

Kvantitatívne verzus kvalitatívne modely v automatickom riadení

Anton Kachaňák

V teórii automatického riadenia bolo rozpracovaných viacero prístupov pre návrh regulátora, resp. riadiaceho systému. Väčšina z nich je založená na predpoklade vytvorenia kvantitatívneho modelu, ktorý je potrebné získať fyzikálno-matematickou analýzou alebo experimentálnou identifikáciou. V prípade zložitých neurčitých procesov, keď nie je možné získať matematický model primeranej zložitosti pre účely návrhu riadenia, je potrebné použiť kvalitatívne formy modelov, ako napr. lingvistické modely, fuzzy modely, neuro-fuzzy modely... V príspevku sú analyzované zásady výberu vhodného modelu pre návrh riadiaceho systému. Poukazuje sa aj na súvislosti a obmedzenia v použití rôznych prístupov v modelovaní a riadení kontinuálnych procesov.

Úvod

Cieľom matematického modelovania v automatickom riadení je získanie matematického modelu na účely návrhu regulátora, resp. riadiaceho systému. Automatické riadenie je potrebné na stabilizáciu činnosti rôznych technických zariadení alebo na optimalizáciu prevádzky technologického procesu. Pri hľadaní vhodnej formy modelu je podstatný účel modelu, ktorý by mal byť čo najjednoduchší, ale pritom dostatočne adekvátny pre zadané požiadavky. Aj keď v súčasnosti neexistuje všeobecná a dostatočne efektívna teória modelovania, je možné formulovať základné princípy na tvorbu modelov a hlavné metodické postupy ich získania. Matematické kvantitatívne modely (napr. vo forme diferenciálnych rovníc), ako aj kvalitatívne modely (napr. v lingvistickej forme) je možné získať pomocou dvoch extrémnych prístupov, pritom ani jeden z týchto prístupov sa spravidla v praxi nevyskytuje v čistej forme. Prvý z nich je získanie modelu matematicko-fyzikálnou analýzou modelovaného objektu. Tento postup, označovaný ako deduktívny, vychádza z dostatočného objemu tzv. apriórnej informácie pri identifikácii modelu. Pri druhom prístupe je matematický model určený experimentálne, resp. meraním vstupov a výstupov na reálnom objekte. V tomto prípade, označovanom ako induktívny, je v závislosti od miery apriórnej informácie model určený z vyhodnotenia jednorazovo získaných experimentálnych dát alebo z priebežne získavaných dát pri tzv. adaptívnej identifikácii spravidla nestacionárneho objektu riadenia. Porovnávať vhodnosť uvedených prístupov je účelné iba pre konkrétne podmienky aplikácie a jasne formulované ciele využitia modelu. V príspevku použitá klasifikácia modelov na kvantitatívne a kvalitatívne nebola použitá náhodne, pretože vyjadruje tak historický vývoj pri tvorbe modelov, ako aj možnosti ich praktického využitia. V poslednom období začína narastať význam kvalitatívnych modelov. Súvisí to nielen s intenzívnym rozvojom umelej inteligencie, ale aj so záujmom o realizáciu inteligentných systémov. Tieto progresívne teoretické a technické prostriedky by mali umožniť realizáciu vyšších foriem riadenia a optimalizácie rôznych technických zariadení a technologických procesov.

1. Základné formy kvantitatívnych modelov a možnosti ich použitia v riadení

Dôležitým kritériom pre voľbu postupu modelovania je objem apriórnej a aposteriórnej (priebežnej) informácie, ktorý je možné pri modelovaní získať. V záujme dosiahnutia určitej kvality riadenia treba vedieť, že čím menšie sú možnosti získania priebežnej informácie, tým väčší musí byť objem apriórnej informácie a naopak. V každom prípade, ak sa to dá, je výhodné použiť vhodnú apriórnu informáciu, ktorá umožňuje nielen predikovať dynamické správa-

