



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA STROJNÍHO INŽENÝRSTVÍ
ÚSTAV MECHANIKY TELES, MECHATRONIKY A
BIOMECHANIKY

FACULTY OF MECHANICAL ENGINEERING
INSTITUTE OF SOLID MECHANICS, MECHATRONICS AND
BIOMECHANICS

POSOUZENÍ VHODNOSTI UČENÍ PRO HEURISTICKÉ ADAPTIVNÍ ŘÍZENÍ POHONU

SUITABILITY ASSESSMENT OF LEARNING FOR HEURISTIC ADAPTIVE CONTROL OF DRIVES

BAKALÁŘSKÁ PRÁCE
BACHELOR'S THESIS

AUTOR PRÁCE
AUTHOR

MILAN KEREK

VEDOUCÍ PRÁCE
SUPERVISOR

doc. RNDr. Ing. TOMÁŠ BREZINA,
CSc.

BRNO 2012

Vysoké učení technické v Brně, Fakulta strojního inženýrství

Ústav mechaniky těles, mechatroniky a biomechaniky

Akademický rok: 2011/12

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

student(ka): Milan Kerek

který/která studuje v **bakalářském studijním programu**

obor: **Mechatronika (3906R001)**

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách a se Studijním a zkušebním řádem VUT v Brně určuje následující téma bakalářské práce:

Posouzení vhodnosti učení pro heuristické adaptivní řízení pohonů

v anglickém jazyce:

Suitability Assessment of Learning for Heuristic Adaptive Control of Drives

Stručná charakteristika problematiky úkolu:

Provést rešerši k současnému stavu řešení vymezené problematiky. Vyhodnotit rešerši a s použitím Matlab/Simulink zvolit a sestavit vhodné simulační modely. Provést simulace a jejich výsledky interpretovat se zřetelem k praktickým hlediskům.

Cíle bakalářské práce:

Získat prakticky interpretovatelné výsledky simulací.

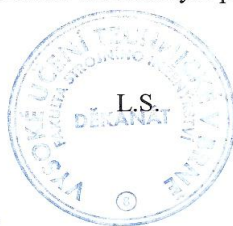
Seznam odborné literatury:

Passino, K.M.; Biomimicry for Optimization, Control and Automation, Springer 2005, pp. 313-415, ISBN 1-85233-804-0.

Vedoucí bakalářské práce: doc. RNDr. Ing. Tomáš Březina, CSc.

Termín odevzdání bakalářské práce je stanoven časovým plánem akademického roku 2011/12.

V Brně, dne 22.11.2011



prof. Ing. Jindřich Petruška, CSc.
Ředitel ústavu

prof. RNDr. Miroslav Doupovec, CSc.
Děkan

ABSTRAKT

Táto bakalárska práca je zameraná na možnosti využitia umelých neurónových sietí v regulácii nelineárnych dynamických systémoch. Ďalej je v práci ukázaná možnosť kombinácie neurónových regulátorov s lineárnymi regulátormi ako sú PID regulátor, stavový regulátor s kompenzáciou poruchy.

Simulačné modely boli navrhnuté v prostredí Matlab/Simulink. Neurónové siete boli trénované pomocou Neural Network Toolbox-u.

Navrhnuté regulátory boli testované na regulácii uhlovej rýchlosti nelineárneho systému 2. rádu - jednosmerného motora s cudzím buđením.

Kľúčové slova

Regulácia, Umelé neurónové siete, Dopredný neurónový model, Inverzný neurónový model, Stavový regulátor, PID regulátor

Abstract

The bachelor thesis is aimed to explore the possibilities of using artificial neural network in order to controll nonlinear dynamic systems.

In addition the document shows the options to combine neural controllers with linear controllers, such as PID regulator, state space regulator with compensation error. Simulation models were designed in environment of Matlab/Simulink. Neural networks were exploit with the help of Neural Network Toolbox-u. Designed regulators were tested on regulating angular velocity of nonlinear system of 2nd order – wound DC motor.

Keywords

Regulation, Artificial neural network, Forward neural network model, Inverse neural network model, State – space controller, PID controller

Bibliografická citácia práce:

KEREK, M. *Posouzení vhodnosti učení pro heuristické adaptivní řízení pohonů*. Brno: Vysoké učení technické v Brně, Fakulta strojního inženýrství, 2012. 32 s. Vedoucí bakalářské práce doc. RNDr. Ing. Tomáš Březina, CSc.

Čestné prehlásenie

Prehlasujem, že som túto bakalársku prácu vypracoval samostatne na základe pokynov a rád vedúceho práce doc. RNDr. Ing. Tomáš Březina, CSc. a že som všetky použité literárne a internetové zdroje uviedol v zozname použitej literatúry.

V Brne, dňa

Podpis:

Pod'akovanie

Chcel by som poďakovať všetkým, ktorí mi pomohli pri vypracovaní tejto bakalárskej práce, predovšetkým vedúcemu práce doc. RNDr. Ing. Tomáš Březina, Csc. za cenné rady a odovzdané skúsenosti. Vďaka aj patrí mojej rodine - hlavne rodičom za podporu počas celého štúdia.

Obsah

1. Úvod.....	9
2. Úvod do teórie riadenia.....	10
2.1. Čo je to riadenie	10
2.2. Inteligentné riadiace systémy	10
3. Neurónové siete v riadení	10
3.1. Neurónové siete	10
3.2. Potenciál využitia neurónových sietí	11
4. Inverzný neurónový regulátor	13
4.1. Príprava dát potrebných na tréning	13
4.2. Rozdelenie množiny tréningových dát	14
4.3. Dopredný model systému	15
4.4. Tréning dopredného modelu	15
4.5. Inverzný model systému	17
5. Stavový regulátor s kompenzáciou poruchy	20
5.1. Stavový popis sústavy	20
5.2. Riaditeľnosť	21
5.3. Návrh stavového regulátora s kompenzáciou poruchy	21
6. Inverzný neurónový <i>PID</i> regulátor	24
6.1. Návrh a ladenie <i>PID</i> regulátora metódou Ziegler-Nichols	24
6.2. Inverzný neurónový <i>PID</i> regulátor	25
7. Stavová regulácia s neurónovým modelom nelinearity	27
7.1. Odstránenie nelinearity	27
7.2. Aplikovanie stavového regulátora	28
7.3. Nahradenie nelinearity umelou neurónovou sieťou	28
7.4. Stavový regulátor s neurónovým modelom	29
8. Záver.....	30
9. Zoznam použitej literatúry.....	31
10. Zoznam použitých skratiek a symbolov	32
11. Zoznam príloh	32

