

Metodika generování a ladění modelů neuronových sítí

Martin Moštěk

Katedra měřicí a řídicí techniky, FEI, VŠB – Technická univerzita Ostrava
17. listopadu 15, 708 33, Ostrava-Poruba
martin.mostek@vsb.cz

Abstrakt. Referát je věnován problematice řešení návrhu, ladění a použití fuzzy pravidlových modelů typu Takagi-Sugeno ve schématu prediktivního regulátoru. Značná část práce je věnována metodice návrhu procesu generování tréninkových množin, nezbytných pro vytvoření fuzzy pravidlového modelu. Referát také obsahuje ověření navržených metod simulačními experimenty.

Klíčová slova: Jazykové modely, umělá inteligence, fuzzy-neuronová síť, Takagi-Sugeno modely, generování tréninkové množiny, adekvátnost modelu, ztrátová funkce, predikční regulátor, kvalita regulace.

1 Úvod

Moderní teorie řízení hledá stále nové přístupy k zajištění co nejlepší kvality regulace v často komplikovaných podmínkách praktických realizací. Jednou z možných řešení je použití systémů prediktivního řízení. Prediktivní regulátory jsou nejčastěji používány při řízení komplexních soustav, kde použití jednodušších (PID) regulátorů selhává.

Vyšetřování vlastností prediktivních regulátorů prokázalo, že kvalita jejich řízení je přímo závislá na kvalitě jejich predikčního modelu.

Významnou pozici v oblasti metod samoučících se modelů zauímají umělé neuronové sítě, které jsou produktem vědního oboru umělé inteligence. Neuronové sítě jsou prostředkem pro identifikaci modelů pomocí tréninkových množin naměřených dat.

Nevýhodou modelů získaných použitím konvenčních neuronových sítí je úplná absence možnosti kontroly konkrétní struktury a parametrů identifikovaného modelu. V mnohých případech přinesly velmi dobré výsledky neuronové sítě, vybavené procedurami pro realizaci fuzzy množinových a fuzzy logických operací, které umožňují identifikovat fuzzy pravidlové modely. Vznikají tak hybridní fuzzy-neuronové sítě.

Fuzzy-neuronové sítě jsou často koncipovány pro strukturální a parametrickou identifikaci fuzzy modelů typu Takagi-Sugeno.

2 Fuzzy-neuronové modely typu Takagi-Sugeno


FN modely jsou struktury, využívající prostředí neuronových sítí k automatické identifikaci fuzzy pravidlových modelů. K identifikaci jsou využívána naměřená vstup-výstupní data (tréninkové množiny). Fuzzy neuronové modely typu Takagi-Sugeno jsou formalizovány jazykovým zápisem[1]:

$$\text{IF } (x_1 \text{ is } A_1) \text{ and } (x_2 \text{ is } A_2) \text{ and } \dots \text{ and } (x_n \text{ is } A_n) \text{ THEN } y = f(x_p), p = 1, \dots, n \quad (1)$$

Modely Takagi-Sugeno jsou základem modelů pro prediktivní řízení. K jejich identifikaci je požito prostředí umělé neuronové sítě využívající speciální procedury FuzNet s využitím vstupně-výstupních naměřených dat (tréninkové množiny) [2].

3 Nelineární predikční řízení s fuzzy modelem

Struktura nelineárního predikčního řízení s fuzzy modelem vychází z principů publikovaných v [3]. Základní myšlenkou této řídicí struktury je použití algoritmů optimalizace nelineárního problému s využitím samotného neuronového modelu soustavy. Je řešena obdobná úloha jako při učení neuronové sítě, kdy se mění váhy tak, aby pro daný vstup síť produkovala požadovaný výstup. V případě řízení modifikujeme nikoli váhy, ale vstupní vektor sítě (modelu) tak, aby výstup modelu maximálně odpovídal požadovanému výstupu. Schéma takového predikčního řízení je na dalším obrázku.



Obr. 1. Schéma predikčního řízení.

K minimalizaci řídicího kritéria je nutno mít neuronový model soustavy predikující výstupy nejen pro další krok, ale pro celý predikční horizont. Tuto funkci zajišťuje tzv. vícekrokový neuronový prediktor.

4 Identifikace T-S modelů s použitím procedury FUZNET

Pro realizaci vícekrokového neuro-fuzzy prediktoru byl v [4] použit vývojový fuzzy-neuronový systém FuzNet. Tento systém umožňuje vytvořit fuzzy-neuronovou síť FNS, identifikovat parametry fuzzy-neuronového modelu a testovat identifikovaný model na reálných datech. Tento systém vznikl jako rozšíření simulátoru neuronové sítě založeného na algoritmu Back Propagation [5].