nie (dynamic behaviour) modelovaného objektu, ale získať aj informácie o štruktúre tzv. deterministického modelu. Pri tvorbe modelu matematicko-fyzikálnou analýzou sa model získava z formulácie základných fyzikálnych zákonov zachovania hmotnosti a energie a tzv. konštitučných rovníc vyjadrujúcich prenos hmotnosti a energie. Ak sa bilančné rovnice formulujú pre element konečných rozmerov, vedie to ku konečnorozmerným modelom, resp. k modelom so sústredenými parametrami, napr. vo forme obyčajných diferenciálnych rovníc (SSP – ODR). Pre bilančné rovnice diferenciálneho elementu získame nekonečnorozmerné modely alebo modely s rozloženými parametrami napr. vo forme parciálnych diferenciálnych rovníc (SRP – PDR). Na to, aby uvedené rovnice bolo možné nazvať modelom, je potrebné vymedziť predpoklady, resp. hypotézy, ktoré podmieňujú platnosť modelu. Snaha o väčšie využitie apriórnej informácie v matematickom modeli viedla v šesťdesiatych rokoch k formulácii deterministických úloh optimálneho riadenia [1], v ktorých je objekt riadenia (regulovaná sústava) opísaný pomocou PDR, resp. teoreticky ekvivalentnými modelmi vo forme integro-diferenciálnych rovníc alebo nekonečnorozmerným systémom ODR. Použitie modelov vo forme PDR, ktoré je spravidla nutné riešiť pomocou približných numerických metód, vychádza z predpokladu, že o riadenej sústave je k dispozícii apriórna informácia, ktorá umožňuje považovať model v tvare PDR za dostatočne adekvátny. Tento predpoklad je aktuálny pri relatívne jednoduchých procesoch so značným podielom apriórnej informácie, napr. pri jednoduchých lineárnych elektrických, mechanických a chemických sústav so zanedbateľným vplyvom neurčitosti na výsledok modelovania. V zložitejších sústavách je ďalším predpokladom možnosť ich dekompozície na jednoduchšie modely so zodpovedajúcimi počiatočnými, v prípade PDR aj okrajovými podmienkami. Za uvedených predpokladov sa získa tzv. nominálny matematický model, spravidla parametrickej štruktúry. Najkritickejším miestom pri takomto prístupe v modelovaní je určenie vhodnej štruktúry modelu. Vysoká zložitost štruktúry vedie nielen k veľkým výpočtovým požiadavkám a problémom s využitím modelu, ale aj k vysokej citlivosti na chyby parametrov modelu, čo môže spôsobiť i stratu robustnosti, a tým aj stratu vierohodnosti a spoľahlivosti použitia modelu. V prípade neurčitosti parametrov modelu a počiatočných i okrajových podmienok, je nutné redukovať túto neurčitost experimentálnou identifikáciou, ktorá bude úspešná, ak bude štruktúra modelu adekvátna k reálnej sústave. Inou možnosťou je vyjadrenie tzv. intervalovej parametrickej neurčitosti modelu a jeho využitie v teórii robustného riadenia. Požiadavky na objem apriórnej informácie je možné redukovať tiež apriórnu voľbu dostatočne jednoduchšej štruktúry modelu a priebežnou parametrickou identifikáciou. Pri takom prístupe je v záujme konvergenencie identifikačného algoritmu potreb-



né využiť heuristické znalosti o objekte identifikácie. Zložitosť tvorby modelov na účely návrhu riadenia spočíva tiež v tom, že matematický model by mal okrem kybernetických aspektov riadenia zohľadňovať aj rôzne ďalšie obmedzenia, napr. konštrukčné, energetické, ekonomické atď. Vo všeobecnosti je problém modelovania zložitý iteračný proces poznávania reálnych objektov, v ktorom sa uplatňujú tak deduktívne postupy tvorby modelu, simulácie, ako aj induktívne postupy experimentovania. Prítom treba zdôrazniť, že v súčasnosti nie sú matematické modely jedinou formou modelov, ktoré je možné použiť na návrh riadenia zložitých a neurčitých procesov.