1. Úvod

V súčasnosti sa na riadenie a reguláciu lineárnych systémov používa nespočetné množstvo metód. V oblastiach, kde tradičné metódy lineárneho riadenia zlyhávajú je možné použiť riadiace systémy využívajúce *UNS*. Neurónové siete sa používajú najmä pri riadení zložitých nelineárnych systémoch. Podľa Hornika [2], ktorý vo svojej práci dokázal, že viacvrstvové neurónové siete vykazujú veľmi dobré aproximačné vlastnosti. Túto schopnosť im zabezpečuje odhad výstupov neurónovej siete v závislosti od privedených vstupov. Vďaka tejto schopnosti neurónových sietí sme schopný získať dopredný model systému. Inverziou dopredného modelu získame, inverzný neurónový model systému, ktorý použijeme ako neurónový regulátor procesu. Podľa [3], takto vytvorený regulátor sa správa podobne ako *PD* regulátor.

Ďalšou možnosťou využitia *UNS* je ich kombinácia s lineárnymi regulátormi. Existuje veľa možností a spôsobov efektívneho návrhu lineárneho regulátora. V tejto práci sa zameriame tiež na postup návrhu a testovania kombinácie lineárnych regulátor a neurónových sietí. Ako lineárne regulátory boli zvolené *PID* regulátor a stavový regulátor s kompenzáciou poruchy. *PID* regulátor patrí medzi najpoužívanejšie riadiace systémy v priemyselnej praxi. *PID* realizuje akčný zásah na základe rozdielu medzi referenčnou hodnotou a skutočnou nameranou veličinou, naproti tomu stavový regulátor realizuje proporcionálne väzby od všetkých stavových premenných a pre kompenzáciu vplyvu poruchy je možné použiť štruktúru s integrátorom na vstupe.

S použitím jazyka Matlab/Simulink sme vytvorili model jednosmerného motora. Nelinearitu v tomto prípade vytvára coulombové trenie, kde trecia sila F_c nie je definovaná pre nulovú rýchlosť.

2. Úvod do teórie riadenia

2.1. Čo je to riadenie

Riadenie sa môže považovať za základ automatizácie. Nasledujúcu definíciu úvádza Ivan Švarc vo svojej práci [4] : *Řízení je cílené působení na řízený objekt tak, aby se dosáhlo určitého předepsaného cíle.*

Riadenie môžeme rozdeliť na základe toho, či je alebo nie je výstup riadeného systému kontrolovaný spätnou väzbou. Na základe tohto kritéria je v [4] riadenie klasifikované na:

- ovládanie – riadenie bez spätnej väzby
- reguláciu – riadenie so spätnou väzbou. Regulácia je ovplyvňovanie stavov alebo chovania regulovaného systému.
- vyššie formy riadenia:
 - optimálne riadenie – systém vynaloží minimálne množstvo energie (v najkratšom čase s maximálnou účinnosťou) aby dosiahol požadovaných vlastností
 - adaptívne riadenie – pri tomto druhu riadenia je regulátor schopný sa prispôsobovať zmenám parametrov regulovaného objektu pri dodržaní optimálneho chodu procesu
- umelá inteligencia – patrí medzi najvyššie formy riadenia. Je to vlastnosť človekom vytvoreného umelého systému, ktorý dokáže rozlišovať javy, predmety, obrazy, riešiť problémy a zdokonaľovať svoju činnosť.

2.2. Inteligentné riadiace systémy

Podľa [6] inteligentné riadiace systémy predstavujú systémy (stroje), ktoré by napodobňovali myseľ a inteligenciu človeka.

Medzi základné schopnosti systémov s prvkami umelej inteligencie patria:

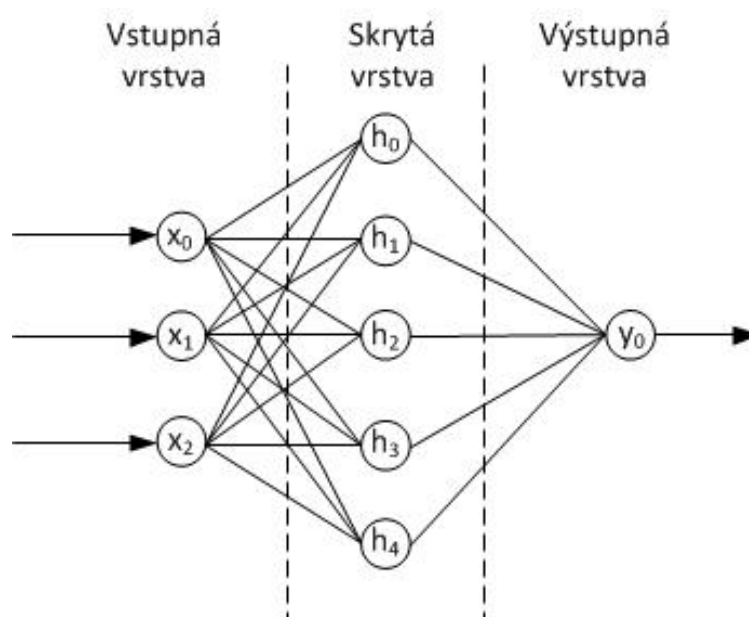
- schopnosť učenia sa a získavania znalosti z dát
- ukladanie získaných znalosti
- využívanie naučených a získaných znalosti pri riešení konkrétnych problémov

3. Neurónové siete v riadení

3.1. Neurónové siete

V súčasnosti sa na riadenie a reguláciu lineárnych systémov používa nespočetné množstvo metód. V oblastiach, kde tradičné metódy lineárneho riadenia zlyhávajú je možné vybrať vhodný spôsob riadenia pre daný systém. Jednou z možností je neuroriadenie, v ktorom využívame potenciál umelých neurónových sietí. Neurónové siete sú paralelné systémy s navzájom prepojenými neurónmi, schopnými riešiť náročné výpočtové problémy. Ich najväčšou výhodou je schopnosť spracovania nelineárnych informácií.

