

Inteligentné modelovanie a riadenie – model MR „mobilný robot s diferenciálnym kolesovým podvozkom“

Úlohy:

1. Vytvorte simulačnú schému pre snímanie trénovacích a testovacích dát dopredného neurónového modelu MR
 - a. vygenerujte referenčnú trajektóriu
 - b. upravte riadiacu štruktúru z časti A a nasnímajte dáta
 - c. rozdeľte nasnímané dáta na trénovaciu a testovaciu množinu
 - d. vykreslite trénovacie a testovacie dáta
2. Natrénujte a otestujte dopredný neurónový model MR
3. Vytvorte simulačnú schému pre snímanie trénovacích a testovacích dát doprednej väzby algoritmu riadenia v sledovaní referenčnej trajektórie
 - a. vygenerujte referenčnú trajektóriu
 - b. upravte doprednú väzbu v riadiacej štruktúre z časti A a nasnímajte dáta
 - c. rozdeľte nasnímané dáta na trénovaciu a testovaciu množinu
 - d. vykreslite trénovacie a testovacie dáta
4. Natrénujte inverzný neurónový model
5. Verifikujte natrénovaný inverzný neurónový model v riadiacej štruktúre
 - a. nahradte funkčný blok doprednej väzby inverzným neurónovým modelom
 - b. verifikujte inteligentnú riadiacu štruktúru v sledovaní referenčnej trajektórie mobilným robotom

Poznámka: Výukový modul je pokračovaním časti A – „Klasické modelovania a riadenie“

1. Vytvorenie simulačnej schémy pre snímanie trénovacích a testovacích dát dopredného neurónového modelu MR

Dopredný neurónový model (FNN) aproximuje dynamiku mobilného robota a na výstupe neurónového modelu dostávame súradnice mobilného robota v geometrickom priestore $[x, y]$. Výstup FNN môžeme vyjadriť nasledujúcou funkciou aproximácie

$$\hat{y}(k+1) = f[y(k), \dots, y(k-n+1), u(k), \dots, u(k-m+1)]. \quad (1)$$

Funkcia f je nelineárna funkcia vstupov $u(k)$ o počte m a výstupov $y(k)$ o počte n nelineárneho dynamického modelu MR (časť A) [1].


a) vygenerovanie referenčnej trajektórie

Referenčnú trajektóriu mobilného robota, na ktorej budeme trénovať dopredný neurónový model je goniometrická funkcia sínus o počte vzoriek $p_v = 25001$. Trajektóriu môžeme vygenerovať pomocou nasledujúcich príkazov, pričom po vygenerovaní ju uložíme do dátového typu *timeseries*.

```
dt = 0.01;           % perióda vzoriek [s]
t = 0:dt:250;       % vektor času
r = 2;              % perióda
a = 1;              % amplitúda
x = t;              % referenčná trajektória v osi X [m]
y = a*sin(t/r);     % referenčná trajektória v osi Y [m]

RefTrajekt = timeseries ([ x' y'], t, 'Name', 'sinus')
save ('RefTrajekt.mat', 'RefTrajekt', '-v7.3');
```

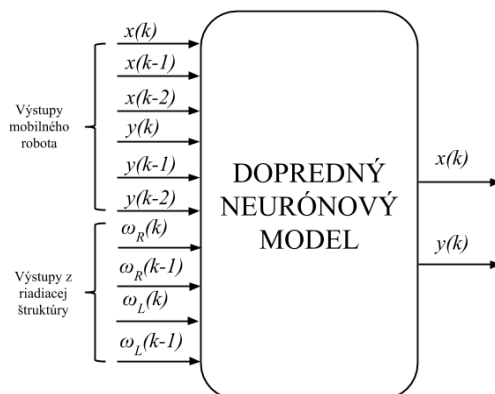
Vygenerovaná referenčná trajektória mobilného robota pomocou vyššie uvedeného kódu pre trénovanie a testovanie dopredného neurónového modelu v programe Matlab potom vyzerá nasledovne (Obr. 1).



