

IDENTIFIKACIJA PROCESA MANEVRIRANJA BRODOM POMOĆU STATIČKE NEURONSKE MREŽE

Petar Matić, Danko Kezić, Pero Vidan.
Pomorski fakultet u Splitu
Zrinsko-Frankopanska 38, 21000 Split, Hrvatska

Sažetak:

Točniji model manevriranja brodom za potrebe prediktivnog vođenja doprinio bi povećanju sigurnosti i radne učinkovitosti broda. Eksperimentalni model dobiven identifikacijom jednostavniji je od fizikalnog modela i bolje opisuje ulazno-izlazno vladanje procesa, što ga čini prikladnim za projektiranje sustava vođenja. Međutim, u nekim slučajevima određivanje modela identifikacijom sustava uobičajenim metodama nije moguće. Takav primjer predstavlja i slučaj određivanja modela broda kod kojeg se javlja takozvani „ill-conditioning problem”. Pozornost ovog rada posvećena je identifikaciji sustava manevriranja brodom pomoću statičke neuronske mreže kojim bi se takav problem riješio. Eksperiment prikupljanja podataka za treniranje neuronske mreže proveden je simulacijski, u Matlabu 7.6.0 (R2008a), pomoću Nomotovog modela drugog reda. Unaprijedna neuronska mreža koja koristi NARX strukturu trenirana je Levenberg-Marquardt algoritmom kako bi se formirao neuronski model manevriranja brodom. Neuronski model je uspješno ispitan simuliranjem „Zig-zag“ manevra za tri različita slučaja.

IDENTIFICATION OF SHIP STEERING DYNAMICS USING NEURAL NETWORK

Abstract:

More accurate system model for MPC (Model Predictive Control) would increase system safety and operating efficiency. Models built from measured data, although do not reveal physical properties of the system better describe their input-output relationship and as such are more convenient for MPC. In some cases, standard system identification of ship manoeuvring is not possible because of an “ill-conditioning property”. This paper is concerned with identification of ship steering dynamics using static neural network, which would solve this problem. Feed-forward neural network that uses NARX model is trained with Levenberg-Marquardt algorithm in Matlab 7.6.0 (R2008a), with data gained through simulation experiment conducted on 2nd order Nomoto model. Neural model of ship steering dynamics was then successfully tested in three different cases of “Zig-zag” manoeuvre.

1. UVOD

Temeljni pristup projektiranju regulatora kaže kako je regulator moguće projektirati ukoliko su poznati sustav i njegova okolina [1]. Različite metode adaptivnog vođenja, kao što su Model Reference Adaptive Systems (MRAS), ali i metode podešavanja regulatora, kao što je Self-Tuning Regulators (STR), koriste model sustava za njegovo vođenje. Jedna od najčešće korištenih metoda vođenja, Model Predictive Control (MPC)

također koristi model sustava za njegovo vođenje, kao što je to opisano u [2]. Očito je model sustava temeljna komponenta naprednih metoda vođenja pa je dobivanje kvalitetnog modela preduvjet za kvalitetno vođenje sustava. U osnovi se matematički modeli sustava mogu podijeliti na teorijske modele, dobivene na temelju analitičkih izraza koji opisuju fizikalne zakonitosti razmatranog sustava, i eksperimentalne modele, dobivene na temelju mjerenja ulaznih i izlaznih vrijednosti sustava. Eksperimentalni model dobiven

identifikacijom, iako ne daje uvid u zbivanja u procesu, jednostavniji je od teorijskog modela i bolje opisuje ulazno-izlazno vladanje procesa, što ga čini prikladnim za projektiranje sustava vođenja [3]. U nekim slučajevima određivanje modela identifikacijom sustava uobičajenim metodama nije moguće. Takav primjer predstavlja i slučaj određivanja modela broda kod kojeg se javlja “*ill-conditioning problem*”. U tom je slučaju potrebno razmotriti alternativna rješenja kao što je uporaba umjetnih neuronskih mreža.

MLP (*Multi Layer Perceptron*) neuronska mreža, trenirana BP (*Back-propagation*) algoritmom, s nelinearnom aktivacijskom funkcijom u skrivenom sloju i linearnom funkcijom u izlaznom sloju, uz uporabu odgovarajućeg broja neurona, može s određenom točnošću aproksimirati bilo koju nelinearnu funkciju [3]. Rezultati mnogih radova, kao što su [4], [5] i [6] promovirali su neuronsku mrežu u jedan od vodećih alata za identifikaciju složenih nelinearnih sustava.