5 Metodika generování tréninkové množiny pro identifikaci FNTS modelu

Před tím než lze identifikovat fuzzy neuronový model typu Takagi-Sugeno (FNTS), se musí zkoumat vlastnosti testovaných modelovaných soustav. Pochopení charakteru, dynamických a statických vlastností daných soustav je důležité pro vytvoření vhodné trénovací množiny. Informace obsažené v tréninkové množině totiž zásadním způsobem ovlivňují vlastnosti FNTS modelu, který je touto množinou adaptován. Cílem přípravy vhodné tréninkové množiny tedy je vygenerovat takový vstupní signál $u(t)$, resp. posloupnost vzorků či hodnot signálu, jenž po průchodu modelovanou soustavou zachytí maximum statických a především dynamických vlastností modelované soustavy [4].

Jednou z metod, pomocí níž lze tyto poznatky získat, je například přechodová charakteristika $h(t)$, která definuje odezvu dané soustavy s přenosem $G_s(t)$ (resp. $G_s(s)$), na jednotkový skok $I(t)$. Matematické vyjádření přechodové charakteristiky pomocí zpětné Laplaceovy transformace je v následující rovnici [6].

$$h(t) = L^{-1}\{H(s)\} = L^{-1}\left\{G(s) \cdot \frac{1}{s}\right\} \quad (2)$$

kde $h(t)$ je přechodová charakteristika soustavy s přenosem dané soustavy $G(s)$.

Z přechodové charakteristiky lze určit dobu ustálení přechodového děje $T_{ust}(t)$, což je důležitý poznatek o chování modelovaných soustav. Na základě určení délky trvání přechodového děje $T_{ust}(t)$, lze určit nejvhodnější vzorkovací čas $TS(t)$ (Time Sampling).

6 Nelineární Stanovení vhodného vzorkovacího času $TS(t)$

Během testování různých typů modelů s různými experimentálně nastavenými hodnotami vzorkovacího času $TS(t)$ pro dané soustavy vyplynulo, že jako nejvhodnější se jeví volit vzorkovací čas tak, abychom získali minimálně sedm vzorků do doby ustálení přechodového děje $T_{ust}(t)$. Tento poznatek popisuje následující rovnice.

$$TS(t) \cong \frac{T_{ust}(t)}{7} [s] \quad (3)$$

V případě, že se nedodrží minimální počet sedmi vzorků na dobu ustáleného děje $T_{ust}(t)$, nejsou dynamické a statické vlastnosti modelované soustavy adekvátně zachyceny v tréninkové množině.

7 Generování vstupního signálu $u(t)$, nastavení koeficientu variability K

Jako vhodný signál pro učení FNTS modelů je použit sled obdélníkových pulsů o náhodné frekvenci a amplitudě, přičemž pro praktické použití se velikost změn amplitudy omezí maximální a minimální hodnotou. Pro náš případ fuzzy-neuronového modelu použijeme funkci PRS pro prostředí Matlab, jejímž autorem je Magnus Norgaard [7]. Funkce je řešena tak, že v náhodných okamžicích je změněna její hodnota na novou náhodnou hodnotu v intervalu min a max. Frekvenci změn signálu lze měnit od konstantního signálu po bílý šum, nastavením koeficientu variability K .

Teoreticky se jako nejvhodnější tréninkový signál jeví takový signál, který má rovnoměrně zastoupeny dynamické a statické vlastnosti, tedy po sérii skokových změn o různých amplitudách následuje statická hodnota o různé amplitudě a opět série skokových změn o různé amplitudě atd.

Při experimentálním nastavování koeficientu K pro různé testované soustavy, byl zjištěn poznatek, že při nastavení vysoké četnosti skoků (velká hodnota koeficientu K), jsou vytvořené impulsy skoků již přes příliš úzké, než aby se na nich mohla projevit odezva soustavy, to znamená, že se ztrácejí informace o sledované soustavě. Navíc délka trvání dalších statických hodnot (o různých amplitudách) je často příliš malá, než aby tréninková množina zachytila statické chování modelované soustavy. Proto je FNTS model, který je touto množinou adaptován, nekvalitní a pro predikční regulaci nevhodný.

Shrnutí předchozích poznatků o nastavování koeficientu variability K vede k návrhu postupu jeho stanovení. Koeficient variability K musí být zvolen tak, aby v časové řadě náhodně generovaných vstupních obdélníkových impulsů, byly (kromě jiných) obsaženy impulsy, jejichž šířka T_{imp} splňuje podmínku

$$T_{imp} \cong 4T_{ust}(t) [s], \quad (4)$$

a impulsy, splňující podmínku

$$T_{imp} \cong T_{ust}(t) [s], \quad (5)$$

kde T_{ust} je doba ustálení identifikované soustavy.

Pro ověření systému prediktivního řízení složitých soustav byla náhodně vybrána soustava třetího řádu s neznámým dopravním zpožděním. Přenos soustavy $G_s(s)$, je v následující rovnici.

$$G_s(s) = \frac{2s^2 + 2s - 2}{1s^3 + 1.79s^2 + 1.43s + 0.44} \quad (6)$$

Nejprve u zkoumané soustavy určíme přechodovou charakteristiku. Z grafu jejího průběhu zjistíme že, se jedná o soustavu s derivačním charakterem se zápornou ustálenou hodnotou. Doba ustálení přechodového děje $T_{ust}(t)$ této soustavy, je $T_{ust}(t)=10s$.