Obr. 1 Referenčná trajektória mobilného robota vygenerovaná v programe Matlab

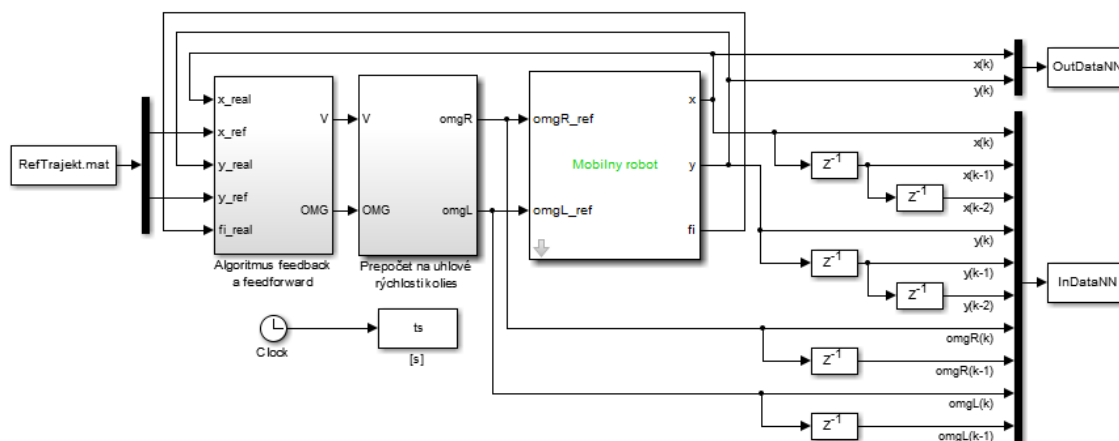
a) upravenie riadiacej štruktúry z časti A a nasnímanie dát

Bloková schéma dopredného neurónového modelu, podľa ktorej upravíme riadiacu štruktúru z časti A pre snímanie tréningových a testovacích dát sa nachádza na Obr. 2. Vstupom je šesť výstupných vektorov mobilného robota a štyri vstupné budiace signály riadiacej štruktúry pre sledovanie referenčnej trajektórie.



Obr. 2 Bloková schéma dopredného neurónového modelu MR

Upravená riadiaca štruktúra z časti A pre snímanie tréningových a testovacích dát je zobrazená na nasledujúcom Obr. 3.



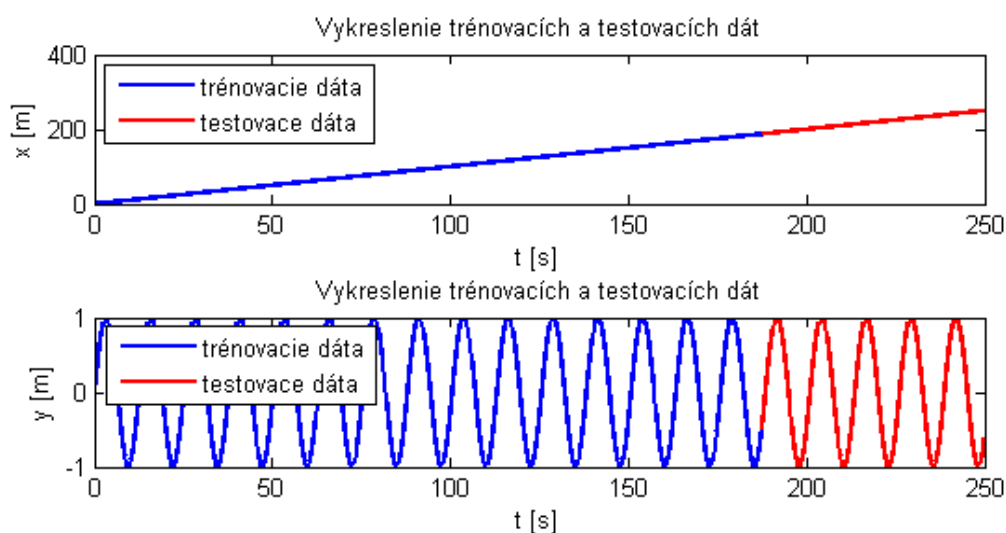
Obr. 3 Simulačné schéma snímania dát pre dopredný neuronový model MR

b) rozdelenie nasnímaných dát na tréningovú a testovaciu množinu

Z vyššie uvedenej simulačnej schémy sme zosnímali desať vstupných vektorov (InDataNN) a dva výstupné vektory (OutDataNN). Dáta rozdelíme v pomere 75% tréningové a 25 % testovacie dáta.

c) vykreslenie tréningových a testovacích dát

Na nasledujúcom Obr. 4 sa nachádzajú výstupné vektory OutDataNN – vzor doprednej neuronovej siete pre tréningovanie a testovanie. Výstupom dopredného neuronového modelu mobilného robota sú súradnice pohybu mobilného robota v rovine $[x, y]$.