Definíciu, čo to vlastne neurónová sieť je, uviedol vo svojej práci *Neurocomputing* [13] Hecht-Nielsen: *Umelá neurónová sieť je paralelná, distribuovaná, informácie spracujúca štruktúra, pozostávajúca z výkonných jednotiek – elementov, poprepájaných jednosmernými informačnými kanálmi nazývanými synapsie. Každá výkonná jednotka má jedeno vstupné prepojenie, ktoré sa rozvetvuje do toľkých paralelných prepojení ako je potrebné. Každé také prepojenie nesie rovnaký signál ako je výstupný signál danej procesnej jednotky. Tento výstupný signál môže byť ľubovoľného matematického typu. Spracovávanie informácie, ktoré sa vykonáva vnútri každej procesnej jednotky môže byť definované ľubovoľne, s obmedzením, že bude kompletne lokálne. Teda záleží len na aktuálnych hodnotách vstupných signálov prichádzajúcich do procesnej jednotky cez dopadajúce prepojenia a na hodnotách uložených v lokálnej pamäti procesnej jednotky.*



Obr 1: Model doprednej neurónovej siete

3.2. Potenciál využitia neurónových sietí

Z vyššie uvedeného vyplýva, že neurónové siete majú širokú škálu použitia. Medzi najviac využívané oblasti použitia neurónových sietí je, ktoré spomenul vo svojej práci *Dynamické riadenie mobilného robota na báze neurónových sietí* [1] Štofán Daniel :

- Klasifikácia vzorov – z praxe známe využitie na rozpoznávanie reči, znakov, klasifikácia grafov EEG a mnoho ďalších.
- Kategorizácia – umelá neurónová sieť podľa určeného algoritmu hľadá podobnosti, rovnaké znaky medzi vstupnými vzorkami, ktoré umiestňuje do zhlukov.
- Aproximácia funkcie – máme množinu trénovacích vzoriek $(x_1, y_1), \dots, (x_n, y_n)$. Táto množina bola vytvorená pomocou neznámej funkcie $f(x)$. Cieľom neurónovej siete je nájsť a nastaviť parametre neznámej funkcie f .
- Predikcia – máme množinu vzoriek $y(t_1), \dots, y(t_n)$ v čase t_1, t_2, \dots, t_n . Úlohou je predpovedať aká vzorka $y(t_n + 1)$ v budúcom čase $t_n + 1$.

- Riadenie – cieľom riadenia neurónovými sieťami je generovať taký akčný zásah $u(t)$ tak, že systém sleduje trajektóriu referenčného signálu.

4. Inverzný neurónový regulátor

V poslednom období došlo k vyznanému zvýšeniu spôsobov riadenia systémov, ktoré sú založené na nelineárnej koncepcii. Jednou z takýchto metód je inverzný model. Táto metóda je však závislá na dostupnosti získania inverzie riadeného systému. Neurónové siete majú schopnosť modelovať akýkoľvek nelineárny systém vrátane ich inverzií, čo nám ponúka možnosť ich využitia v riadení.

Použitie umelej neurónovej siete ako regulátora je založené na návrhu inverzného neurónového modelu riadeného systému, ktorý je možné použiť ako neurónový regulátor. Umelá neurónová sieť musí byť natrénovaná presnou inverziou dopredného modelu systému, aby sa zabezpečila dobrá regulácia.

4.1. Príprava dát potrebných na tréning

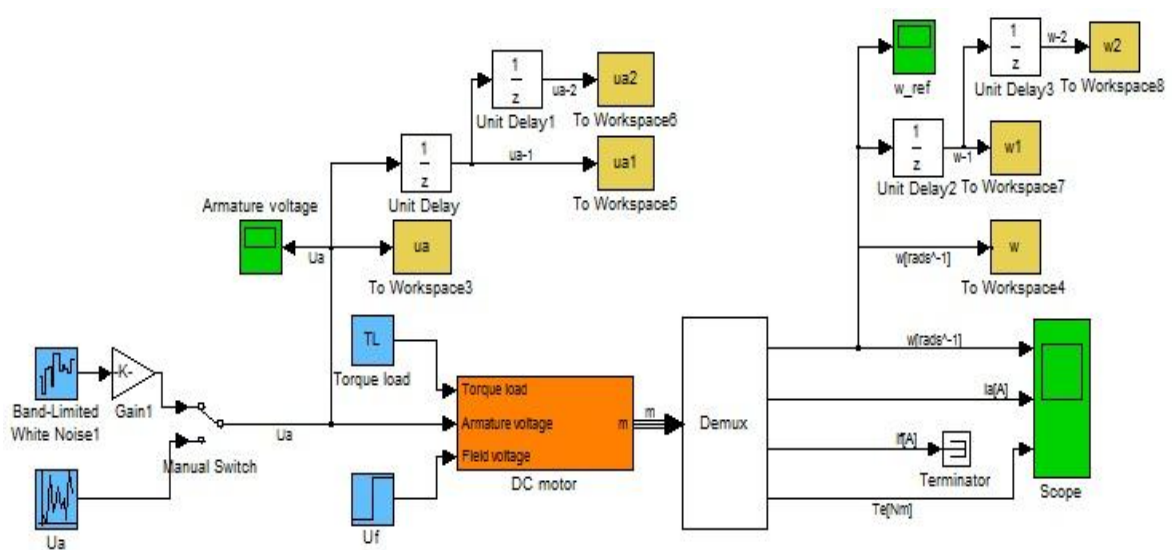
V prostredí *MATLAB/SIMULINK*, sme vytvorili model jednosmerného motora s cudzím budením, ktorý predstavuje nelineárny dynamický systém 2. rádu, a je popísaný diferenciálnymi rovnicami :

$$\frac{di_f}{dt} = \frac{1}{L_f}(u_f - R_f \cdot i_f) \quad (1)$$

$$\frac{di_a}{dt} = \frac{1}{L_a}(u_a - R_a \cdot i_a - L_{af} \cdot i_f \cdot \omega) \quad (2)$$

$$\frac{d\omega}{dt} = \frac{1}{J}(L_{af} \cdot i_f \cdot i_a - B_m \omega - T_f - T_L) \quad (3)$$

kde i_f je budiaci prúd, u_f budiace napätie, R_f a L_f je odpor a indukčnosť budenia, L_{af} spoločná indukčnosť, i_a prúd na motore, u_a napätie na motore, R_a a L_a odpor a indukčnosť motora, ω uhlová rýchlosť motora, J moment zotrvačnosti, B_m a T_f viskózne a coulombové trenie a T_L je záťaž motora. Parametre L_{af} a i_f tvoria napäťovú konštantu $K_E \doteq K_T$. K_T momentová konštantá. Model DC motora v *SIMULINKU* a ukladanie potrebných dát pre tréning:



Obr. 2: Príprava dát potrebných pre tréning

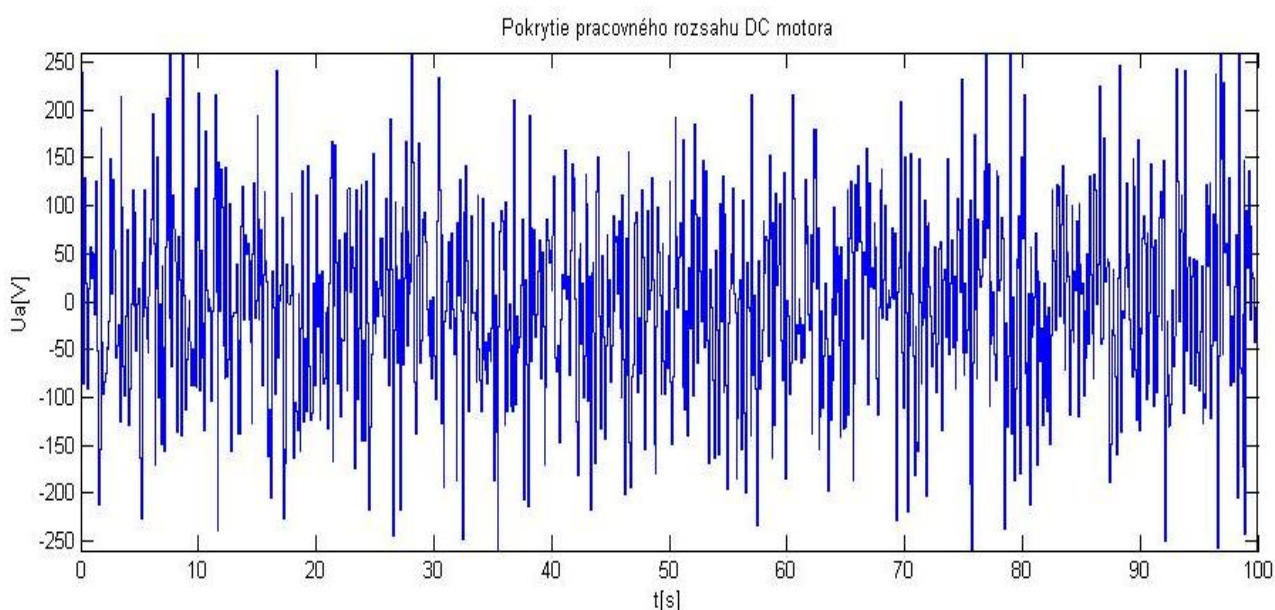
Je dôležité zvoliť typ vstupného signálu tak, aby pokryl pracovný rozsah systému. V našom prípade sa jedná o napätie u_a . Pri pokrytí celého pracovného rozsahu DC motora získame na výstupe systému hodnoty uhlovej rýchlosti ω , potrebných pre tréning siete.

4.2. Rozdelenie množiny tréningových dát

NNT v programe Matlab pracuje tak, že súbor dát, ktorý bude posúvaný neurónovej sieti sa rozdelí podľa [14] náhodne na 3 časti, ktoré sú použité na:

- tréning – dáta, použité na učenie neurónovej siete. Učenie je fáza počas tréningu, pri ktorej sa synaptické váhy posilňujú (ukladanie znalosti)
- vyhodnotenie – dáta použité na meranie generalizácie¹ (zovšeobecnenie) siete a na zastavenie učenia, ak sa generalizácia nezlepšuje
- testovanie – dáta, ktoré nemajú žiadny vplyv na proces tréningu. Na ich základe dokážeme zistiť ako dokáže neurónová sieť využívať znalosti, ktoré sa naučila vo fáze tréningu.

Dôležité je aby sme dáta správne rozdelili. Tréningová množina musí rovnomerne pokryť daný interval.



Obr. 3: Pokrytie pracovného rozsahu DC motora vhodným typom vstupného signálu

Môže sa stať, že nedokážeme pokryť celý pracovný rozsah systému, čím vzniknú miesta, v ktorých nepoznáme výstup systému. Dáta potrebné pre tréning preto nebudú kompletne. V takom prípade je neurónová sieť schopná extrapolovať takéto hluché miesta s veľmi veľkou presnosťou.

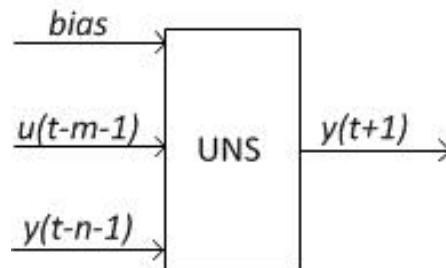
¹ Cieľom je extrapolácia funkčných hodnôt mimo tréningovú množinu čiže predikcia (predpoveď) aké budú funkčné hodnoty pre vstupné vektory, ktoré sieť nikdy nevidela. – [5] Návrat P, Bielíková M, Benusková L, Kapustík I, Unger M (2006) Umelá inteligencia, 2. vydanie Vydavateľstvo STU, Bratislava. ISBN 80-227-2354-1 (1. vydanie, 2002, ISBN 80-227-1645-6).