2. Základné formy a vlastnosti kvalitatívnych modelov

Štúdium kvalitatívnych metód modelovania nie je nové, tieto metódy boli už použité v rôznych vedných odboroch, ako napr. v kvalitatívnej teórii diferenciálnych rovníc, kvalitatívnych metódach chémie, kvalitatívnych metódach ekonómie... Ďalej sa zameriame na využitie metód kvalitatívneho modelovania, najmä v súvislosti s počítačovou simuláciou a jej aplikáciou do oblasti riadenia. Pre kvalitatívne modely je charakteristické, že v porovnaní s kvantitatívnymi sú v odbornej literatúre omnoho menej rozpracované a dosiaľ nie je ustálená ani jednotná terminológia. Pod kvalitatívnym modelovaním a/alebo kvalitatívnou simuláciou sa označuje viacero metód. Sú to napr. metódy tzv. naivnej fyziky [3]. Uvedený prístup je charakterizovaný tým, že model má dobre definovanú, spravidla jednoduchú štruktúru. Pomocou transformácie stavových veličín na kvalitatívne premenné s konečnou usporiadanou množinou hodnôt a diskretizáciou nezávislej časovej premennej dostaneme kvalitatívny ekvivalent kvantitatívneho modelu. Kvalitatívne modelovanie nie je pritom alternatíva kvantitatívneho modelovania, ale uvedené prístupy sa viac dopĺňajú než nahrádzajú. V naivnej fyzike sa predpokladá nízky počet hodnôt kvalitatívnej premennej. V prípade troch hodnôt sa uvažuje konečná množina $\{-, 0, +\}$. Časové zobrazenie trajektórie kvalitatívnej premennej vyjadruje tzv. epizodické správanie kvalitatívneho modelu. Neskôr boli niektorými autormi zavedené ďalšie hodnoty kvalitatívnej premennej, resp. iné definície týchto hodnôt. Napr. Kuipers [4] uvažoval tiež hodnoty $-\infty, \infty$. Morgan [5] rozšíril množinu hodnôt $\{-, 0, +\}$ o ďalšie dva prvky. Symbol $?$ označuje neznámu hodnotu a \vee neprípustnú alebo nekonzistentnú hodnotu. Morgan okrem toho vyjadril každú kvalitatívnu premennú trojzložkovým vektorom, kde prvá zložka vyjadruje hodnotu spojitej premennej, druhá zložka jej prvú a tretia zložka druhú deriváciu tejto premennej. Pre kvalitatívne premenné boli zavedené operácie sčítania, odčítania, násobenia a delenia, ako aj integrovania vyjadrených pomocou pravdivostných tabuliek. Softvér, ktorý je k dispozícii pre uvedené operácie má názov Qual-Sim a bol vytvorený buď ako knižnica CTRL - C funkcie, alebo ako toolbox MATLABU. Na popis kvalitatívneho správania v naivnej fyzike sa využívajú rôzne formalizmy, napr. pojem konfluencie (kvalitatívnej diferenciálnej rovnice), binárne relácie Kuipers (1986) a matematická logika prvého rádu s využitím programovacieho jazyka PROLOG, Bratko (1989) atď.

Kľúčovým problémom pri kvalitatívnom modelovaní je určenie tzv. medzníkov (landmarks), ktoré oddeľujú jednotlivé hodnoty kvalitatívnej premennej, ako aj výber periódy vzorkovania od závislej časovej premennej. Problém medzníkov, ktorý obsahuje prvky subjektívnosti sa snažil vyriešiť L. Zadeh [2] zavedením fuzzy miery a formulovaním základov teórie fuzzy (neostrých) množín. Práve rozvoj teórie fuzzy množín a fuzzy logiky, ktorý sa začal v polovici šesťdesiatych rokov naznačil významný smer v modelovaní neurčitosti, resp. vágnosti, ktorá je v menšej alebo väčšej miere charakteristická pre každý reálny objekt. Teória fuzzy množín je zovšeobecnením klasickej teórie množín a v určitom zmysle aj teória pravdepodobnosti. Pokiaľ fuzzy množiny sú schopné vyjadriť vágnosť aj v prirodzenom jazyku, fuzzy miera vyjadruje neurčitosť matematicky, ktorá je spôsobená nedostatkom informácie.

Ďalšia forma kvalitatívneho modelovania bola zavedená J. Klírom [6] v roku 1970 s označením induktívne uvažovanie, ktoré vychádza zo všeobecnej teórie systémov. Je to úplne induktívna forma modelovania, ktorá pracuje s množinou bodov získaných meraním a identifikuje model na základe týchto meraní. V induktívnom modelovaní sú hodnoty kvalitatívnej premennej nazývané hladinami. Určovanie počtu hladín pre každú premennú, ako aj výber medzníkov, je potrebné konzultovať s expertom z daného odboru. Napr. v medicíne lekár určuje, kedy je možné považovať krvný tlak alebo srdcový rytmus za normálny, kriticky nízky alebo kriticky vysoký. Epizodické správanie v časovej histórii legálnych stavov je kvalitatívnou verziou kvantitatívnej trajektórie.