Obr. 4 Tréningové a testovacie dáta pre dopredný neuronový model

2. Trénovanie a testovanie dopredného neurónového modelu

Typ doprednej neurónovej siete, ktorú budeme používať v inteligentnom modelovaní je označovaná ako MLP - viacvrstvový perceptron. Viac o neurónových sieťach sa nachádza v [2].

Neurónová sieť je v programe Matlab reprezentovaná ako objekt, ktorý potrebujeme nakonfigurovať. Dôležitými údajmi sú pre nás počet neurónov v skrytej vrstve pn , perióda vzorkovania ΔT , presnosť učenia E , typ algoritmu a pod. Veľmi dôležitým parametrom sú aj aktivačné funkcie vstupnej a výstupnej vrstvy neurónovej siete a algoritmus učenia. Podrobný postup práce s aplikačnou knižnicou Neural Network Toolbox sa nachádza v [3].

Trénovanie dopredného neurónového modelu

Dopredný neurónový model mobilného robota vytvoríme, natrénujeme a vygenerujeme v aplikačnej knižnici Neural Network Toolbox pomocou nasledujúcich príkazov zobrazených nižšie [3]. Komentár k použitým funkciám, vstupné parametre a návratové hodnoty nájdete v helpe programu Matlabu.

```

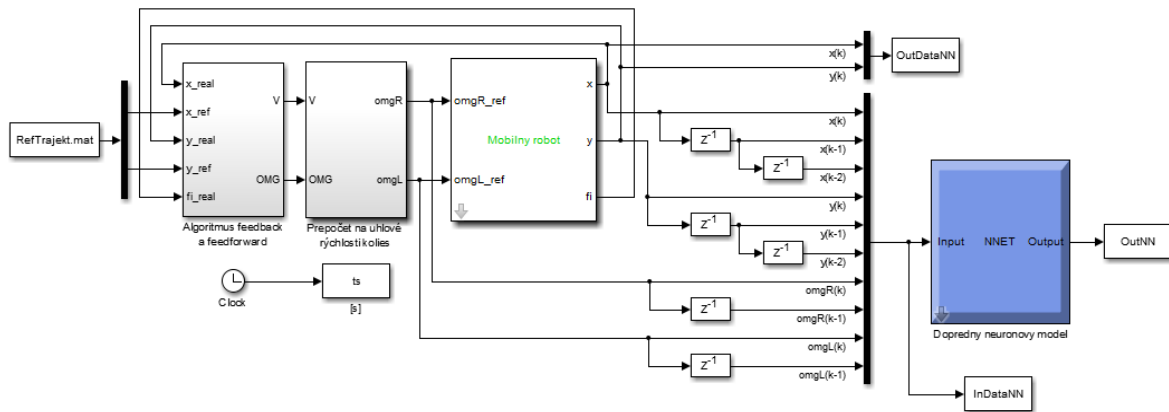
%% Vytvorenie neuronoveho modelu MR
net = newff(minmax(InD.TrenData.data),OutD.TrenData.data,PN,{'logsig','purelin'},'trainlm');
% inicializacia nazvu neuronovej siete a poctu epoch
net.name = 'Dopredny neuronovy model';
net.trainParam.epochs = 1000;
% presnost trenovania neuronovej siete
net.trainParam.goal = 1e-6;
% inicializacia neuronovej siete
net = init(net);
% trenovanie trenovacou mnozinou dat
[net,tr] = train(net, InD.TrenData.data, OutD.TrenData.data);
plotperform(tr)
% testovanie testovacou mnozinou dat
netOut = net(InD.TestData.data);
% vykon natrenovanej neuronovej siete
vykon = perform(net, netOut, OutD.TestData.data);
% zobrazenie struktury neuronovej siete
view(net)
% vygenerovanie subsystemu neuronovej siete v Simulinku
gensim(net,dt)

```

Poznámka: Neurónový model je možné natrénuvať aj pomocou grafického okna, teda nie je nutné ovládať príkazy uvedené vyššie.