Manevriranje brodovima je složen zadatak jer je brod složen objekt koji prvenstveno zbog izrazito velike mase ima spor odziv na zadane pobude, bilo da je riječ o pobudi u vidu zakreta kormila ili neželjenim promjena iz okoline. Pojava zakašnjele promjene kursa čest je slučaj, a naročito opasan ukoliko se radi o promjeni kursa za izbjegavanje nesreće. Također, kašnjenje odziva broda ima za posljedicu dodatna pomicanja kormila koja djeluju negativno na željenu brzinu broda i potrošnju goriva [9]. Što točniji model manevriranja brodom za potrebe prediktivnog vođenja broda doprinio bi povećanju sigurnosti i radne učinkovitosti broda. Kao što to pokazuju rezultati iz radova [7], [8] i [9] dobre rezultate moguće je postići uporabom neuronske mreže. Pomoću neuronske mreže moguće je dobiti bolji, precizniji model sustava koji tada omogućava i bolje vođenje.

Pozornost ovog rada posvećena je identifikaciji sustava manevriranja brodom pomoću statičke neuronske mreže. Postupak identifikacije proveden je simulacijski, u Matlabu 7.6.0 (R2008a), na temelju podataka prikupljenih snimanjem odziva Nomotovog modela drugog reda. Simulacijski rezultati prikazuju uspješnost predložene metode. Sijedeći korak u smjeru formiranja kvalitetnog modela broda za potrebe vođenja bio bi treniranje neuronskog modela opisanog u ovom radu podacima dobivenim mjerenjima na stvarnom objektu.

2. IDENTIFIKACIJA SUSTAVA POMOĆU NEURONSKE MREŽE

Proces manevriranja brodom se može detaljno opisati složenim matematičkim modelima na način prikazan u radovima [8], [10], [11] i [12]. Međutim, ukoliko se model koristi za vođenje sustava tada su

prikladniji modeli u obliku prijenosne funkcije, prvenstveno zbog mogućnosti provođenja postupka identifikacije. Nomotovim modelom drugog reda (1), detaljno opisanim u [11], može se dobro modelirati proces manevriranja brodom, ukoliko je takav model moguće postaviti.

$$\frac{r}{\delta} = \frac{K(1+T_3s)}{(1+T_1s)(1+T_2s)} \quad (1)$$

Naime, u praksi je čest slučaj jednakosti $T_2 = T_3$ pa se nula i pol prijenosne funkcije međusobno ponište i sustav postaje nemoguće identificirati. Ovaj problem se naziva “*ill-conditioning problem*” i predstavlja ozbiljnu prepreku u korištenju Nomotovog modela drugog reda za identifikaciju procesa manevriranja brodom.

2.1. Opis metode

Jedno od rješenja koje se često primjenjuje u identifikaciji sustava su umjetne neuronske mreže, detaljno opisane u [13]. Neuronske mreže se mogu koristiti za formiranje modela „crnih kutija“ (*Black-box approach*) na temelju prikupljenih ulaznih i izlaznih informacija sustava. Predstavljanjem dovoljno velikog broja ulazno-izlaznih parova, kroz proces učenja neuronska mreža može usvojiti zakonitost prema kojoj se ulazne vrijednosti preslikavaju u izlazne, odnosno aproksimirati funkciju prema kojoj se preslikavanje odvija.

Izbor strukture modela je najvažniji korak postupka identifikacije. Najčešće korištena struktura nelinearnog modela sustava prikladna za primjenu neuronskih mreža je NARX struktura modela. NARX model se dobije primjenom nelinearne regresije nad prošlim mjernim uzorcima izlaznih i ulaznih signala procesa:

$$y(k) = f(y^{k-1}, u^{k-1}) + \xi(k) \quad (2)$$

NARX model, opisan u [3], može se smatrati općim modelom nelinearnih sustava. Izlaz NARX modela (3), je u biti procijenjena vrijednosti izlaznog signala procesa u k -tom koraku, izračunata u $k-1$ koraku na temelju trenutno dostupnih ulaznih i izlaznih signala procesa.

$$\hat{y}(k) = f_N(\varphi(k), \theta) \quad (3)$$

gdje je $\varphi(k)$ regresijski vektor, definiran izrazom:

$$\begin{aligned} \varphi(k) &= [\varphi_y(k), \varphi_u(k)] = \\ &= [y(k-1), \dots, y(k-a), u(k-1), \dots, u(k-b)]^T \end{aligned} \quad (4)$$

NARX model nema povratnih veza pa njegovi regresori ne ovise o parametrima modela. Ovo svojstvo čini NARX model strukturno stabilnim. Kao parametrirana nelinearna funkcija f_N može se koristiti neuronska mreža koja ima svojstva univerzalnog aproksimatora [3].

Više-slojni perceptron (*MLP, Multi-Layer Perceptron*), koji u skrivenom sloju koristi sigmoidalnu (tansig), a u izlaznom sloju linearnu aktivacijsku funkciju, je univerzalni aproksimator i može se koristiti za identifikaciju sustava [14].