Dosadíme hodnotu $T_{ust}(t)$ do rovnice (3) a po zaokrouhlení obdržíme hodnotu $TS(t) = 1,5 s$. Jakmile, je určen vhodný vzorkovací čas $TS(t)$ pro dané soustavy, můžeme již přistoupit k fázi generování optimálního vstupního signálu $u(t)$.

8 Hodnoticí ztrátová funkce

K posouzení kvality experimentálních regulačních dějů byla použita v [4] číselná charakteristika označovaná jako integrální kvadratické kritérium SSE (Sum of Squares of the Error) ve tvaru:

$$SSE = \sum_{i=1}^{\text{celkový poč. vzorků}} [y(i) - w(i)]^2 \quad (7)$$

kde *celkový počet vzorků* představuje počet vzorkovacích okamžiků za celou dobu trvání regulačního děje.

Obecně lze říci, že čím je hodnota SSE vyšší, tím je kvalita regulace horší.


9 Srovnávací regulátor

Abychom mohli posoudit kvalitu regulace s predikčním regulátorem, musíme navrhnout pro soustavu s přenosem $G_s(s)$ srovnávací regulátor.

Návrh PID regulátoru pro tuto soustavu nelze realizovat, protože je tato soustava s derivačním charakterem a se zápornou ustálenou hodnotou. Bylo tedy nutné navrhnout LQR regulátor. Následující rovnice popisuje přenos otevřené smyčky $G_o(s)$, pro tuto soustavu s přenosem $G_s(s)$.

$$G_o(s) = \frac{2s^2 + 2s - 2}{1s^3 + 3.8715s^2 + 5.3222s + 2.0478} \quad (8)$$

A nyní již můžeme porovnat výsledky dosažené z predikčního regulátoru a srovnávacího LQR regulátoru.



Obr. 2. Porovnání výsledků Predikčního a srovnávacího LQR regulátoru.

Na obrázku číslo 2 je vidět, průběh regulace predikčního regulátoru a srovnávacího LQR regulátoru. Hodnota SSE je při použití predikčního regulátoru $SSE = 31,753702$. Srovnávací LQR regulátor dosáhl hodnotu $SSE = 116,103030$. Kvalita regulace soustavy s přenosem $G_s(s)$ je při použití predikčního regulátoru mnohonásobně lepší

v porovnání s výsledky srovnávacího LQR regulátoru. Nelineární predikční řízení regulaci této soustavy zvládá s velmi dobrými výsledky a naměřené hodnoty SSE tento fakt plně podporují.

10 Závěr

Požadavek vysoké kvality regulačního procesu predikčního regulátoru je podmíněn mj. vysokou kvalitou jeho predikčního modelu. Predikční regulátory jsou používány pro řízení komplikovaných a proto obtížně matematicky formalizovatelných soustav. Teoretickým výsledkem řešení je v první řadě vypracování metodiky návrhu režimu generování tréninkové množiny vstupních a výstupních dat, nutných pro automatickou strukturální i parametrickou identifikaci predikčního fuzzy modelu v prostřední umělé fuzzy neuronové síti FuzNet. Metodika vychází z analýzy vlivu vlastností tréninkové množiny na kvalitu naučeného fuzzy modelu a stanoví podmínky pro algoritmus generování náhodného vstupního signálu tréninkové množiny. Výsledky řešení přispívají ke zvýšení efektivity návrhu predikčních regulátorů snížením časových nároků potřebných k hledání nejlepší trénovací množiny pro učení predikčního fuzzy neuronového modelu a snížení času potřebného k nalezení optimálních hodnot parametrů řídicího predikčního algoritmu.

Tento referát byl vytvořen za pomoci grantu FRVŠ 2003, číslo 1731

Reference

- 1 Pokorný, M. *Umělá inteligence v modelování a řízení*. BEN Praha 1996
- 2 Čermák P. *Využití neuronových sítí pro identifikaci fuzzy modelů*. Disertační práce. VŠB-TU Ostrava 2000.
- 3 Najvárek J. *Neuronové sítě v prediktivním řízení*. Disertační práce. VUT Brno 1998
- 4 Rehberger I. *Prediktivní fuzzy regulátor*. teze Disertační práce. VŠB-TU Ostrava 2001.
- 5 Klir J.G. *The role of uncertainty measure and principles in AI*. Proc. AI'91. Praha 1991.
- 6 Vavřín P. *Teorie Automatického řízení I*. Skripta. VUT Brno 1991.
- 7 Norgaard M., Ravn O., Poulsen N. K., Hansen L. K. *Neural Networks for Modelling and Control of Dynamic Systems*. Springer-Verlag. London 2000

Annotation:

Methodology of Creating and Tuning Neural Network Models

The paper is aimed on problems solving design and tuning of Takagi-Sugeno fuzzy models application in predictive control scheme. The main part of work is dedicated to methodology of training data set generation, which are necessary to create Takagi-Sugeno fuzzy models. The paper contains some numerical simulation experiments to prove designed methods.