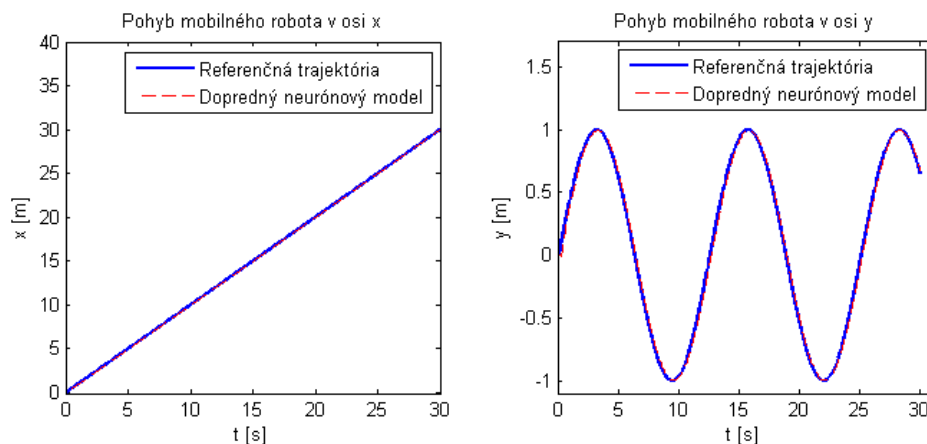
Testovanie dopredného neurónového modelu

Po vygenerovaní dopredného neurónového modelu ho otestujeme zapojením do simulačnej schémy (Obr. 3), pričom výsledné zapojenie je zobrazené na Obr. 5. Neurónový model MR verifikujeme na natrénuvanú referenčnú trajektóriu tvaru sínus. Perióda experimentu je $\Delta T = 0,01$ s a čas experimentu je $t = 30$ s. Simulačná schéma validácie dopredného neurónového modelu MR sa nachádza na nasledujúcom Obr. 5.




Obr. 5 Simulačná schéma verifikácie dopredného neurónového modelu MR

Výstupom validácie sú nasledujúce grafy (Obr. 6 a Obr. 7) aproximácie dynamiky modelu MR dopredným neurónovým modelom mobilného robota pre natrénovanú referenčnú trajektóriu goniometrickej funkcie sínus. Na nasledujúcom Obr. 6 vidíme validáciu správnosti dopredného neurónového modelu mobilného robota. Výstup z dopredného neurónového modelu mobilného robota je s určitou presnosťou totožný s referenčnou trajektóriou a je zobrazený zvlášť pre x -ovú a y -ovú os (Obr. 6).



Obr. 6 Verifikácia dopredného neurónového modelu mobilného robota v osi x a y

Na nasledujúcom Obr. 7 je zobrazená validácia dopredného neurónového modelu mobilného robota v rovine.



Obr. 7 Pohyb dopredného neurónového mobilného robota v rovine

Na záver môžeme konštatovať, že natrénovanie a otestovanie neurónového modelu bolo úspešné. Natrénovaný dopredný neurónový model MR sledoval referenčnú trajektóriu, na ktorú bol natrénovaný (Obr. 6 a Obr. 7).

3. Vytvorenie simulačnej schémy pre snímanie tréningových a testovacích dát doprednej väzby algoritmu riadenia v sledovaní referenčnej trajektórie

Inverzný neurónový model (INN) je presným opakom dopredného neurónového modelu a je daný inverznou funkciou (2). Výstupom z neurónovej siete sú budiace signály mobilného robota ω_R a ω_L . Inverzná funkcia aproximácie je podľa [1] vyjadrená nasledovne.

$$u(k) = f^{-1}[\hat{y}(k+1), \dots, y(k-n+1), u(k), \dots, u(k-m+1)]. \quad (2)$$

