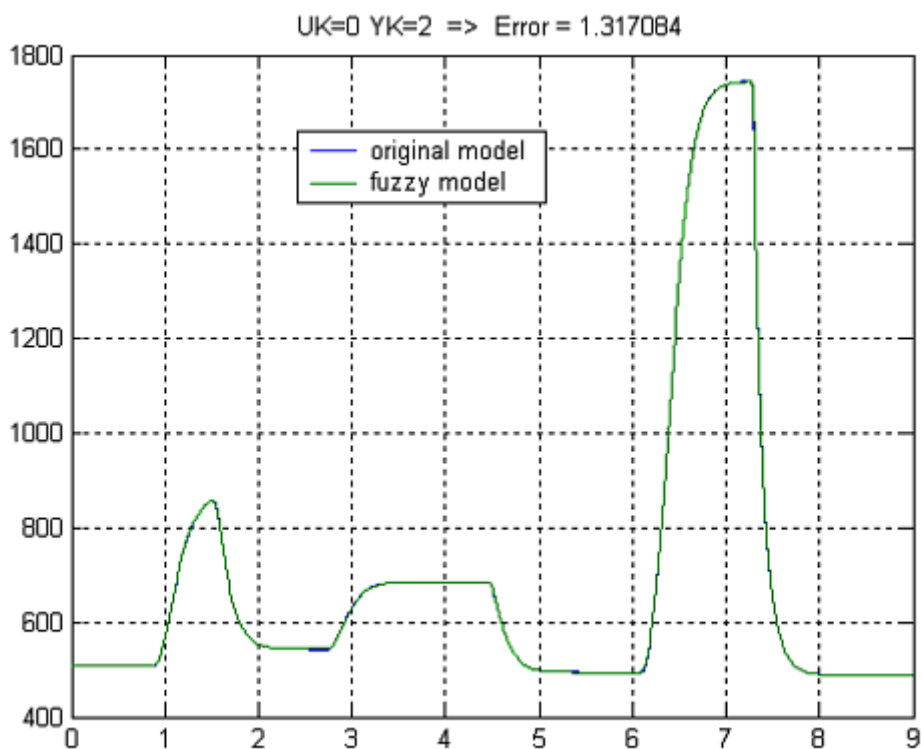
Obr. 7. Testovacie dáta s podstatne vyššou variabilitou ako trénovacie.

Uvedené priebehy demonštrujú nízku náročnosť fuzzy modelu na vstupné údaje. Model je trénovaný na veľmi strohých dátach z modelu magnetickej levitácie, napriek tomu je však schopný pokryť oveľa dynamickejšie testovacie dáta. Vďaka aproximačným schopnostiam fuzzy opisu pritom stačia iba 3 fuzzy pravidlá.

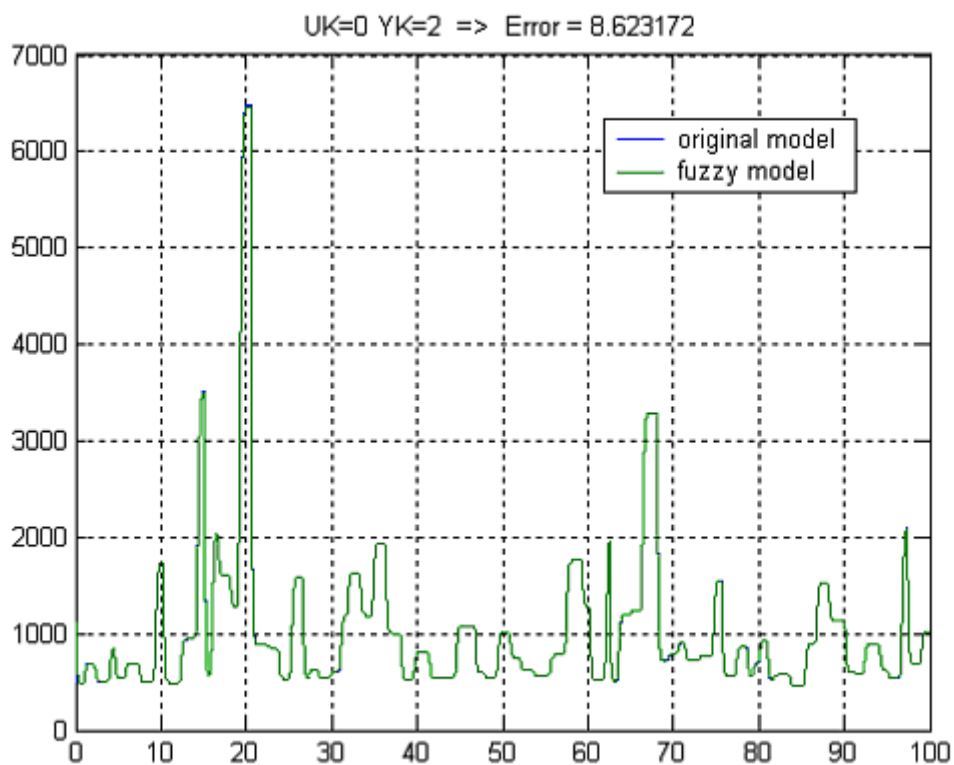
Ďalší podobný príklad nenáročnosti na tréningové dáta predstavuje modelovanie **polymerizačného reaktora**. V tomto prípade stačili na opis systému iba dve fuzzy pravidlá.



