

VYUŽITIE NEURÓNOVÝCH SIETI NA MODELOVANIE MECHATRONICKÝCH SYSTÉMOV

Ing. Róbert Bartko¹

Trenčianska univerzita Alexandra Dubčeka v Trenčíne

Úvod

Umelé neurónové siete vznikali ako pokus modelovať mozog a jeho činnosť. Vzniklo mnoho teoretických konštrukcií, ktoré nie celkom korešpondujú s biologickou realitou a nie sú správnu abstrakciou alebo matematickým modelom činnosti mozgu. I napriek tomu sa tieto systémy ďalej rozvíjajú a študujú, a nachádzajú sa pre ne aplikácie.

V článku ukážeme využitie neurónovej siete s dopredným šírením ako univerzálneho aproximátora dynamického systému (štvrtinový model auta), ktorý pre trojvrstvovú sieť s dostatočným množstvom neurónov je schopný aproximovať s dostatočnou presnosťou každé spojité zobrazenie.

Matematický model

Nelineárny dynamický systém môžeme vo všeobecnosti popísať sústavou diferenciálnych rovníc v tvare

$$\frac{d\mathbf{x}(t)}{dt} = \mathbf{f}(t) = \Phi(\mathbf{x}(t), \mathbf{u}(t)), t \in R^+ \quad (1)$$


$$\mathbf{y}(t) = \Psi(\mathbf{x}(t), \mathbf{u}(t)) \quad (2)$$

ktorá predstavuje systém s p vstupmi, m výstupmi rádu $2n$. Ak je systém lineárny, môžeme rovnice prepísať do stavového tvaru

$$\dot{\mathbf{x}}(t) = \mathbf{A}\mathbf{x}(t) + \mathbf{B}\mathbf{u}(t) \quad (3)$$

$$\mathbf{y}(t) = \mathbf{C}\mathbf{x}(t) + \mathbf{D}\mathbf{u}(t) \quad (4)$$

kde \mathbf{A} , \mathbf{B} , \mathbf{C} , \mathbf{D} sú $(2n \times 2n)$, $(2n \times p)$, $(m \times 2n)$ a $(m \times p)$ matice.



Obr. 1 Štvrtinový model auta

Uvažujme štvrtinový model automobilu [3], ktorý môžeme charakterizovať ako sústavu dvoch nelineárnych diferenciálnych rovníc druhého rádu v tvare (Obr. 1)

$$m_s \ddot{z}_s = -F_s - F_d - F_c \quad (5)$$


$$m_u \ddot{z}_u = F_s + F_d + F_c - F_t \quad (6)$$

kde m_s je odpružená hmota, m_u je neodpružená hmota, z_s je posunutie odpruženej hmoty, z_u je posunutie neodpruženej hmoty, z_r je vstup od vozovky, F_s je sila v pružine, F_t je sila v pneumatike, F_d je pasívna časť sily v pružine a F_c riadená časť sily v pružine.


Modelovanie pomocou neurónovej siete

Existujú dva základné spôsoby modelovania nelineárnych dynamických systémov pomocou neurónových sietí. Prvý prístup je základný priamy model (Obr. 2). Tento model sa používa napríklad pri riadení, ak nie je možné merať výstupy, pri diagnostike, atď. Pri modelovaní sa minimalizuje rozdiel medzi výstupom neurónovej siete a výstupom modelovaného stroja.

Druhý spôsob sa nazýva inverzný model (Obr. 3). Výstupy zo modelovaného stroja sú vstupy do neurónovej siete. Výstup z neurónovej siete sa porovnáva so vstupom do modelovaného stroja a tento rozdiel sa minimalizuje.



Obr. 2 Priamy model



Obr. 3 Inverzný model

Štvrtinový model automobilu bez riadenia (Obr. 1) bol vytvorený pomocou neurónovej siete s tromi vrstvami neurónov s architektúrou 6-12-4. Vstupy boli tvorené stavovým vektorom v kroku $k-1$ a vstupom v kroku k , $k-1$

$$\mathbf{u}_{NN} = [\mathbf{x}(k-1)^T \quad u(k-1) \quad u(k)]^T \quad (7)$$

kde

$$\mathbf{x} = [z_s \quad z_u \quad \dot{z}_s \quad \dot{z}_u]^T \quad (8)$$

$$u = z_r \quad (9)$$

Výstup je tvorený stavovým vektorom v k -tom kroku

$$\mathbf{y}_{NN} = [\mathbf{x}(k)] \quad (10)$$

Dáta potrebné pre testovanie a verifikovanie neurónovej siete boli vytvorené numerickou simuláciou rovníc (5) a (6) v SIMULINKu (Obr. 4). Na tréning a verifikáciu sa použilo 5000 usporiadaných dvojíc dát, ktoré boli normované. Počet tréningových cyklov bol 150.