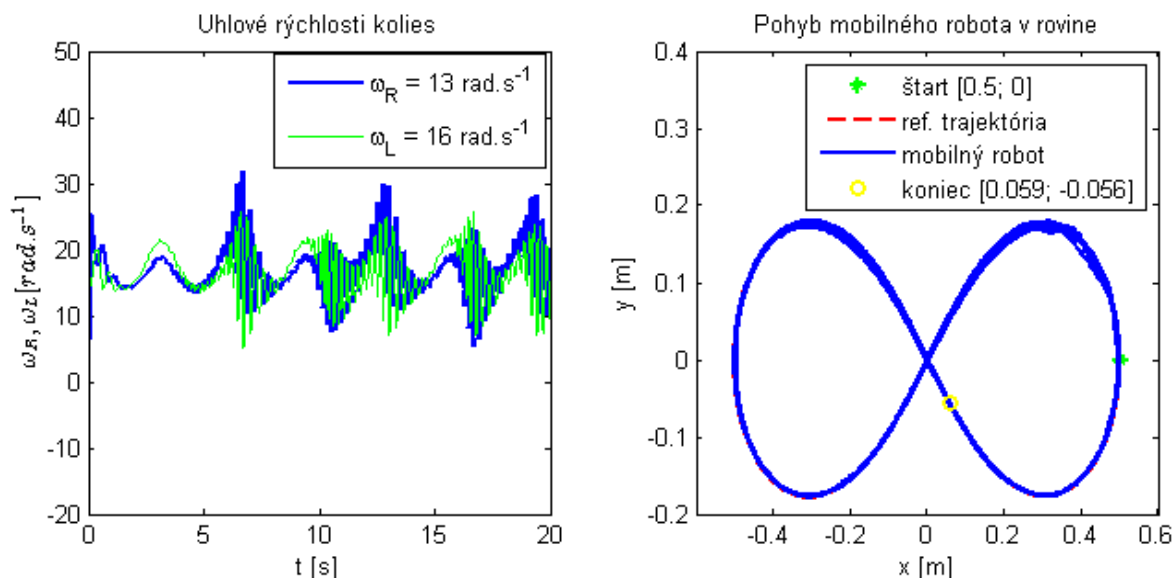
a) vygenerovanie referenčnej trajektórie

Referenčnú trajektóriu mobilného robota tvaru ležiacej osmičky môžeme vygenerovať pomocou nasledujúcich príkazov (podobne ako v časti A) o počte vzoriek $p_v = 25001$, pričom po vygenerovaní ju uložíme do dátového typu *timeseries*.

```
dt = 0.01;           % perióda vzoriek [s]
t = 0:dt:250;       % vektor času
x = sin(t/4);       % referenčná trajektória v osi X [m]
y = sin(t/2);       % referenčná trajektória v osi Y [m]

RefTrajekt = timeseries([ x' y' ], t, 'Name', 'Lamniscate_test_00')
save('RefTrajekt.mat', 'RefTrajekt', '-v7.3');
```

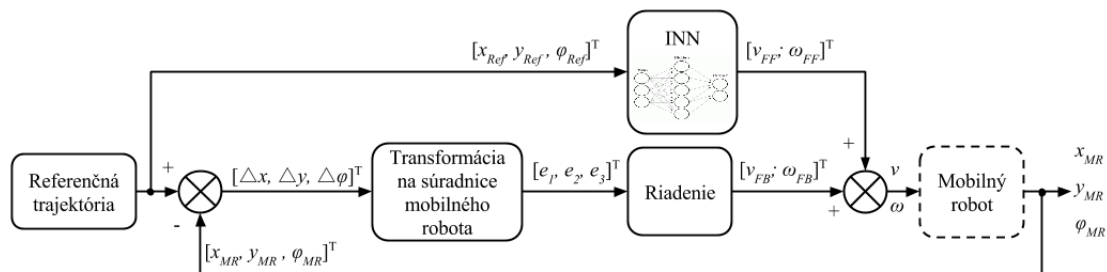
Vygenerovaná referenčná trajektória mobilného robota pomocou vyššie uvedeného kódu pre tréning a testovanie inverzného neurónového modelu v programe Matlab potom vyzerá nasledovne (Obr. 8). Na Obr. 8 sú akčné veličiny mobilného robota ω_R a ω_L zobrazené len do času $t = 20$ s, nakoľko by na danej veľkosti grafu nebolo možné rozoznať signál pri vykreslení celého rozsahu $t = 250$ s. Celý rozsah akčných veličín ω_R a ω_L je zobrazený na Obr. 12.