Obr. 8. Prevodová charakteristika procesu polymerizačného reaktora

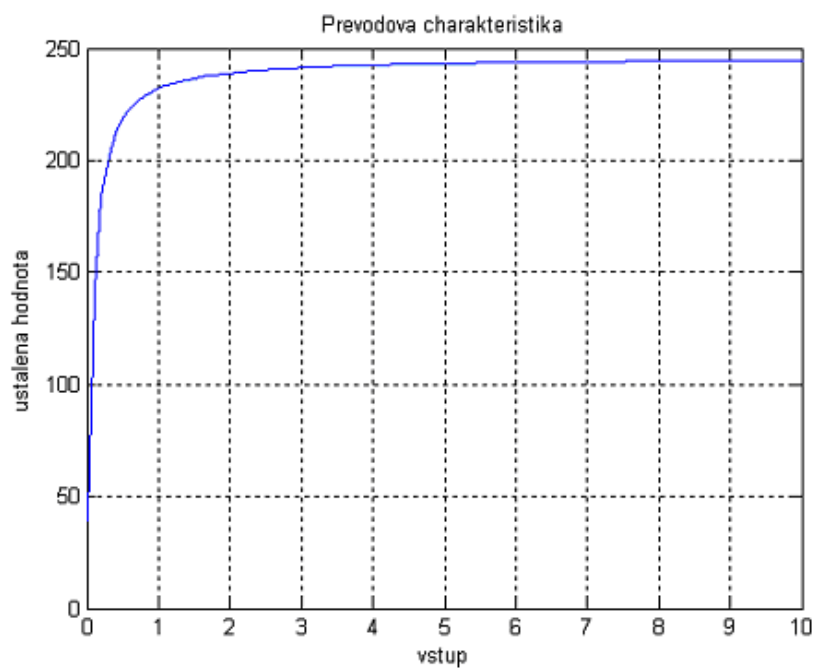


Obr. 9. Tréningové dáta polymerizačného reaktora




Obr. 10. Testovacie dáta polymerizačného reaktora

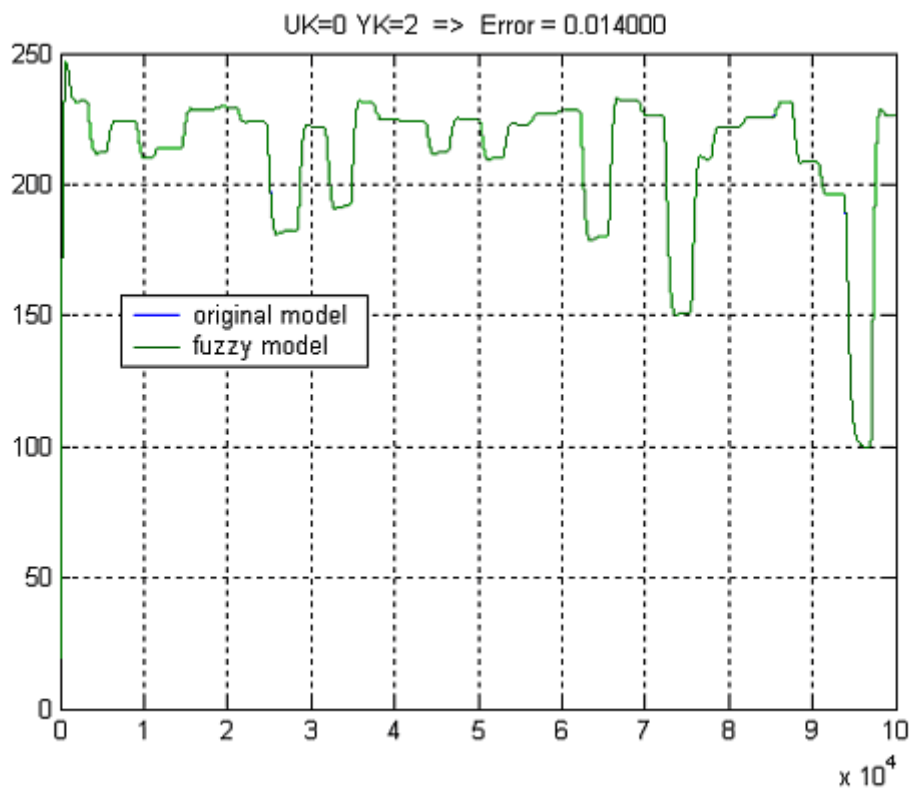
Tretím a posledným príkladom nenáročnosti na experimentálne dáta pri modelovaní nelineárneho systému pomocou T-S fuzzy modelu je model **chemického reaktora**:



Obr. 11. Prevodová charakteristika procesu chemického reaktora



Obr. 12. Trénovacie dáta polymerizačného reaktora



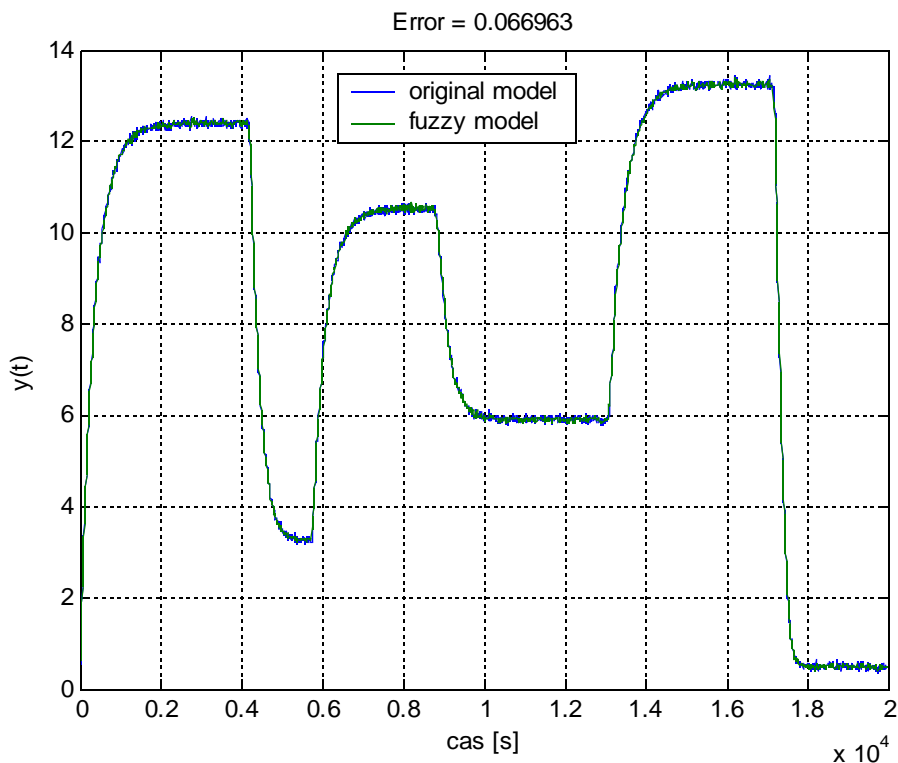
Obr. 13. Testovacie dáta polymerizačného reaktora

Uvedené priebehy demonštrujú nenáročnosť subtraktívnej zhukovej analýzy na experimentálne údaje pri vytváraní fuzzy modelu, čo v praxi predstavuje veľkú výhodu, pretože nie je vždy možné namerať údaje z priemyslu v dostatočnom počte.

3.9 Robustnosť


Popri aproximačných schopnostiach má T-S fuzzy model aj robustné vlastnosti. Nasledujúce priebehy ukazujú vytvorenie fuzzy modelu na experimentálnych údajoch pri zašumenom meracom kanáli, a následná rekonštrukcia.

Nasledujúce obrázky ukazujú robustnosť T-S fuzzy modelu. Vstupno výstupné tréningové dáta namerané z reálneho procesu spojených nádob sú nedostatočné na vytvorenie modelu pomocou MPL neurónovej siete, navyše je na nich superponovaný šum meracieho kanála.



Obr. 14. Zašumené tréningové dáta spojených nádob malej variability.

Subtraktívna zhuková analýza však dokáže aj z takýchto riedkych a zašumených údajov zostrojiť fuzzy model s iba tromi fuzzy pravidlami, ktorý dokáže pokryť aj oveľa dynamickejšiu testovaciu vzorku:



Obr. 15. Testovacie dáta s podstatne vyššou variabilitou ako trénovacie.

Ukazuje sa, že použitie T-S fuzzy modelu ako interného modelu prediktívneho riadenia môže poskytnúť veľké výhody z hľadiska tvorby robustných modelov aj pri sťažených meracích podmienkach.

4. Genetické algoritmy

Z nárastu výkonu výpočtovej techniky ťažia aj evolučné výpočty. Jedná sa o optimalizačné metódy využívajúce princípy evolúcie. Ich počiatky siahajú do 50. a 60. rokov 20. storočia, keď viacerí počítačovní vedci študovali evolučné systémy a ich možné využitie v optimalizačných problémoch.

4.1 Princípy GA

Ťažisko leží vo vytvorení analógie dvoch hlavných znakov evolučného procesu, ktorými sú princíp prežitia najsilnejších jedincov, a genetická rekombinácia (zastúpená operáciami mutácie a kríženia), ktoré vedú pri definovaných podmienkach k optimálnemu riešeniu (globálnemu extrémum optimalizovanej kritériálnej funkcie).


4.2 Klasické metódy

Klasické optimalizačné algoritmy sú dobre preštudované a teoreticky podložené. Pri hľadaní extrémum však často potrebujú poznať gradient účelovej funkcie (rôzne gradientové metódy), prípadne aj Hesseho maticu H druhých derivácií (metódy konjugovaného gradientu, napr. *Fletcher a Reeves*), a kladú na danú funkciu rôzne požiadavky, ako je jej spojitosť, hladkosť, diferencovateľnosť či konvexnosť a predovšetkým možnosť jej analytického vyjadrenia.