2.2. Simulacijsko istraživanje

Kako bi se izradio neuronski model manevriranja brodom korišten je Matlab 7.6.0 (R2008a). Za potrebe ovog rada, uobičajeni postupak prikupljanja podataka mjerenjima na stvarnom objektu zamijenjen je simuliranjem na računalu, prvenstveno zbog jednostavnosti, ali i ekonomskih razloga.

Prema Nomotovom modelu drugog reda iz rada [11] izrađen je simulacijski model sustava u Matlab/Simulinku, kako bi se prikupili potrebni podaci za treniranje mreže. Simulacija se odvija s vremenom uzorkovanja $T_s = 0.1$ s, a vrijeme trajanja simulacije je $T = 1000$ s, što znači da je simuliranjem procesa na digitalnom računalu prikupljeno 10 000 uzoraka za treniranje mreže.

Pobudni signal je linearni signal sa superponiranom smetnjom BLWNS (*Band Limited White Noise*) i ponavlja se s različitim periodom, a ima značenje promjene kuta kormila od -30° do 30° i obratno, različitom brzinom. BLWNS se koristi zbog svojih svojstava, opisanih u radu [3], koja omogućavaju provođenje procesa identifikacije.

Ulazni podaci za provedbu postupka identifikacije sustava pomoću statičke neuronske mreže, prema NARX modelu, su članovi regresijskog vektora, koji u ovom slučaju ima 6 članova, tri uzastopna uzorka pobudnog signala: $x(k-1)$, $x(k-2)$, $x(k-3)$ i tri uzastopna uzorka izlaznog signala: $y(k-1)$, $y(k-2)$, $y(k-3)$.

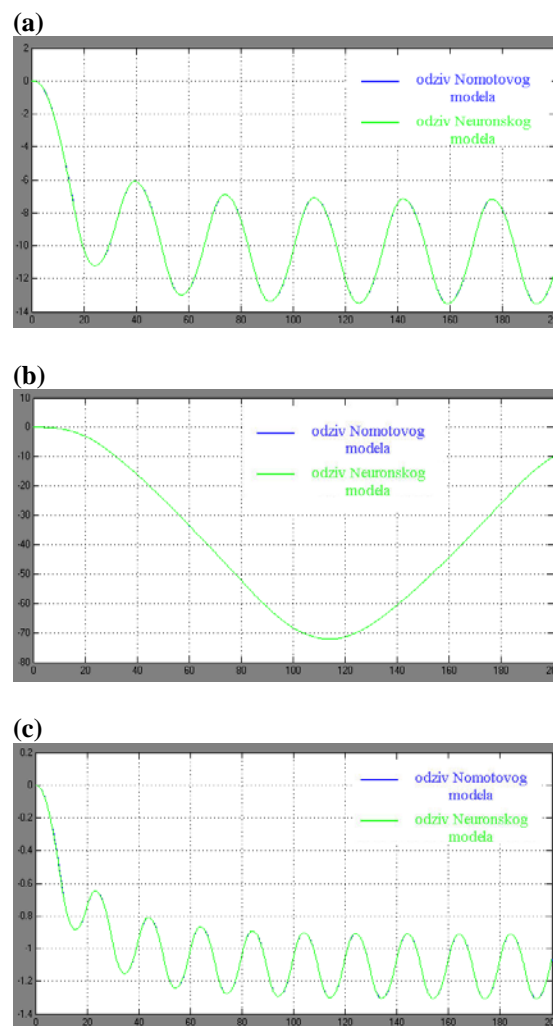
Za modeliranje procesa manevriranja brodom koristi se MLP s 18 neurona skrivenog sloja sa sigmoidalnom aktivacijskom funkcijom, jedan izlazni neuron s linearnom aktivacijskom funkcijom, Levenberg-Marquardt algoritam za treniranje i metodu ranog zaustavljanja. Treniranje mreže se zaustavlja kad srednja kvadratna pogreška (*MSE, Mean Square Error*) konvergira ka nekoj minimalnoj vrijednosti. U konačnom je odabran slučaj u kojem se postiže vrijednost pogreške $MSE = 1.21 \cdot 10^{-10}$, nakon 1000 epoha.

2.3. Rezultati simulacijskog istraživanja

Kako bi se ispitala vrijednost dobivenog modela potrebno ga je testirati u novim, nepoznatim situacijama koje modelu nisu predstavljene u

procesu treniranja. Ovo znači da je potrebno koristiti različite pobude za treniranje i testiranje modela. Neuronski model testiran je u „Zig-Zag“ manevru. Uobičajeni postupak provođenja „Zig-Zag“ manevra opisan je u [8].

Napravljena su tri različita slučaja ispitivanja modela, koja podrazumijevaju različite brzine zakreta kormila, različite maksimalne položaje te različitu učestalost promjene položaja lista kormila.