Obr. 8 Referenčná trajektória mobilného robota tvaru ležiacej osmičky vygenerovaná v programe Matlab

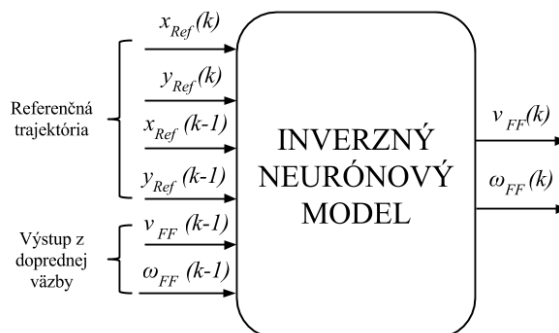
b) upravenie riadiacej štruktúry z časti A a nasnímanie dát

V riadiacej štruktúre (časť A) nahradíme doprednú väzbu inverzným neurónovým modelom mobilného robota. Takto dostaneme inteligentnú riadiacu štruktúru, ktorá bude natrénovaná na konkrétny typ referenčnej trajektórie, ktorú potom porovnáme s klasickou metódou (časť A). Bloková schéma inteligentnej riadiacej štruktúry s inverzným neurónovým modelom v doprednej väzbe sa nachádza na nasledujúcom Obr. 9.



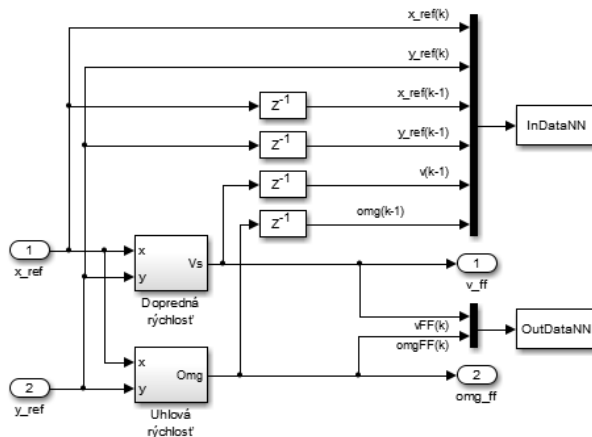
Obr. 9 Riadiaca štruktúra sledovania referenčnej trajektórie zapojením inverzného neurónového modelu v doprednej väzbe

Blok INN predstavuje požadovanú doprednú a uhlovú rýchlosť mobilného robota v_{FF} a ω_{FF} na referenčnej trajektórii. Bloková schéma (Obr. 10) zobrazuje vstupné vektory, ktoré sme použili pri tréovaní a testovaní INN v doprednej väzbe a výstupné vektory požadovanej doprednej a uhlovej rýchlosti v_{FF} , ω_{FF} .



Obr. 10 Bloková schéma inverzného neurónového modelu doprednej väzby

Upravená dopredná väzba z riadiacej štruktúry (časť A) pre snímanie tréovacích a testovacích dát je zobrazená na nasledujúcom Obr. 11.



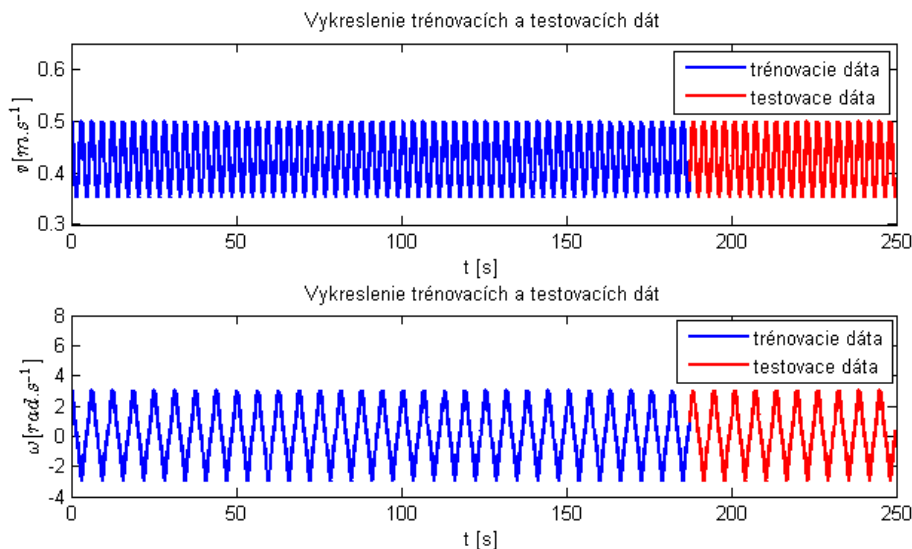
Obr. 11 Simulačná schéma pre snímanie tréovacích a testovacích dát inverzného neurónového modelu v doprednej väzbe