V praxi sa však často vyskytujú funkcie, pri ktorých sú kvôli zložitosti funkcie klasické metódy neefektívne až nepoužiteľné. Často nie je možné splniť požiadavky týchto metód na účelovú funkciu, pretože okrem schopnosti zistiť funkčnú hodnotu v danom bode nevieme o funkcii vôbec nič.

Sú vypracované optimalizačné metódy typu nula, čo znamená, že im stačí informácia o funkčnej hodnote, a nepotrebujú informácie o deriváciách (napr. mapovacia metóda riadkovej stratégie, Powellova metóda konjugovaných smerov, metóda pružného simplexu Nelder a Meada).


Ich nevýhodou je však tendencia skonvergovať do lokálneho extrémum, predovšetkým v prípade zložitých multimodálnych funkcií. Bod konvergencie je tiež silne závislý na voľbe počiatočného riešenia. Zároveň ich výpočtová náročnosť prudko narastá so stúpajúcou dimenziou účelovej funkcie. Nasleduje niekoľko príkladov dvojrozmerných multimodálnych funkcií, s ktorými klasické metódy mávajú problémy.



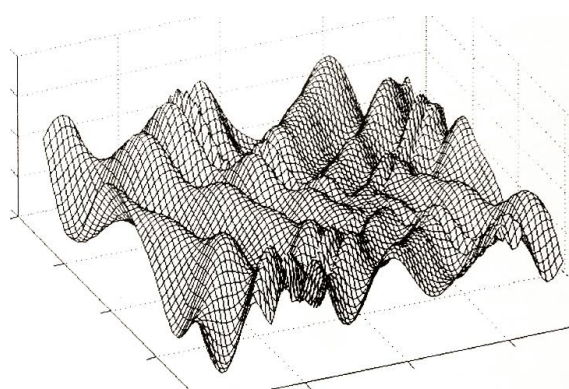
Obr. 16. Schwefelova funkcia



Obr. 17. Príklad multimodálnej funkcie



Obr. 18. Rastriginova funkcia



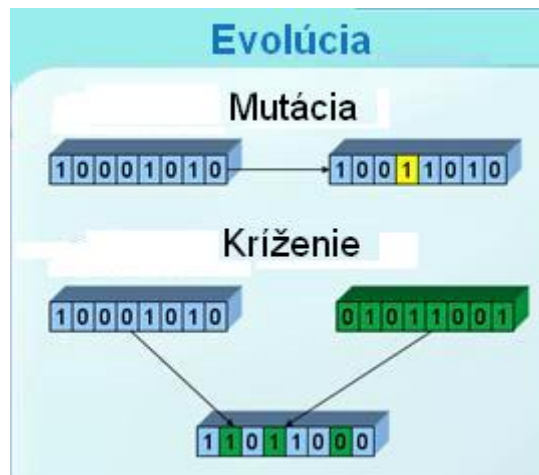
Obr. 19. Ukážka dvojrozmernej multimodálnej funkcie (prevzaté z [13])

4.3 Výhody GA

Genetické algoritmy predstavujú pri riešení podobných funkcií efektívny nástroj. Ich princíp spočíva v pokrytí prehľadávaného priestoru nezávislých premenných určeným počtom bodov – chromozómov. Množina takto vygenerovaných bodov predstavuje populáciu chromozómov, ktorých parametrické súradnice sa nazývajú gény a ich počet určuje veľkosť populácie. V rámci danej populácie sa vyhodnotí funkčná hodnota každého chromozómu. Ak uvažujeme, že hľadáme minimum, čím má chromozóm menšiu funkčnú hodnotu, tým je z evolučného hľadiska úspešnejší.

Nasleduje uplatnenie princípu prirodzeného výberu, keď sa vyberú najúspešnejší jedinci aktuálnej populácie, ktorí podstúpia operácie kríženia a mutácie. *Kríženie* spočíva vo výmene jednej alebo viacerých podčastí génového reťazca medzi dvomi chromozómami navzájom, *mutácia* spočíva v náhodnej zmene hodnoty nejakého génu v chromozóme. Základné dva druhy mutácií sú globálna, kde nová hodnota génu môže byť z celého prehľadávaného priestoru, a mutácia lokálna, pri ktorej dochádza k náhodnej zmene

v blízkom okolí pôvodnej hodnoty.




Obr. 20. Operácie mutácia a kríženie

Po výbere najúspešnejších jedincov a ich rekombinácií je vytvorená nová populácia čiastočne z nich, čiastočne náhodným výberom zo starej populácie, a celý proces sa iteračne opakuje. Jeden takýto iteračný cyklus predstavuje jednu generáciu v evolučnom výpočte. Zastavovacou podmienkou býva spravidla počet generácií. Najúspešnejší jedinec poslednej generácie potom predstavuje výsledné riešenie. Takýmto spôsobom je prehľadávaný priestor funkcie, pričom selektívnym tlakom v evolúcii je lokálna mutácia a výmena časti reťazcov úspešných chromozómov.

Spôsobov, ako vyberať úspešných jedincov, či vykonať mutácie a kríženie je veľké množstvo a do istej miery je použitie optimálneho spôsobu heuristickou záležitosťou.

Genetické algoritmy majú ako schopnosť prehľadávania priestoru, čím sú schopné neuviaznuť v lokálnom extréme, tak schopnosť konvergencie. Nasleduje znázornenie jednorozmerného rezu viacrozmernou multimodálnou funkciou.



Obr. 21. Funkčnosť mutácie a kríženia

Na obrázku je znázornené, akú funkciu má kríženie a mutácie. Lokálne mutácie znázornené červenou farbou predstavujú trajektóriu jedinca počas generácií, ktorá predstavuje lokálne prehľadávanie v okolí daného jedinca a spôsobujú konvergenciu do lokálneho extrému. Naproti tomu globálna mutácia a kríženie reprezentované modrou menia súradnice jedincov populácie naprieč hľadaným priestorom a predstavujú nástroj, ako sa vymaniť z uviaznutia v lokálnom extrémé.

To sú základné mechanizmy, vďaka ktorým sú genetické algoritmy výkonným optimalizačným a do veľkej miery univerzálnym nástrojom aj v prípade zložitých a mnohodoménových funkcií.

Medzi výhody genetického algoritmu patrí malé zvýšenie výpočtovej náročnosti pri zvyšovaní dimenzie kriteriálnej funkcie. Pri klasických metódach predstavuje zvyšovanie dimenzie kriteriálnej funkcie často exponenciálny nárast zložitosti. Povaha genetických algoritmov však spôsobuje, že na rast dimenzie účelovej funkcie nereflektujú exponenciálnym nárastom výpočtovej náročnosti. Rovnako nie sú tak výpočtovo citlivé ani na nelineárne ohraničenia prehľadávaného priestoru.

4.4 GA v prediktívnom riadení

V kontexte prediktívneho riadenia majú tieto vlastnosti viacero výhod. Nízke nároky na jednoduchosť účelovej funkcie umožňujú hľadať optimum aj pri zložitých systémoch, predikcia výstupu ktorých môže viesť k zložitým multimodálnym funkciám, ktorých zložitosť môžu zvyšovať aj do nej implementované ďalšie požiadavky na vlastnosti riadenia. Neexponenciálny nárast zložitosti pri zvyšovaní dimenzie účelovej funkcie predstavuje v rámci prediktívneho riadenia možnosť rátať akčný zásah aj v dlhších radiaciach horizontoch, nakoľko počet dopredu rátaných akčných zásahov predstavuje

dimenziu účelovej funkcie.