Kvalitatívne modelovanie, ktoré je charakteristické využívaním skúsenosti a znalosti, je možné interpretovať aj ako súčasť vedného odboru umelá inteligencia. Umelá inteligencia rozvíja rôzne metódy, ktoré umožňujú vo väčšej miere používať počítač na typicky ľudské činnosti, akými sú napr. lekárska alebo technická diagnostika, rozpoznávanie obrazov, inteligentné riadenie zložitých systémov atď. Ku kvalitatívnym modelom tejto kategórie patria napr. lingvistické (slovné) modely, rôzne formy grafických modelov, fuzzy modely neuro-fuzzy modely, kognitívne modely, evolučné (genetické) algoritmy atď. Intenzívny výskum týchto modelov bol podmienený jednak zvýšenými požiadavkami na realizáciu tzv. inteligentných systémov, ale aj väčšími možnosťami súčasných informačných technológií (machine intelligence). Riadenie veľmi zložitých a neurčitých procesov, ktoré je často realizované vo viacrovnových štruktúrach distribuovaného riadenia, vyžaduje hľadať nové metódy modelovania zohľadňujúce uvedené skutočnosti, keďže klasické kvantitatívne formy modelov sú prakticky nepoužiteľné. Pri metódach umelej inteligencie je charakteristické nahradenie spracovania dát spracovaním znalostí, ktoré môžu byť aj kvantitatívne nazývané tiež hlboké, napr. vo forme analytických vzťahov, resp. zákonitostí a kvalitatívne, nazývané tiež povrchové, napr. vo forme produkčných pravidiel, rámcov, predikátorových kalkulov a iných foriem reprezentácie heuristických znalostí. Povrchové znalosti vychádzajú z dlhodobej skúsenosti a praxe experta. Štruktúrovaná forma znalosti vedie k vytvoreniu expertného systému, častokrát pravidlového typu, ktorý umožňuje riešiť úlohy predikcie, plánovania, diagnostiky atď. aj používateľovi, ktorý nie je špecialistom v danej problémovej oblasti. Je to však komplikované tým, že znalosti sú často neurčité (fuzzy) a ťažko formalizovateľné. Zohľadnenie dočasných (temporálnych) znalostí viedlo k vytvoreniu expertných systémov reálneho času, ktoré sú už v praxi využívané vo funkcii radcu operátora pri riadení zložitých výrobných technológií.

Za špeciálnu triedu jednoúčelových (dedikovaných) expertných systémov reálneho času je možné považovať fuzzy regulátory (FLC), ktoré už dnes našli široké praktické uplatnenie, a patria skôr do oblasti inžinierskej problematiky návrhu inteligentných systémov, než do teórie kvalitatívneho modelovania a umelej inteligencie. Ako prvý použil fuzzy regulátor v praktickej aplikácii Mamdani v roku 1975 na základe motivácie prác Zadeha. Dnes je možné vytvoriť fuzzy analógie prakticky všetkých základných klasických regulačných algoritmov P, PI, PD, PID a vzniká len otázka, kedy to bude v konkrétnej aplikácii účelné. Použitie FLC môže byť buď ako náhrada klasického regulátora, ale aj ako systém na ladenie parametrov klasického regulátora a v neposlednom rade ako náhrada operátora na vyššej (dispečerskej) úrovni riadenia a experimentálnej optimalizácii riadeného procesu. Medzi významné vlastnosti fuzzy regulátora patri kvalitatívny charakter správania, a pri vhodnom výbere produkčných pravidiel tiež jeho jednoduchosť, robustnosť a možnosť využitia pri riadení zložitých nelineárnych procesov. Na druhej strane, aj keď návrh regulátora nevyžaduje znalosť matematického modelu procesu a nezávisí od zložitosti procesu, je potrebné použiť heuristické postupy a zložitú metodiku ladenia parametrov fuzzy regulátora, napr. využitím metód pokusu a opravy, číslcovej simulácie, prípadne metód učenia pomocou umelých neuronových sietí.