4.3. Dopredný model systému

Pri hľadaní inverzného neurónového modelu sa vychádza z doprednej dynamiky systému. Prvým krokom je natrénovať *UNS* tak, aby zachytila doprednú dynamiku systému, čím získame tzv. dopredný model systému, ktorý je popísaný vzťahom podľa [3] :

$$y(t+1) = f \begin{bmatrix} y(t), y(t-1), \dots, y(t-n-1) \\ u(t), u(t-1), \dots, u(t-m+1) \end{bmatrix} \quad (4)$$

Vstupmi do neurónovej siete sú *bias*, vstup systému $u(t)$ a jeho oneskorené vzorky $u(t-m-1)$, oneskorené vzorky regulovanej výstupnej veličiny systému $y(t)$ a jej oneskorené vzorky. Hodnoty m a n predstavujú počet oneskorených predchádzajúcich signálov. Výstupom je predikovaná hodnota $y(t+1)$.



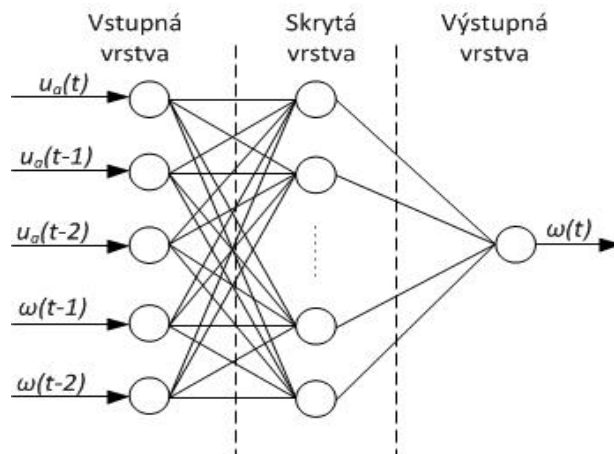
Obr. 4: Schéma dopredného modelu

Z obr.4 je zrejmé, že o výstupe siete nerozhodujú len aktuálne vstupy, ale aj ich história. Oneskorené vzorky vstupných signálov umožňujú *UNS* získať informácie o stave momentálneho vstupu v predošlých časových krokoch.

4.4. Trénovanie dopredného modelu

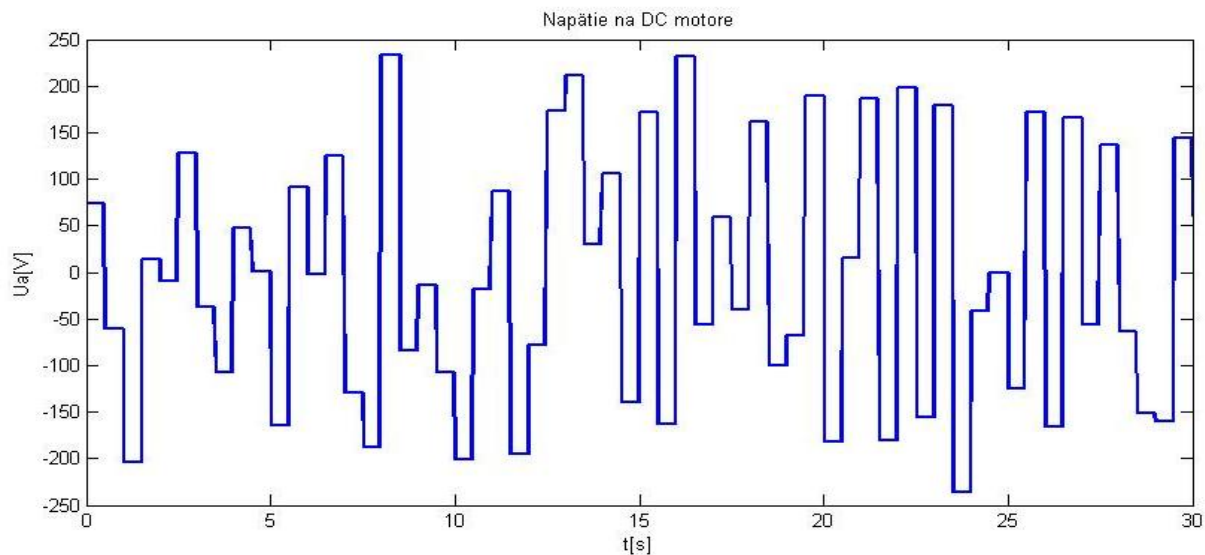
Trénovanie dopredného modelu prebieha v niekoľkých krokoch. V prvom kroku si určíme vstupy a výstupy *UNS*. Po natrénovaní *UNS* príslušnými dátami vstupov a výstupov analyzujeme chybu siete a ak nie sme s výsledkom spokojní rozšírime *UNS* o ďalší vstup alebo upravíme počet vnútorných neurónov. Takto pokračujeme dovtedy, kým nenájdeme optimálne parametre, pri ktorom *UNS* má minimálnu chybu oproti referenčnej hodnote.

Pri trénovaní dopredného modelu DC motora bol optimálny počet vstupov 5 a počet vnútorných neurónov 10. Vstupy boli reprezentované napätím motora $u_a(t)$, $u_a(t-1)$, $u_a(t-2)$ a oneskorenými vzorkami uhlovej rýchlosti $\omega(t-1)$ a $\omega(t-2)$. Výstupom je uhlová rýchlosť ω . Schéma topológie neurónovej siete dopredného modelu je na obr. 5:

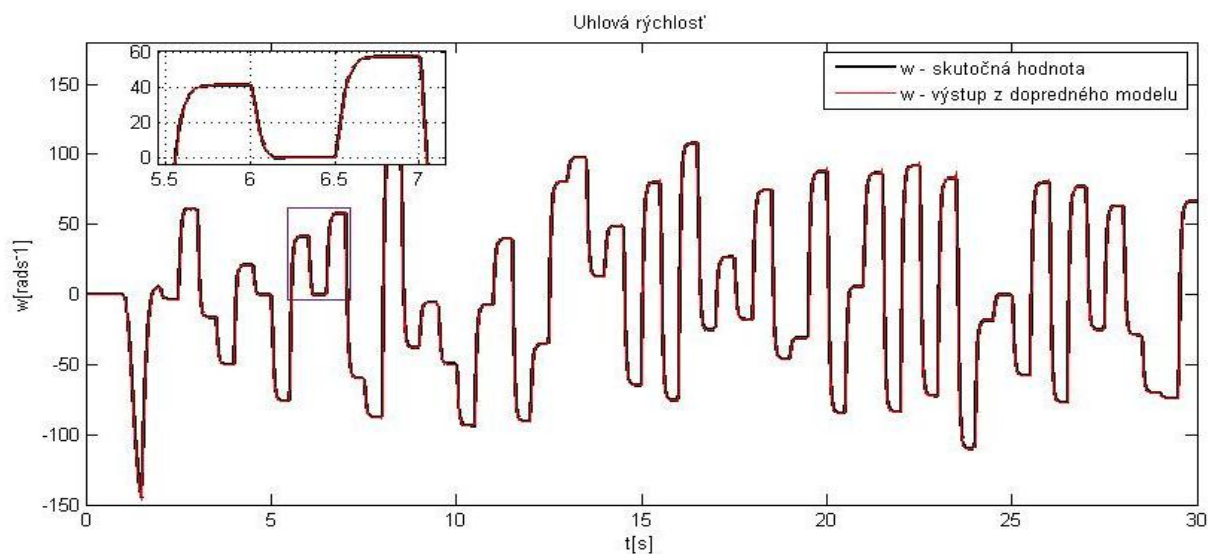


Obr. 5: Topológia dopredného modelu UNS.

Porovnanie uhlovej rýchlosti motora s výstupom dopredného modelu UNS:



Obr. 6: Napätie na DC motore



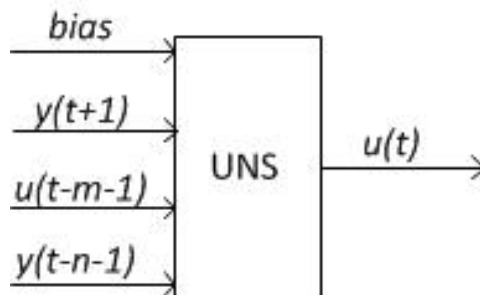
Obr. 7: Uhlová rýchlosť

4.5. Inverzný model systému

Po získaní dopredného modelu systému a minimalizovaní odchýlky medzi skutočnou hodnotou výstupu systému a výstupu *UNS* môžeme inverziou vzťahu (4) dopredného modelu získať inverzný neurónový model systému. Inverzný model systému je popísaný vzťahom :

$$u(t) = f^{-1} \begin{bmatrix} y(t+1), y(t), \dots, y(t-n+1) \\ u(t-1), \dots, u(t-m+1) \end{bmatrix} \quad (5)$$

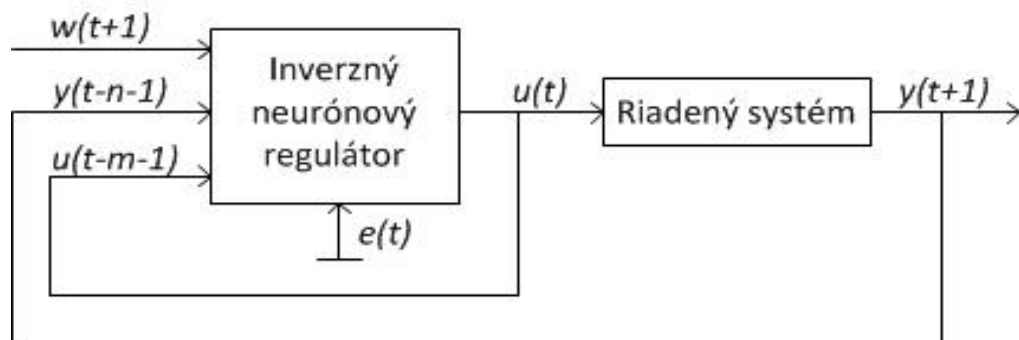
Schéma inverzného modelu podľa vzťahu (5):



Obr. 8: Schéma inverzného modelu

Vstupom do inverzného modelu je *bias*, vstupná a výstupná veličina systému *u(t)* a *y(t+1)* a ich oneskorené vzorky. Hodnoty *m* a *n* značia počet oneskorených signálov. Výstupom z inverzného modelu je akčná veličina *u(t)*.

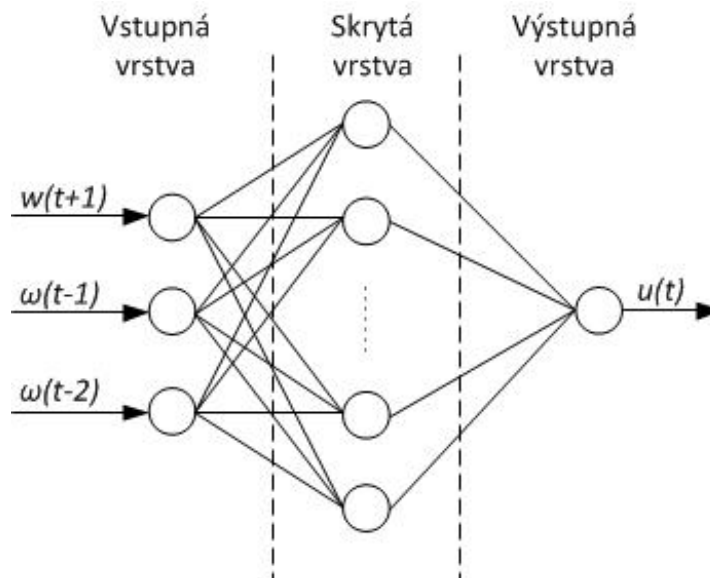
Počas tréningu je predpovedaná hodnota *y(t+1)*, ktorá je známa z množiny tréningových dát. Podľa [3], ak sa regulátor použije v uzavretom regulačnom obvode, sa táto hodnota stáva nedostupnou. V takom prípade ju nahradíme žiadanou hodnotou *w(t+1)*, čím získame z inverzného modelu spätnoväzobný neurónový regulátor. Zapojením takto vytvoreného inverzného regulátora do systému vytvoríme regulačný obvod s inverzným neurónovým regulátorom.



Obr. 9: Schéma regulačného obvodu s inverzným neurónovým regulátorom

Tréning inverzného modelu je totožný s postupom tréningu dopredného modelu, opísaného v kapitole 4.4.