Zároveň pri možnosti pridať rôznorodé nelineárne ohraničenia akčného zásahu bez väčšieho zvýšenia náročnosti predstavuje pre prediktívny regulátor genetický algoritmus výkonnú optimalizačnú rutinu.

Jedným z možných vylepšení algoritmu je nasadenie niektorej z klasických optimalizačných metód pri podozrení na okolie extrému, ktorá urýchli konvergenciu. V základnom tvare konvergujú genetické algoritmy vďaka lokálnej mutácií, čo je proces do istej miery stochastický. Pre urýchlenie konvergenzie do extrému je možné použiť nejakú z klasických metód, ktoré dobu konvergenzie oproti lokálnym mutáciám podstatne skráti. V našej práci sme skúsili v okolí ustáleného stavu použiť metódu pružného simplexu Nelder-Meada ([11]).


Pri simuláciách v tejto práci sa ukázalo, že na určenie akčného zásahu genetickými algoritmi väčšinou stačilo len 20 generácií po 20 jedincoch.

5. Integrácia moderných metód


Integrácia uvedených metód fuzzy modelovania a použitia genetických algoritmov v prediktívnom riadení má veľké výhody. Prediktívne riadenie poskytuje spôsob, ako generovať optimálny riadiaci zásah podľa zadanej kritériálnej funkcie, do ktorej môžu byť zakomponované rôznorodé ohraňenia. Podmienkou je existencia modelu riadeného systému, ktorú spĺňa fuzzy model so spomenutými výhodami.

Na nasledujúcom príklade ukážeme, ako zohľadnenie správania sa riadeného systému v blízkej budúcnosti umožňuje prediktívnemu regulátoru optimálne reagovať veľkosťou akčného zásahu.


Nasledovné simulácie boli vykonané na modeli chemického reaktora so silne nelineárnou prevodovou charakteristikou. Reaktor má charakteristický spontánný počiatkový nábeh bez ohľadu na veľkosť vstupnej veličiny. Predikčný horizont riadenia bol 20 períód vzorkovania, riadiaci 1 períoda, jedna vzorkovacia períoda bola 20 sekúnd. Fuzzy model bol tvorený tromi pravidlami.



Obr. 22. Prevodová charakteristika chemického reaktora



Obr. 23. Časový priebeh regulácie chemického reaktora so spontánnym počiatočným nábehom



Obr. 24. Časový priebeh akčného zásahu regulácie chemického reaktora so spontánnym počiatočným nábehom

Z uvedeného priebehu regulačnej simulácie vidno, že prediktívny regulátor správne identifikoval počiatkový nábeh reaktora a zvolil minimálny možný akčný zásah, počas ktorého v systéme prebehne počiatkový nábeh. Regulátor vďaka schopnosti predikovať podľa interného modelu budúce výstupy procesu začal systém riadiť, až keď malo význam generovať vstup do riadeného systému, ktorého výstup po odznení počiatkového nábehu začal byť riaditeľný. To s kauzálnym regulátorom, ako je napríklad PID, nie je možné.

Existuje veľká variabilita možných úprav a vylepšení genetického algoritmu. V tejto práci sme okrem spomenutého nasadenia metódy pružného simplexu Nelder-Mead v okolí extrému použili aj injekťaz predchádzajúceho riešenia, ak sa systém nachádzal v blízkosti ustáleného stavu.

Injekťaz spočívala v tom, že v prípade aktuálneho stavu riadeného systému v okolí ustálenia bolo do náhodne vygenerovanej počiatkovej populácie pridané riešenie optimalizačného problému z predchádzajúcej vzorkovacej periódy, čím sa ušetril výpočtový čas na hľadanie riešenia, ktoré je v blízkosti ustáleného stavu podobné predchádzajúcemu.

5.1 Porovnanie prediktívneho riadenia a PID regulácie

Pre porovnanie s prediktívnym riadením tohto reaktora bol genetickými algoritmi navrhnutý optimálny PID regulátor. Simulácia bola robená v simulačnom prostredí Simulink programu Matlab 6.5.

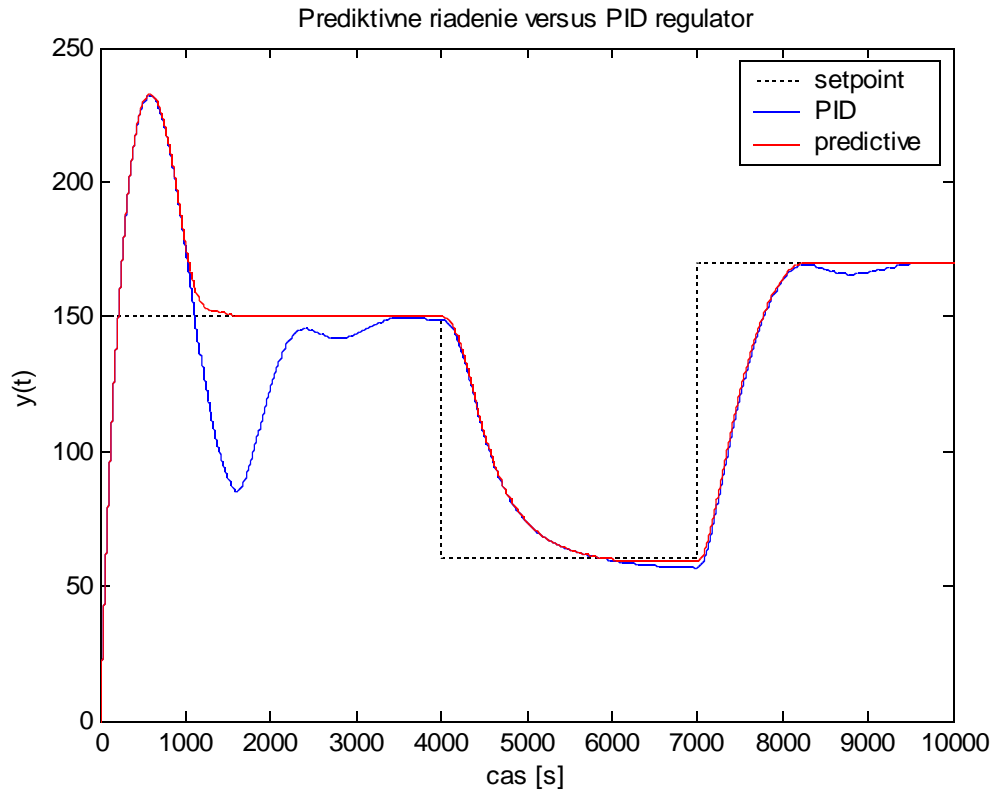
Kvôli počiatkovému nábehu a silnej nelinearite nebolo možné regulovať pomocou PID od začiatku, preto v simulačnej schéme Simulinku bol nastavený spínač, ktorý zapol regulačný obvod PID až po jeho odznení, pri čase $t = 1500$ s.

Nasledujúce časové priebehy ukazujú porovnanie riadenia prostredníctvom prediktívneho regulátora a regulátora PID.