V posledných rokoch bol realizovaný intenzívny výskum tzv. umelých neurónových sietí (ANN), ktoré sa dnes označujú ako špeciálna trieda systémov umelej inteligencie s neštruktúrovanou formou vyjadrenia znalostí. Umelou neurónovou sieťou sa označuje masívny paralelný procesor, ktorý má schopnosť pamätať si znalosti získané experimentálne, a tieto znalosti ďalej využívať. Štruktúra neurónovej siete je tvorená jednotlivými neurónmi, ktoré sú pospájané synaptickými prepojeniami. Pomocou algoritmov učenia sa nastavujú parametre (váhy) jednotlivých prepojení, až kým sa nedosiahne požadovaná funkcia neurónovej siete. Od publikovania perceptrónu Rosenblatom (1961) bolo publikované o neurónových sieťach veľké množstvo prác, ktorých analýza je mimo rámca tohto príspevku. Stručne budeme iba charakterizovať neurónovú sieť ako univerzálny prostriedok modelovania, resp. univerzálny aproximátor správania. Neurónová sieť má dve fázy činnosti. Prvou je fáza učenia, kedy na základe experimentálne získaných vstupno-výstupných dát sa nastavujú váhy synaptických prepojení. Druhou je fáza života, resp. aplikácie, kedy sa neurónová sieť využíva na daný účel, napr. na počítačové modelovanie, pri prediktívnom riadení, optimalizácii procesu apod. Výhodou neurónovej siete je jej univerzálnosť použitia pre nelineárne a neurčité procesy. Nevýhodou je to, že pri učení je obtiažne využívať apriórnu informáciu na zrýchlenie procesu učenia. Ak nie je možné použiť princípy kontrolovaného učenia (s učiteľom), treba použiť nekontrolované učenie na princípe samoorganizácie (Kohonenove siete), prípadne použiť princíp učenia s hodnotením činnosti (reinforcement learning), ktorý navrhol Barto (1983) ako prístup vhodný do oblastí riadenia procesov. Na realizáciu princípov učenia boli vypracované ďalšie alternatívy algoritmov, napr. s využitím tzv. radiálnych bazových funkcií (RBF), genetických algoritmov atď.

Pre využitie neurónových sietí v riadení procesov sa ukázalo výhodné spojenie fuzzy regulátora a neurónovej siete. Fuzzy regulátor využíva apriórnu informáciu o riadenom procese a dopredná viacvrstváva neurónová sieť je použitá pre účely ladenia fuzzy regulátora pomocou reinforcementného učenia. Tak je možné vytvoriť hybridný neuro-fuzzy systém ako špecializovanú neurónovú sieť, v ktorej váhy predstavujú parametre funkcií príslušnosti fuzzy regulátora pri tzv. parametrickom učení. Zložitejšia je úloha tzv. štruktúrného učenia, pri ktorom je možné určovať tiež štruktúru fuzzy regulátora, čiže počet a tvary funkcií príslušnosti vstupných a výstupných premenných procesu [17]. K systémom uvedeného typu patria napr. neuro-fuzzy systémy ANFIS, NEFCON, FALCON, rozpracované v 90. rokoch. Systém NEFCON bol napr. úspešne aplikovaný na parametrické učenie pri dispečerskom riadení procesu vykurovania [16].

Z uvedenej analýzy vyplýva rozdiel medzi kvantitatívnou a kvalitatívnou formou modelu, ako aj veľká rozmanitosť foriem kvalitatívnych modelov (Cellier). Kvalitatívny model na rozdiel od kvantitatívneho nevyžaduje identifikáciu parametrov. Doterajšie skúsenosti ukázali, že uplatnenie kvantitatívnych deterministických, ako aj štatistických modelov, je limitované predpokladmi na ich použitie. Zadeh v tzv. princípe inkompatibility (1973) formuloval rozpor medzi zložitou a použiteľnosťou modelu. Feigenbaum vyslovil na základe toho tézu, že predpokladom úspešného riešenia problému sú špecifické znalosti (metódy), ktorými je potrebné nahradiť slabé všeobecné metódy. Z uvedeného vyplýva, že výber vhodného modelu určujú predovšetkým vlastnosti modelovaného objektu a cieľ modelovania. Je prirodzené, že iné požiadavky sa budú klásť na kvalitatívny model na účely rozpoznávania obrazov (pattern recognition), iné požiadavky na model určený na návrh riadenia v procesnej úrovni a iné na návrh vyšších úrovní riadenia. O význame rozvoja kvalitatívnych foriem modelov svedčí aj to, že cieľom modelovania spravidla nie sú čísla, ale skôr kvalitatívne charakteristiky reálnych objektov a hľadanie vhodnej formy komunikácie medzi počítačom a človekom (human-machine interface). Inak povedané, vhodnejšie je hľadať hoci menej presné užitočné riešenia problému, než riešenia presné a exaktné, ale

prakticky nepoužiteľné. Preto je možné predpokladať intenzívnejší rozvoj metód, ktoré sú založené na znalostiach a princípoch umelej inteligencie pri modelovaní zložitých a neurčitých procesov.