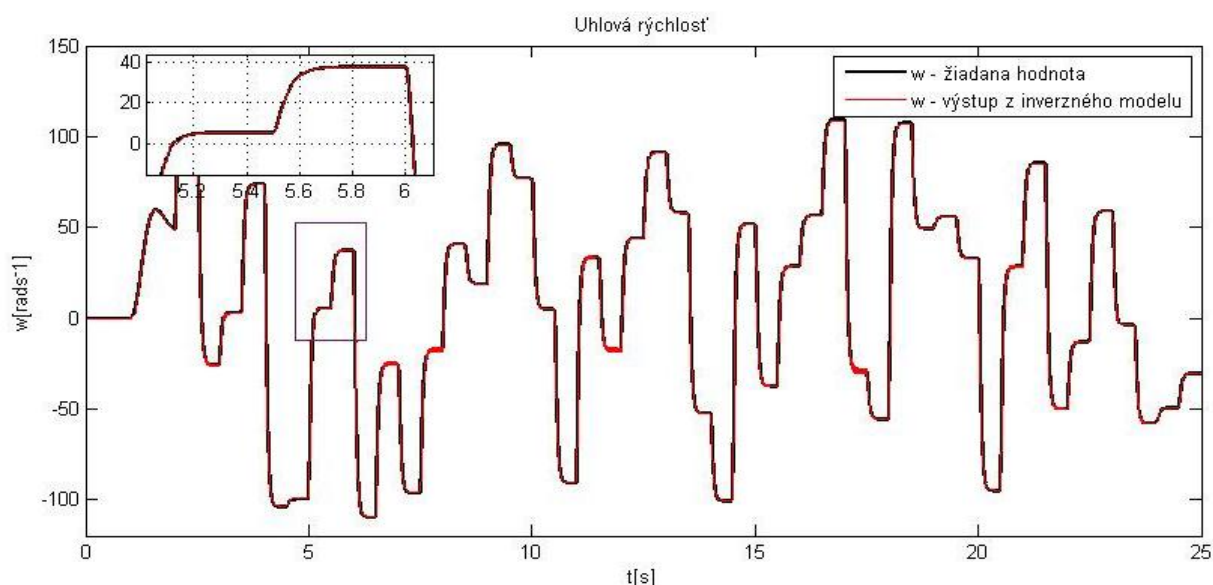
Najlepšie výsledky inverzný model DC motora vykazuje pri počte vstupných neurónov 3 a 10 vnútorných neurónov. Vstupy sú reprezentované žiadanou hodnotou uhlovej rýchlosti $\omega(t+1)$, oneskorenými vzorkami skutočnej hodnoty $\omega(t-n-1)$. Ako ďalší vstup *INS* je možné použiť akčný zásah $u(t)$. V našom prípade to nebolo nutné.



Obr. 10: Topológia inverzného modelu *UNS*

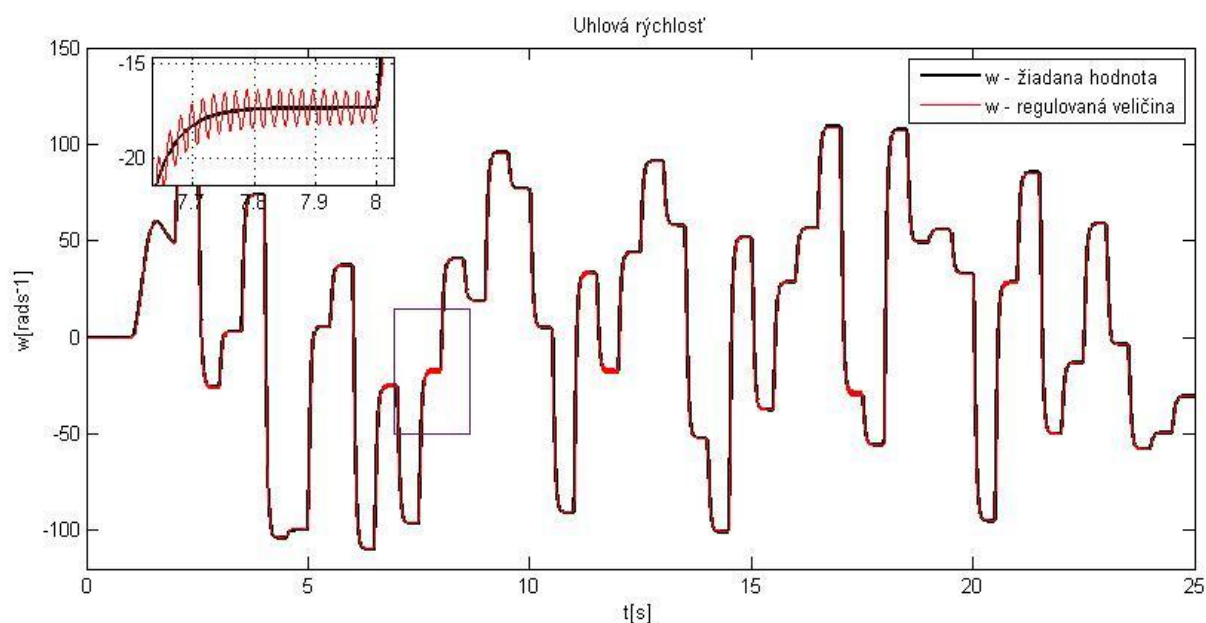
Dôležitým faktorom je správny výber signálu žiadanej hodnoty. Pre inverzný model DC motora nie je vhodné použiť obdĺžnikový signál uhlovej rýchlosti ako vstup. Z fyzikálneho ani konštrukčného hľadiska nám DC motor neumožňuje skokovú zmenu uhlovej rýchlosti. Použitím zlého typu signálu sa nám nepodarilo natrénovať inverzný model tak, aby spĺňal nami požadované kritéria. Preto je vhodné zvoliť typ signálu podobného skutočnému priebehu regulovanej veličiny.