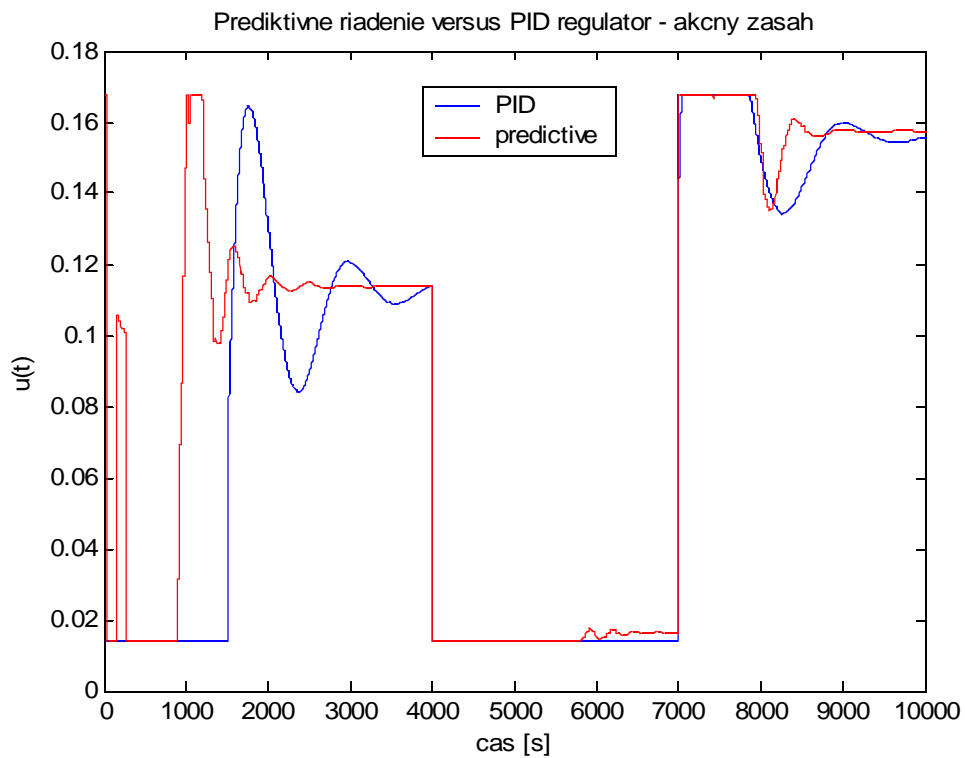
Nasledovné dve dvojice časových priebehov ukazujú, že prediktívne riadenie produkuje optimálny akčný zásah, ktorým riadi systém bez kmitov a dokáže utlmiť preregulovanie.

Prvá dvojica grafov predstavuje časové priebehy porovnávaných regulátorov a ich akčných zásahov. Koeficienty PID regulátora boli genetickým algoritmom optimalizované na konkrétnu trajektóriu žiadanej veličiny. Nevýhodou PID regulátora je jeho kauzalita a trojica statických parametrov, ktorá sa nemôže prispôsobiť zmene pracovného bodu riadeného systému.


Pri zmene trajektórie želanej hodnoty sa v dôsledku nelinearity riadeného procesu zhoršujú riadiace vlastnosti PID regulátora, pričom prediktívny regulátor generuje stále optimálny akčný zásah. Porovnanie časových priebehov prediktívneho regulátora a PID regulátora pri zmene trajektórie žiadanej hodnoty predstavuje druhá dvojica grafov.



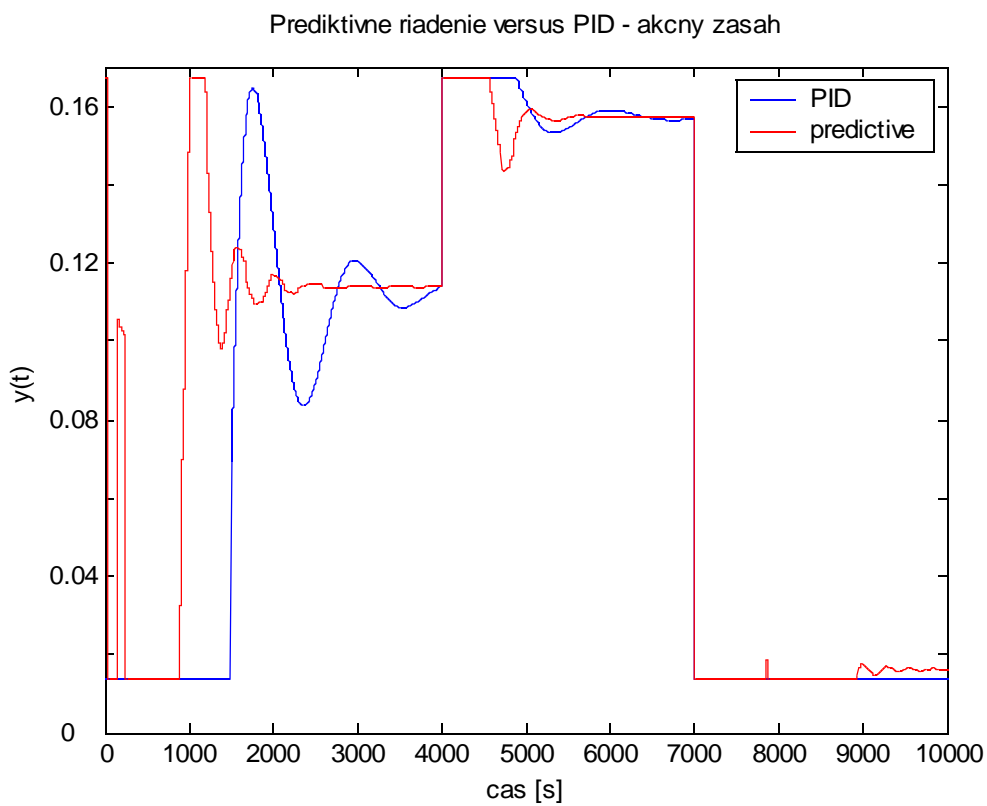
Obr. 25. Porovnanie časového priebehu regulácie prediktívnym a optimálnym PID regulátorom.



Obr. 26. Porovnanie časového priebehu akčných zásahov regulácie prediktívnym a optimálnym PID regulátorom.




Obr. 27. Porovnanie časového priebehu regulácie prediktívnym a optimálnym PID regulátorom pri inej želanej trajektórii.

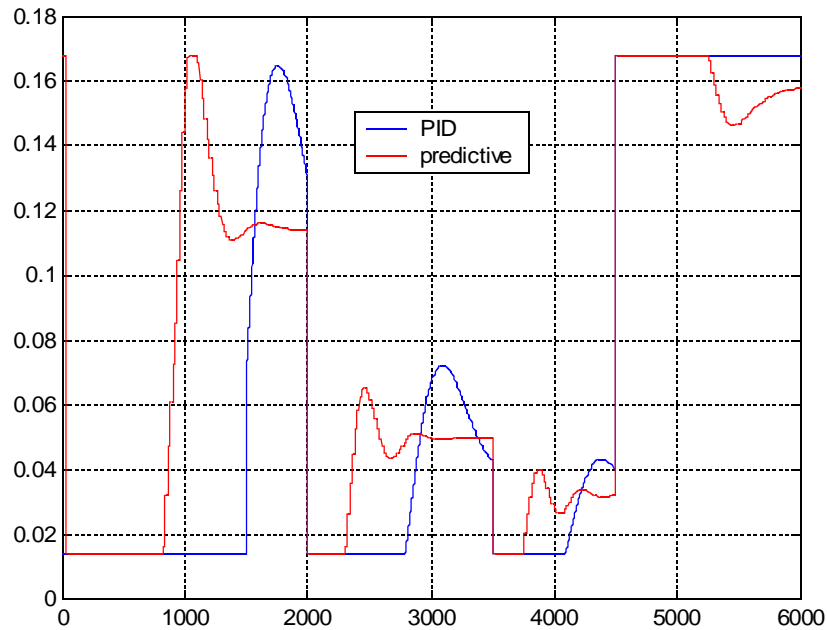


Obr. 28. Porovnanie časového priebehu akčných zásahov regulácie prediktívnym a optimálnym PID regulátorom pri inej želanej trajektórii.