c) rozdelenie nasnímaných dát na tréningovú a testovaciu množinu

Z vyššie uvedenej simulačnej schémy sme zosníмали šest' vstupných vektorov (InDataNN) a dva výstupné vektory (OutDataNN). Dáta rozdelíme v pomere 75% tréningové a 25 % testovacie dáta.

d) vykreslenie tréningových a testovacích dát

Množina tréningových a testovacích dát, ktoré sme namerali zo simulačnej schémy doprednej väzby mobilného robota v sledovaní referenčnej trajektórie (Obr. 11) sa nachádza na nasledujúcom Obr. 12.



Obr. 12 Tréningové a testovacie dáta inverzného neurónového modelu namerané z doprednej väzby sledovania referenčnej trajektórie mobilným robotom

4. Tréning inverzného neurónového modelu

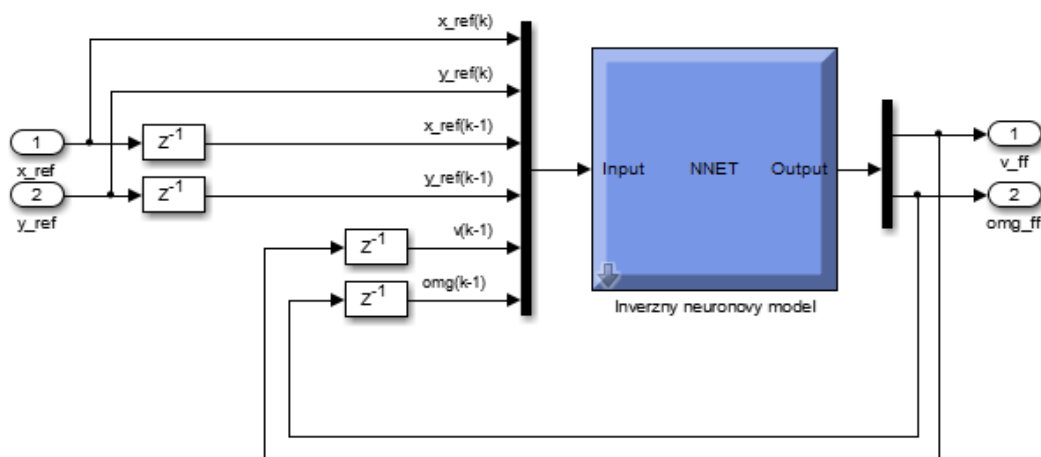
Tréning inverzného neurónového modelu MR (postupnosť príkazov) je totožná s tréningom dopredného neurónového modelu MR (bod č. 2).

5. Verifikovanie natréňovaného inverzného neurónového modelu v doprednej

Inteligentnú riadiacu štruktúru potrebujeme verifikovať pre natréňovanú referenčnú trajektóriu. Na základe odchýlok potom zhodnotíme kvalitu inteligentného riadenia v sledovaní referenčnej trajektórie mobilným robotom.