Záver

V predloženej príspevku je uvedená analýza vzťahu kvantitatívnych a kvalitatívnych modelov a možností ich použitia v riadení. Poukazuje sa na obmedzené možnosti kvantitatívnych modelov pri návrhu riadenia zložitých, nelineárnych a neurčitých procesov. Na druhej strane sú charakterizované základné formy kvalitatívnych modelov a zdôraznená perspektívnosť ich uplatnenia v technických, ale aj v netechnických odboroch. Je možné predpokladať intenzívny rozvoj najmä kvalitatívnych modelov, ktoré sú predmetom štúdií v oblasti umelej inteligencie, t. j. znalostných modelov, fuzzy modelov, neurónových modelov, genetických algoritmov, resp. ich kombinácií. Napr. v technických odboroch je možné predpokladať využitie uvedených foriem modelov pri realizácii vyšších foriem riadenia v hierarchických distribuovaných štruktúrach riadiacich systémov, pri tvorbe používateľského rozhrania človek – stroj (human machine interface), systémov SCADA, multiagentových systémoch atď. Významnými oblasťami pre využitie budú tiež netechnické odbory, napr. ekonomické, sociálne, biomedicínske, kde sú možnosti použitia kvantitatívnych modelov veľmi obmedzené. Je však treba upozorniť aj na určitú opatrnosť pri kvalitatívnom modelovaní a simulácii, ktoré sú v súčasnosti v štádiu výskumu a vývoja, takže tieto metódy by mali byť použité len v odôvodnených prípadoch aplikácií. V rámci rozsahu príspevku bolo možné analyzovať iba základné princípy kvalitatívneho modelovania, ktoré v súčasnosti v značnej miere využíva heuristické postupy, má však predpoklady pre ďalší rozvoj a využitie najmä v riadení procesov, ktoré sú charakteristické vyššou zložitou a neurčitou.

Literatúra

- [1] BUTKOVSKIJ, A.: Teorija optimalnogo upravlenija sistemami s raspredelemnymi parametrami. Izd. Nauka, Moskva 1965.
- [2] ZADEH, L. A.: Fuzzy Sets. Inf. Control 6, 8, 1965, pp. 338 – 353.
- [3] HAYES, P. J.: The Naive Physics Manifesto. In: Expert Systems in Micro-Electronic Age. Edinburg Univ. Press 1979, pp. 242 – 270.
- [4] KUIPERS, B. J.: Qualitative Simulation. Artif. Intell. 29, 1986, pp. 289 – 338.
- [5] MORGAN, A. J.: Accurac in Qualitative Descriptions of Behaviour. Proc. Sim. Conf. New Orleans. La, 1990, pp. 520 – 526.
- [6] KLIR, G. J.: Aspects of Uncertainty in Qualitative System Modeling. In: Fishwick, P., Luker, P. A.: Qualitative Simulation Modeling and Analysis. Vol. 5. Springer Verlag 1991, pp. 24 – 49.
- [7] HULKÓ, G., ANTONIOVÁ, M., BELAVÝ, C., BELANSKÝ, J., SZUDA, J., VÉGH, P.: Modeling, Control and Design of Distributed Parameter Systems, Publ. house STU Bratislava, 1998.
- [8] KACHAŇÁK, A., HOLIŠ, M., BELANSKÝ, J.: Control Systems Design for Building Heating Process using Neuro-fuzzy Approach. Proc. IFAC Symp. CSD, Bratislava 2000, pp. 560 – 565.
- [9] KACHAŇÁK, A., LEHOTSKÝ, M.: Analysis of Neuro-fuzzy Systems with Structural and Parametric learning Characteristics. Proc. Int. Conf. Process Control. Kouty nad Desnou 2002. CD ROM

doc. Anton Kachaňák, CSc.

**Katedra automatizácie a merania
Strojnícka fakulta, STU Bratislava
e-mail: kachanak@kam.vvm.stuba.sk**

43