Optimalita prediktívneho regulátora ostáva aj pri požiadavke skrátenia doby regulácie. Zmeny žiadanej veličiny v nasledujúcich regulačných priebehoch sú dvakrát častejšie oproti predchádzajúcemu príkladu. Aj napriek snahe určiť genetickým algoritmom optimálne koeficienty PID regulátora, nebol schopný uradiť silne nelineárny systém pri 50% skrátení požadovanej doby regulácie.



Obr. 29. Porovnanie časových priebehov prediktívneho riadenia a optimálneho PID regulátora




Obr. 30. Porovnanie časových priebehov akčných zásahov prediktívneho riadenia a optimálneho PID regulátora

5.2 Časová a výpočtová náročnosť

Jeden z dôležitých parametrov prediktívneho riadenia je dĺžka horizontu riadenia, ktorá môže zásadne ovplyvniť náročnosť optimalizačného výpočtu. Každé jeho zvýšenie o jeden krok predstavuje z hľadiska optimalizácie o jednu dimenziu kriteriálnej funkcie navyše. Pre mnohé klasické optimalizačné metódy to predstavuje exponenciálny nárast zložitosti.

Výhodou genetických algoritmov je, že exponenciálny nárast nevykazujú. Nasledujúci graf predstavuje výsledok porovnania časovej náročnosti simulácií prediktívneho riadenia s použitím genetických algoritmov (s použitím metódy pružného simplexu v okolí ustálených stavov) - tmavo modrá - a použitia iba klasickej optimalizačnej metódy pružného simplexu Nelder-Meada pri riadení spomenutého chemického reaktora pre horizont riadenia rôznej dĺžky. Simulácie boli robené na PC s taktovaciu frekvenciou 3 GHz.


Podstatné je pomerné porovnanie časovej náročnosti, ktoré ukazuje, že z počiatku je genetický algoritmus výpočtovo náročnejší, no už pri dĺžke riadiaceho horizontu 3 sa náročnosť vyrovnáva, a ďalej v prípade metódy Nelder-Mead prudko rastie, kým v prípade genetických algoritmov len mierne stúpa. Červené stĺpce navyše predstavujú počet akčných zásahov pri použití metódy Nelder-Mead, pri ktorých optimalizačný výpočet neskonvergoval. Ukazuje sa, že výpočtová náročnosť je pri použití genetických algoritmov iba zlomok náročnosti klasickej metódy.



Obr. 31. Porovnanie časovej náročnosti genetických algoritmov a metódy pružného simplexu

5.3 Kompenzácia poruchy


Úlohou regulátora je nielen priviesť výstup riadeného systému na požadovanú úroveň, ale dokázať kompenzovať poruchy, ktoré v systéme môžu nastať. Nasleduje príklad kompenzácie poruchy pri riadení vyššie spomenutého chemického reaktora (obr. 22)



Obr. 32. Schéma regulačného obvodu s kompenzáciou poruchy

Úlohou regulátora je vyrovnať výchylku spôsobenú poruchou d v čo najkratšom čase.

Vďaka predikcii hodnôt systému pomocou interného modelu je možné porovnať v každej vzorkovacej perióde aktuálny výstup zo systému s jeho hodnotou predikovanou v predchádzajúcom kroku. Ak dôjde k rozdielu týchto hodnôt, je tým zistený vznik poruchy.



Obr. 33. Prevodová charakteristika: princíp kompenzácie poruchy

Hodnoty výstupu systému sa tak kopírujú do vektora minulých hodnôt fuzzy modelu upravené o túto poruchu, aby model napriek poruche ostal v rovnakom pracovnom bode, ako je samotný riadený systém.


SP znamená ustálenú hodnotu žiadanej veličiny (ak predpokladáme systém v ustálenom stave), na ktorý sa riadi výstup zo systému. Pôsobením poruchy d je výstup zo systému zmenený na hodnotu $SP - d$, pričom výstup zo samotného reaktora ostáva na hodnote SP .

Bod $SP - d$ predstavuje výstup z procesu zaťažený poruchou ($y - d$ na schéme). Úlohou regulátora je upraviť vstup do riadeného reaktora o hodnotu Δu tak, aby sa zmenil jeho výstup o hodnotu poruchy a vykompenzoval ju. Výstup zo samotného reaktora bude tak po kompenzácii poruchy $SP + d$ a celkový výstup zo systému bude preto


$$SP + d - d = SP \quad (4)$$

čím je porucha vykompenzovaná. Priložené časové priebehy porovnávajú kompenzáciu poruchy prediktívneho riadenia a optimálneho PID regulátora. Prvá porucha s hodnotou 10 nastala v čase 5000, druhá s rovnakou hodnotou v čase 7500. Prediktívne riadenie operovalo s predikčným horizontom 20 a horizontom riadenia 1.

Z priebehov vidno, že oproti PID kompenzuje prediktívny regulátor poruchy bez preregulovania a kmitov.



Obz. 34. Kompenzácia poruchy: porovnanie časových priebehov PID a prediktívneho riadenia

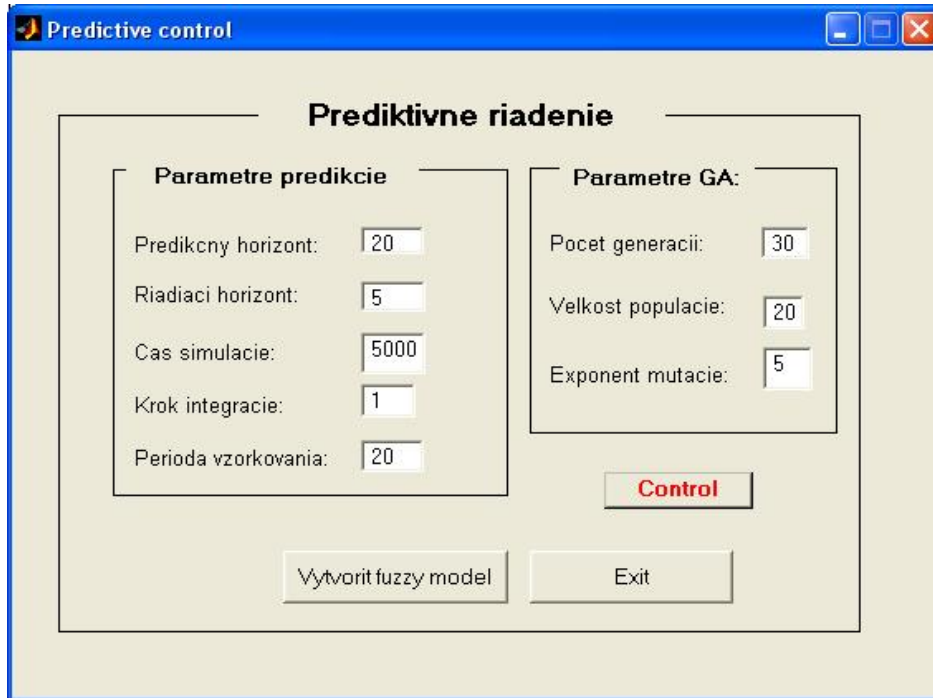


Obr. 35. Kompenzácia poruchy: porovnanie časových priebehov akčného zásahu PID a prediktívneho riadenia

Podľa týchto priebehov poskytuje prediktívne riadenie oproti riadeniu pomocou regulátora PID rýchlejšie regulačné priebehy i dobu regulácie a bez preregulovania výstupnej veličiny.