a) nahradenie funkčného bloku doprednej väzby inverzným neurónovým modelom

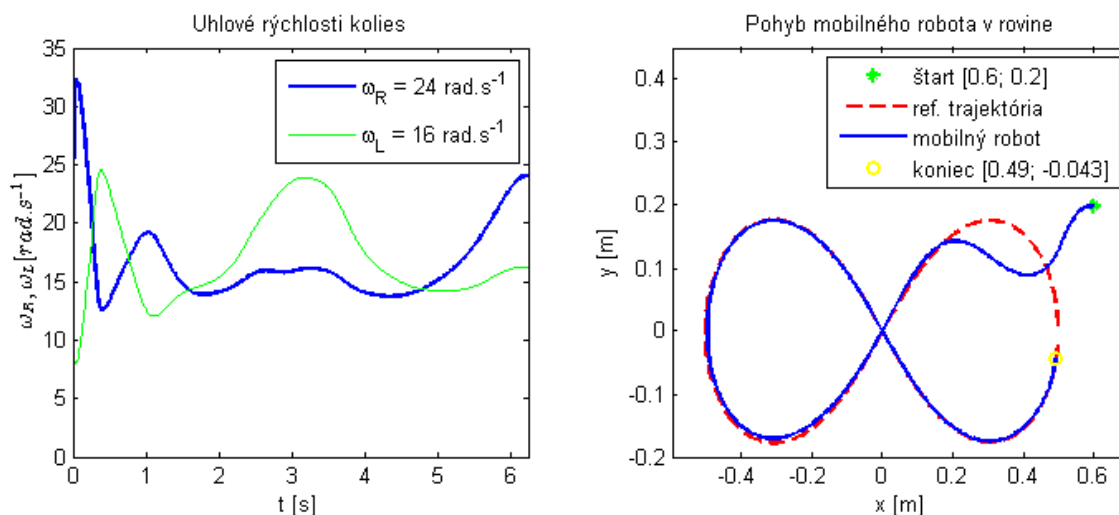
Po vygenerovaní inverzného neurónového modelu ho otestujeme zapojením do simulačnej schémy (Obr. 9), pričom výsledné zapojenie je zobrazené na Obr. 13. Perióda experimentu je $\Delta T = 0,01$ s a čas experimentu je $t = 6,24$ s. Počet neurónov v skrytej vrstve je rovný počtu vstupných vektorov INN, čo odpovedá počtu $pn = 6$. Simulačná schéma validácie INN v doprednej väzbe sledovaní referenčnej trajektórie mobilným robotom sa nachádza na nasledujúcom Obr. 13.



Obr. 13 Zapojenie inverzného neurónového modelu mobilného robota v doprednej väzbe sledovania referenčnej trajektórie


b) verifikovanie inteligentnej riadiacej štruktúry v sledovaní referenčnej trajektórie mobilným robotom

Na nasledujúcom Obr. 14 sa nachádza verifikácia inteligentnej riadiacej štruktúry mobilného robota pre natrénovanú referenčnú trajektóriu tvaru ležiacej osmičky. Mobilný robot sa v experimente porovnania nachádza na východnom bode a natočení $[0,6; 0,2; \pi]$. Čas experimentu porovnania je $t = 6,24$ s a perióda vzorkovania je $\Delta T = 0,01$ s.



Obr. 14 Porovnanie inteligentného a klasického riadenia mobilného robota v sledovaní referenčnej trajektórie

Na nasledujúcom Obr. 15 sa nachádzajú odchýlky mobilného robota od referenčnej trajektórie e_1 , e_2 a e_3 . Odchýlka e_1 má trvalú regulačnú odchýlku, pričom odchýlky e_2 a e_3 sa ustália až po tom, ako sa mobilný robot nachádza na referenčnej trajektórii.



Obr. 15 Odchýlky e_1 , e_2 a e_3 inteligentnej metódy riadenia mobilného robota v sledovaní referenčnej trajektórie

Pri zmene referenčnej trajektórie je potrebné pretrénovať INN a vykonať verifikáciu v riadiacej štruktúre pre nový typ referenčnej trajektórie.

Zoznam použitej literatúry

- [1] JADLOVSKÁ, A.: *Modeling and Control of Dynamic Processes Using Neural Networks*, FEI TU, Košice, Informatel Ltd., 173p., ISBN 80- 88941-22-9, (in Slovak)
- [2] SINČÁK, P.; ANDREJKOVÁ, G. *Neurónové siete. Inžiniersky prístup. 1. a 2. diel.* Košice: elfa s.r.o., 1996. 107 s. a 63 s. ISN 80-88786-38-X a ISBN 80-88786-42-8.
- [3] Neural Network Toolbox – User’s Guide, The Math Works
(https://www.mathworks.com/help/pdf_doc/nnet/nnet_ug.pdf).