Uvažujme štvrtinový model automobilu podľa Obr. 1. Je veľmi obtiažne priamo merať všetky stavové veličiny, ak by sme chceli napríklad navrhnúť riadenie tlmiča ako stavové riadenie, potrebujeme pre určenie spätnej väzby poznať stavové veličiny. Alebo ak potrebujeme poznať veľkosť veličiny, ktorej meranie je buď technicky problematické alebo finančne náročné

Ukážme si príklad inverzného modelu pomocou neurónovej siete, kde na základe nameraných výstupných veličín

$$\mathbf{y} = [\dot{z}_s \quad \dot{z}_u \quad z_s - z_u \quad \dot{z}_s - \dot{z}_u]^T \quad (11)$$

spätne zistíme veľkosť stlačenia pneumatiky a veľkosť rýchlosti stlačenia pneumatiky, ktoré sú obtiažne priamo merať

$$\mathbf{x}_{rel.1} = [z_u - z_r] \quad \mathbf{x}_{rel.2} = [\dot{z}_u - \dot{z}_r] \quad (12)$$

Vytvorili sme neurónovú sieť s tromi vrstvami neurónov s architektúrou 12-7-1 pre rekonštrukciu veličiny stlačenie pneumatiky a druhú sieť s rovnakou architektúrou pre rýchlosť stlačenia pneumatiky.

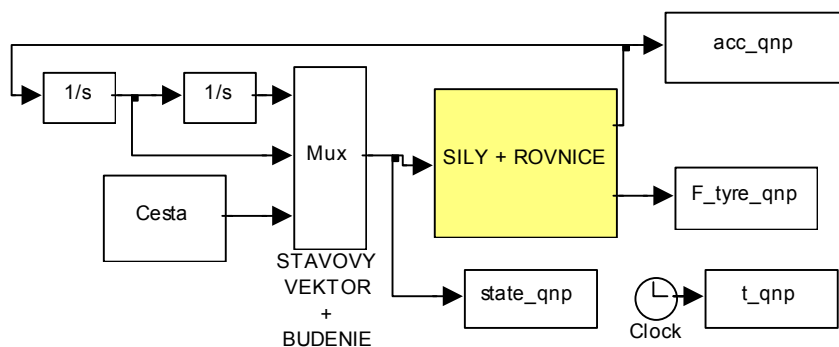
Vstupy do neurónových sietí boli výstupné veličiny v krokoch

$$\mathbf{u}_{NN} = [\mathbf{y}(k)^T \quad \mathbf{y}(k-1)^T \quad \mathbf{y}(k-2)^T]^T \quad (13)$$