6. Aplikačný systém

Súčasťou tejto práce bolo vytvorenie grafického frontendu pre naprogramované algoritmy v prostredí GUI Matlab 6.5, prostredníctvom ktorého je možné užívateľsky zadávať parametre prediktívneho riadenia, ako dĺžky horizontov, dobu a integračný krok simulácie a periódu vzorkovania. V časti parametrov GA je možné zadať počet generácií, veľkosť populácie a exponent mutácie.

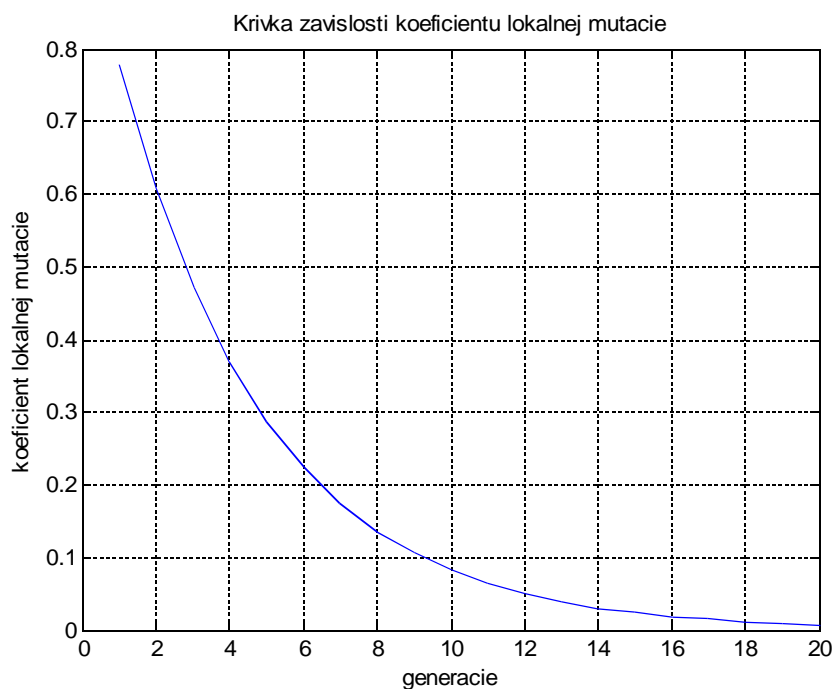


Obr. 36. Grafický frontend pre prediktívne riadenie s parametrami pre prediktívny regulátor a genetické algoritmy

Exponent mutácie je koeficient exponenciálnej klesajúcej funkcie, ktorý určuje mieru rozsahu lokálnych mutácií.

$$K(i) = rozsah * \exp\left(-\frac{E_M}{N_G} * i\right) \quad (5)$$

kde $K(i)$ je hodnota koeficientu rozsahu lokálnej mutácie, E_m je exponent mutácie, N_G počet generácií a i je index aktuálnej generácie. Hodnotou E_m sa mení zakrivenie funkcie.

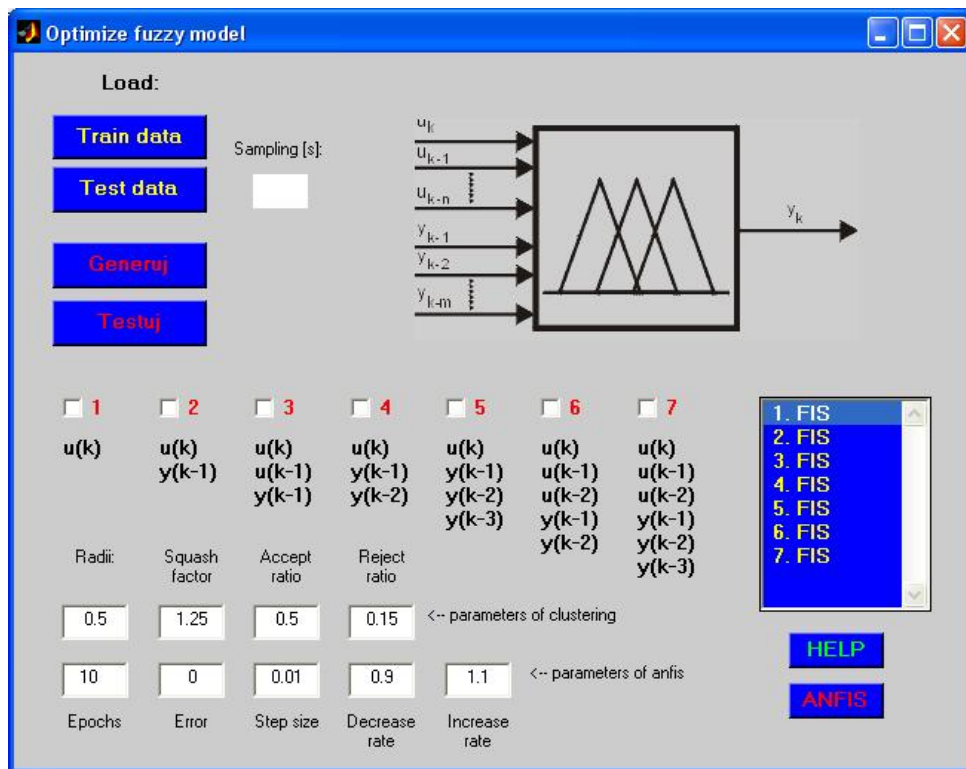


Obr. 37. Krivka závislosti koeficientu lokálnej mutácie od počtu generácií

Jeho význam spočíva v znižovaní rozsahu lokálnej mutácie s plynúcimi generáciami. Kým na začiatku genetického algoritmu je žiaduca diverzita kvôli prehľadávaniu priestoru, je s postupujúcimi generáciami žiaduca stále viac selektivita, a jemnejšie hľadanie v okolí extrémov, čo je zabezpečené zmenšením rozsahu lokálnych mutácií podľa tejto funkcie.

Súčasťou frontendu je aj možnosť vytvoriť z nameraných údajov fuzzy model, ktorý zobrazí ďalšiu samostatnú grafickú aplikáciu s parametrami pre fuzzy modelovanie, kde pre vytvorenie modelu stačí zadať štruktúru modelov a cestu k uloženým experimentálnym vstupno výstupným údajom.

Umožňuje zo zadaných údajov vygenerovať fuzzy modely rôznych štruktúr odlišujúcich sa od seba rôznym počtom hodnôt minulých vstupov a výstupov, porovnať ich modelovacie schopnosti a vybrať model s optimálnou štruktúrou. V prípade potreby je možné transformovať fuzzy model do FNS systému typu ANFIS a tréňovaním neurofuzzy systému doladiť parametre modelu.



Obr. 38. Grafický frontend pre vytvorenie fuzzy modelu z experimentálnych údajov

7. Záver

Cieľom tejto práce nebola náhrada klasických metód riadenia modernými, ale poukázať na oblasti, pri ktorých sa môžu uplatniť výhody moderných metód riadenia a možnosti obohatenia klasických metód.

Do konceptu prediktívneho riadenia ako spôsobu hľadania optimálneho riadiaceho zásahu sme vložili objekty dvoch ďalších moderných disciplín.