Sl. 1. Usporedba odziva sustava i odziva modela (a) u prvom, (b) drugom i (c) trećem slučaju

Slika 1 (a), (b) i (c) prikazuje usporedbu odziva sustava opisanog Nomotovim modelom drugog reda i neuronskog modela dobivenog identifikacijom. Odzivi se preklapaju pa je sa slike gotovo nemoguće utvrditi razliku između dva odziva.

3. ZAKLJUČAK

Cilj ovog rada je bio identifikacija broda pomoću neuronske mreže, pri čemu se brod kao

sustava promatra iz perspektive manevriranja i opisuje modelom koji dovodi u izravnu vezu položaj kormila i kurs broda. Osnovni zadatak bi je formirati neuronski model koji što točnije predstavlja promatrani sustav.

Neuronski model je ispitan simuliranjem „Zig-zag“ manevra za tri različita slučaja. U sva tri slučaja simulacijski rezultati su jako dobri pa se može zaključiti da je modeliranje procesa manevriranja brodom predloženim neuronskim modelom uspješno provedeno. Neuronski model dobiven identifikacijom daje odziv identičan odzivu modela koji je korišten za prikupljanje podataka pa se može pretpostaviti da bi neuronski model dobiven na temelju mjerenja provedenih na stvarnom objektu također bio dobar.

Dakle, slijedeći korak u smjeru formiranja kvalitetnog modela broda za potrebe vođenja bio bi treniranje neuronskog modela opisanog u ovom radu podacima dobivenim mjerenjima na stvarnom objektu.

Postojanje kvalitetnog modela koji vjerodostojno predstavlja sustav je preduvjet za kvalitetno vođenje sustava pa je, za slučaj nemogućeg određivanja kvalitetnog modela tradicionalnim identifikacijskim postupcima, identifikacija sustava pomoću neuronske mreže očito dobro rješenje.

4. LITERATURA

- [1] K.J. Astrom, B. Wittenmark: “*Adaptive Control*”, Addison-Wesley, 1989.
- [2] M.T. Hagan, H.B. Demuth, and M.H. Beale: *Neural Network Toolbox™ 6, User’s Guide*, MATLAB, 2008.
- [3] I. Petrović: „*Identifikacija nelinearnih dinamičkih procesa statičkim neuronskim mrežama, doktorska disertacija*“, FER, Zagreb, 1998.
- [4] R.K. Al Seyab, Y. Cao: “*Nonlinear system identification for predictive control using continuous time recurrent neural networks and automatic differentiation*”, *Journal of Process Control*, Volume 18, Issue 6, July 2008, Pages 568-581, October 2007.
- [5] K.S. Narendra, K. Parthasarathy: “*Identification and Control of Dynamical Systems Using Neural Networks*”, *IEEE Transactions on Neural Networks*, Vol. 1, No. 1, Pages 4-27, March 1990.
- [6] J. Sjöberg, H. Hjalmarsson, L. Ljung: “*Neural Networks in System identification*”, In *Proc. 10th IFAC Symposium on System Identification (SYSID'94)*, volume 2, pages 49-72, Copenhagen, Denmark, 1994.
- [7] S. Beroš, R. Markovina, J. Šoda: “*Modeling of Neural Network Autopilot*”, 11th Congress of the International Maritime Association of the Mediterranean (IMAM), 2005.
- [8] Y. Cao, Z. Zhou, W.S. Vorus: “*Application of Neural Network Predictor/Controller to Dynamic Positioning of Offshore Structures*”, *Dynamic Positioning Conference - Advances in Technology*, 2000.
- [9] H. El-Tahan: “*Development and Field Testing of a Neural Network Ship Predictor System (SPS)*”, CORTEC Incorporated, January 1999.
- [10] T.I. Fossen: “*A Nonlinear Unified State-Space Model for Ship Maneuvering and Control in a Seaway*”, *Journal of Bifurcation and Chaos in Applied Sciences and Engineering*, 2005, Vol. 15, No. 9, pp. 2717-2746.
- [11] C. Tzeng, J. Chen: “*Fundamental Properties of Linear Ship Steering Dynamic Models*”, *Journal of Marine Science and Technology*, Vol.7, No.2, pp. 79-88, 1999.
- [12] R. Skjetne, Ø.N. Smogeli, T.I. Fossen: “*A Nonlinear Ship Manoeuvring Model: Identification and adaptive control with experiments for a model ship*”, *Modeling, Identification and Control*, Vol.25, No.1, 3-27, 2004.
- [13] S. Haykin: “*Neural Networks: A Comprehensive Foundation*”, NY: Macmillan, 1994.
- [14] M.T. Hagan, H.B. Demuth, O. De Jesus: “*An introduction to the use of neural networks in control systems*”, *International Journal of Robust and Nonlinear Control*, Vol. 12, No. 11, September, 2002, pp. 959-985.