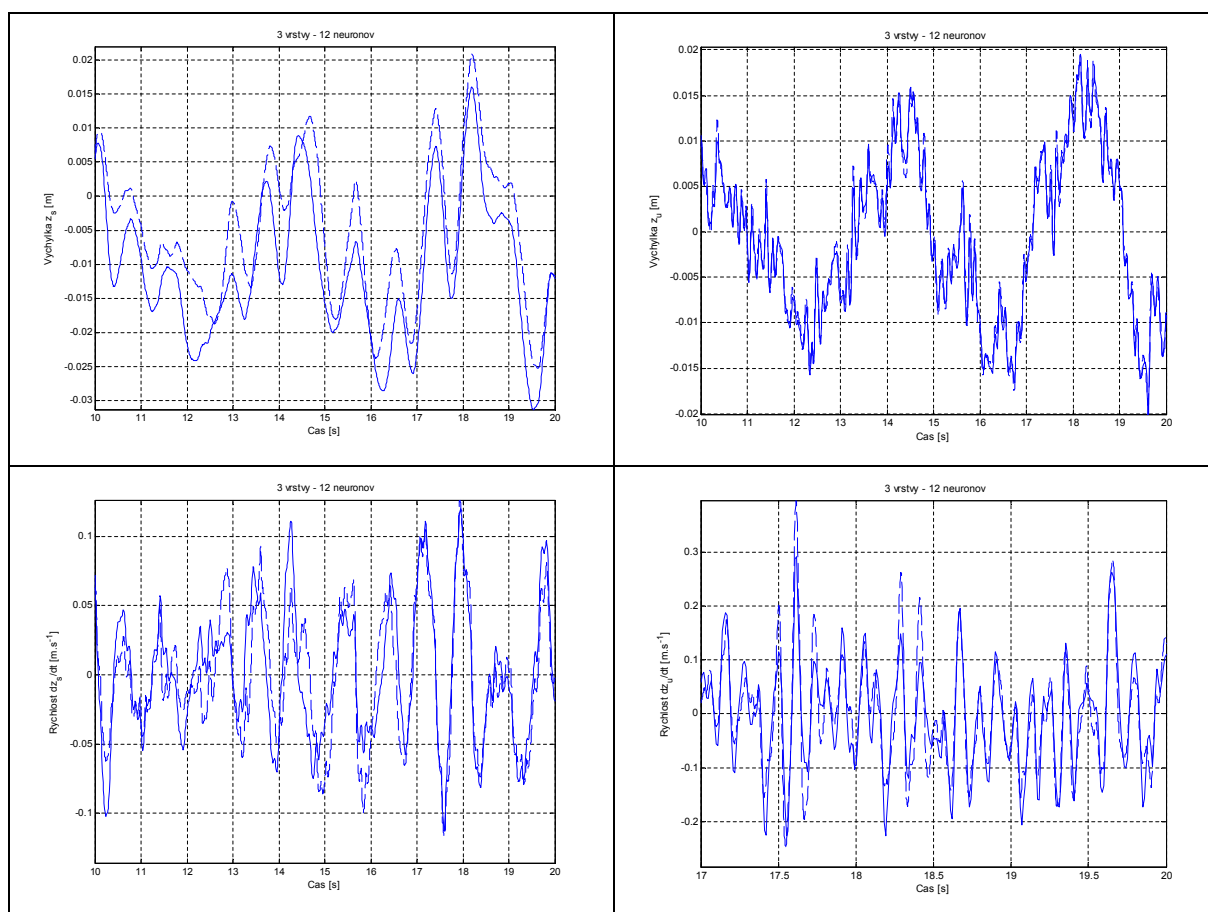
Výstupy boli

$$\mathbf{y}_{NN} = [\mathbf{x}_{rel.i}(k)], \quad i = 1, 2 \quad (14)$$

Dáta potrebné pre testovanie a verifikovanie neurónovej siete boli vytvorené numerickou simuláciou rovníc (5) a (6) v SIMULINKu (Obr. 4). Na tréning a verifikáciu sa použilo 4000 usporiadaných dvojíc dát, ktoré boli normované. Počet tréningových cyklov bol 200.



Obr. 4 Štvrtinový model auta - SIMULINK




Obr. 5 Porovnanie výsledkov získaných pomocou neurónovej siete a numerickým riešením diferenciálnych rovníc

Výsledky

Na porovnanie výsledkov bol vytvorený model štvrtiny auta v SIMULINKu pomocou neurónovej siete (Obr. 4). Ako vstup sa použil model „dobrej cesty“, ktorú automobil prechádza rýchlosťou $20 \text{ m}\cdot\text{s}^{-1}$. Na Obr. 5 sú porovnané priebehy stavových veličín.

Analogicky boli overené dve neurónové siete vytvárajúce inverzný model a výsledky sú uvedené na Obr. 6.



Obr. 6 Porovnanie výsledkov získaných pomocou neurónovej siete a pomocou riešenia diferenciálnych rovníc

Záver

V článku je v krátkosti rozobratá možnosť modelovania mechatronických systémov pomocou neurónových sietí. Vytvorené neurónové siete (priamy a inverzný model) sú numericky porovnané s pôvodným modelom, ktorý majú aproximovať. V prípade, že potrebujeme tieto veličiny poznať a nie je možné ich merať je použitie neurónových sietí vhodné a dostatočne presné.

Zoznam použitej literatúry

- [1] Narendra, K. S. – Parthasarathy, K.: “Identification and Control of Dynamical Systems Using Neural Networks.” IEEE Transactions on Neural Networks, 1, 1990, p. 4.
- [2] Ng, G. W.: “Adaptive Control Using Neural Network – A Survey.” Control Systems Centre Report Number 813, 1994.
- [3] Venhovens, P.J.Th., “Semi-Active Suspension for Automotive Application.” Delft University of Technology, 1991.
- [4] Bartko, R.: “Design of Semi-active Suspension of Truck Using Neural Network.”, XXXIX. Konferencie kateder časti a mechanizmov strojů, Liberec, 1998.

¹ KFIM Fakulta priemyselných technológií TnU AD, T. Vansovej 1054/45, 020 32 Puchov, e-mail: bartko@tnuni.sk