Fuzzy modelovanie je prístup založený na teórii fuzzy množín, ktorými popisuje vstupné údaje, z ktorých sme zhlukovou analýzou vygenerovali optimálny počet zhlukov popísaných fuzzy množinami. Ukázali sme, že použitím príslušnosti údajov k fuzzy množine zhluku je možné docieľiť výbornú aproximačnú schopnosť.

Ďalej sme prediktívne riadenie rozšírili o metodológiu genetických algoritmov, ktoré pri optimalizačnom výpočte kopírujú princípy evolúcie z prírody. Selektivita prameniaca z princípu prežitia najsilnejšieho a diverzita prameniaca z operácií mutácie a kríženia robí z genetických algoritmov výkonný optimalizačný nástroj vhodný predovšetkým na použitie pri zložitých mnohorozmerných a multimodálnych účelových funkciách.

Mnohé moderné metódy, ako sú napríklad genetické algoritmy, dosiaľ nemajú plný teoretický rámec, avšak ich stále širšie a úspešnejšie nasadenie v praktických aplikáciách naznačuje ich veľké možnosti.

Prediktívne riadenie predstavuje spôsob generovania optimálneho akčného zásahu. Jeho základným rysom je zohľadnenie ďalšieho správania riadeného procesu, vďaka čomu môže v predstihu reagovať úpravou akčného zásahu. Riadené systémy reguluje optimálne, v zmysle požiadaviek optimality formulovanými účelovou funkciou. Je potrebné bližšie preskúmať riadenie s dlhými horizontami riadenia, pretože podľa našich simulácií jeho predlžovanie vedie k miernemu zvýšeniu dynamiky riadenia, ale i k zvýšeniu kmitania.

Použitie T-S **fuzzy modelu** vytvoreného substraktívnou zhlukovou analýzou prináša v prediktívnom riadení výhodu automatickej tvorby modelu z nameraných údajov, pričom sa vie do veľkej miery vysporiadať aj s nekvalitnými alebo zašumenými tréningovými dátami. Ukazuje sa ich použiteľnosť na ťažko modelovateľné systémy, ktorých zložitost' nespočíva iba v ich silnej nelinearite, ale aj v nemožnosti namerať dostatok vstupno výstupných údajov v dostatočnom rozsahu a dynamike, aké by potrebovala neurónová sieť, čo má pri praktickom použití veľký význam.

Zároveň možnosť transformácie fuzzy modelu na RBF neurónovú sieť umožňuje priebežné ladenie modelu systému počas prevádzky a zachytiť zmeny jeho parametrov v čase.

Použitie **genetických algoritmov** ako optimalizačnej metódy poskytuje široké možnosti. Nevýhodou mnohých aplikácií prediktívneho riadenia boli špeciálne nároky na vlastnosti účelovej funkcie a obmedzenie dĺžky riadiaceho horizontu pre exponenciálny nárast výpočtovej náročnosti. Použitím genetických algoritmov ako optimalizačnej metódy sme získali výkonný nástroj, podstatne sme znížili nároky kladené na účelovú funkciu, ako aj exponenciálnu závislosť od nárastu riadiaceho horizontu.

Genetické algoritmy umožňujú efektívne zakomponovať rôznorodé ohraničenia, pretože kritériálna funkcia nie je limitovaná svojou konvexnosťou. Robustnosť genetických algoritmov dáva priestor ich použitiu v riadení širokého rozsahu typov nelineárnych systémov len malou zmenou optimalizačného algoritmu. Vzhľadom na relatívnu nízku výpočtovú náročnosť pri dlhších riadiacich horizontoch majú veľkú výhodu oproti klasickým optimalizačným metódam, hoci v absolútnom merítku ide stále o výpočtovo veľmi náročné postupy, vďaka čomu sú pri súčasnom výkone VT aplikovateľné zatiaľ v relatívne pomalých priemyselných procesoch.

Predstava geneticko-fuzzy-prediktívneho riadenia spočíva vo vízii, kde sa z nameraných experimentálnych údajov z riadeného nelineárneho systému v rozsahu, v akom umožňovala namerať technológia, vytvorí vďaka vlastnostiam substraktívneho clusteringu automaticky fuzzy model, ktorý sa použije ako interný model prediktívneho riadenia. Všetky požiadavky na vlastnosti, kvalitu a ohraničenia riadenia je možné formulovať v kritériálnej funkcii. Vďaka schopnosti GA vysporiadať sa so zložitými mnohodoménovými multimodálnymi funkciami máme široké možnosti požiadaviek, ktoré môžeme mať na vlastnosti regulácie prostredníctvom kritériálnej funkcie, a výpočtovo prijateľnejšie sú aj dlhšie riadiace horizonty.

Priebežné sledovanie experimentálnych údajov umožňuje sledovať zmeny parametrov riadeného systému, a vďaka možnosti transformácie fuzzy modelu do ekvivalentnej RBF siete, napríklad neurofuzzy systému ANFIS, je možné počas prevádzky online vyladiť model na nové vlastnosti riadeného systému. Pri vhodnom nastavení štruktúry a parametrov tohto riadiaceho systému je možné získať veľmi výkonný, univerzálny a robustný riadiaci systém.

Použitie moderných metód riadenia má pred sebou ešte dlhú cestu, počas ktorej ich čaká ďalšie teoretické skúmanie, ďalšie analýzy ich schopností, možností a hraníc uplatnenia, ako aj odolávanie konzervatizmu automatizačného priemyslu. Táto práca sa snažila poukázať na vlastnosti vybraných moderných oblastí, a význam ich integrácie do zmysluplného celku riadiaceho systému.

8. Zoznam použitej literatúry

- [1] Novák, V.: *Základy fuzzy modelování*, Ostrava: BEN, 2000 ISBN 80-7300-009-1
- [2] Cornelius, T. Leondes: *Fuzzy Logic and Expert Systems Applications*, 1998
- [3] Jantzen J.: *Neurofuzzy Modelling*, Technical University of Denmark, 1998
- [4] Ojala T.: *Neuro-Fuzzy systems in control*, Tampere University of Technology, 1994
- [5] Dokumentácia k programu Matlab 6.5,
- [6] Abonyi J. et al.: *Compact TS-Fuzzy Models through Clustering and OLS plus FIS Model Reduction*, University of Veszprem
- [7] Fleming P., Purshouse R.: *Genetic algorithms in control systems engineering*, University of Sheffield UK, 2001
- [8] Hacker K., Kemper L.: *Robust design through the use of a hybrid genetic algorithm*, University of Buffalo, 2002
- [9] Goodrich M., Stirling W., Frost R.: *Model Predictive Satisficing Fuzzy Logic Control*, In: IEEE Transactions on fuzzy systems, vol. 7, 1999, no. 3
- [10] Haber, Bars: *Basic predictive control algorithms*, 2004
- [11] Hudzovič, P.: *Optimalizácia*, Bratislava: FEI STU, 2001 ISBN 80-227-1598-0
- [12] Vyskočil, J.: *Využitie fuzzy clusteringu v modelovaní nelineárnych systémov*, konferencia ŠVOČ, Bratislava: FEI STU, 2005
- [13] Doc. Ing. Sekaj, I. PhD.: *Evolučné výpočty a ich využitie v praxi*, Bratislava: FEI STU, 2005 ISBN 80-89018-87-4
- [14] Camacho E., Bordons C.: *Model Predictive Control*, Springer, 2004
- [15] Mitchell M.: *An Introduction to Genetic Algorithms*, MIT Press, 1996
- [16] Vyskočil, J., *Syntéza moderných prístupov v riadení*, konferencia ŠVOČ, Bratislava: FEI STU, 2007