Voľba vhodného signálu pre žiadanú veličinu a porovnanie výstupu inverzného modelu:



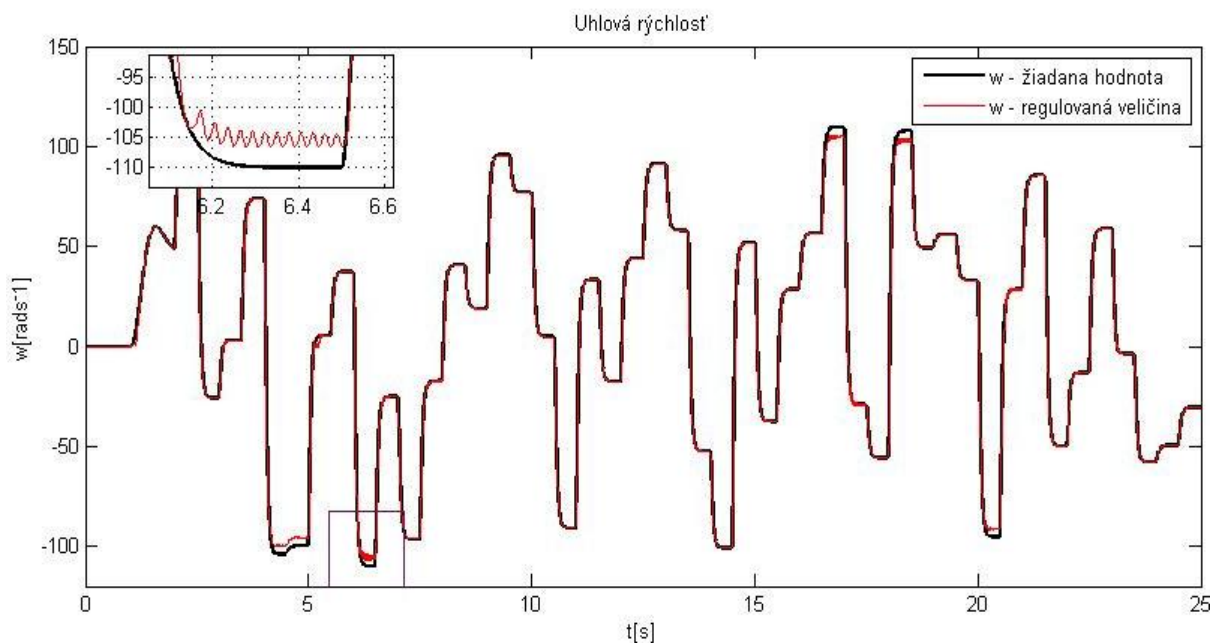
Obr. 11: Porovnanie žiadanej a regulovanej hodnoty systému

V niektorých miestach obr. 12 regulovaná veličina nekopíruje priebeh žiadanej hodnoty, sústava sa rozkmitá.



Obr. 12: Porovnanie žiadanej a regulovanej hodnoty systému

Pri pokuse o odstránenie kmitania znovu natrénovaním inverzného modelu, rozšírením vstupov siete zlepšenie výsledkov nenastalo.



Obr. 13: Pokus o odstránenie kmitania rozšírením vstupov

5. Stavový regulátor s kompenzáciou poruchy

Jednou z možností použitia lineárnych regulátorov je stavový spätnoväzobný regulátor. Základným rozdielom medzi klasickým *PID* regulátorom a stavovým regulátorom je v tom, že stavový regulátor používa pre výpočet akčných zásahov stavové veličiny, tzn. musíme poznať všetky informácie o stavových veličinách. Nie v každom prípade sme schopní získať úplne informácie o stavových veličinách. V takom prípade je možnosť použitia pozorovateľa. Úlohou pozorovateľa je získavať informácie o vstupoch a výstupoch systému. Ak sú už známe všetky stavy, sme schopní riadiť systém pomocou stavového regulátora. V našom prípade použitie pozorovateľa nebolo nutné.

Cieľom v tejto kapitole bolo vytvoriť pomocou lineárnych metód regulátor, ktorý by bol použitý na reguláciu uhlovej rýchlosti DC motora s coulombovým trením a v programe Matlab/Simulink sledovať jeho chovanie.

5.1. Stavový popis sústavy

Aby sme získali lineárny stavový model sústavy, prepíšeme diferenciálne rovnice (1) až (3) do stavových matic. Keďže v matici sústavy **A** by sa nachádzali dva stavy na sebe závislé – prúd motora i_a a budiaci prúd i_f , musíme zaviesť zjednodušenie. Spoločnú indukčnosť L_{af} a budiaci prúd i_f nahradíme napäťovou konštantou K_E a momentovou konštantou K_T , čím dostaneme sústavu dvoch diferenciálnych rovníc popisujúcich jednosmerný motor s permanentnými magnetmi:

$$\frac{di_a}{dt} = \frac{1}{L_a}(u_a - R_a \cdot i_a - K_E \cdot \omega) \quad (6)$$

$$\frac{d\omega}{dt} = \frac{1}{J}(K_T \cdot i_a - B_m \cdot \omega - T_f - T_L) \quad (7)$$

$$K_e \doteq K_T \quad (8)$$

Pomocou [7] sme zo vzťahov (6) a (7) sme zostavili matice predstavujúce lineárny stavový model so vstupom poruchy, ktorý je popísaný vzťahmi :

$$\mathbf{x}' = \mathbf{Ax} + \mathbf{Bu} + \mathbf{Ez} \quad (9)$$

$$\mathbf{y} = \mathbf{Cx} + \mathbf{Du} \quad (10)$$

A – matica systému, popisujúca závislosť medzi stavmi a ich deriváciami

B – matica budenia, popisujúca závislosť medzi vstupmi systému a deriváciami stavov

C – matica výstupov, popisujúca závislosť medzi výstupmi a stavmi

D – matica prenosov, popisujúca závislosť medzi výstupmi a vstupmi

E – matica poruchy

$$\begin{bmatrix} \omega' \\ i_a' \end{bmatrix} = \begin{bmatrix} -\frac{B_m}{J} & \frac{K_T}{J} \\ -\frac{K_e}{L_a} & -\frac{R_a}{L_a} \end{bmatrix} \cdot \begin{bmatrix} \omega \\ i_a \end{bmatrix} + \begin{bmatrix} 0 \\ \frac{1}{L_a} \end{bmatrix} [u_a] + \begin{bmatrix} \frac{1}{J} \\ 0 \end{bmatrix} \cdot [-T_L] \quad (11)$$

$$\begin{bmatrix} \omega \\ i_a \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} \omega \\ i_a \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \end{bmatrix} [u_a] \quad (12)$$

Vektor stavov \mathbf{x} reprezentuje uhlovú rýchlosť ω a prúd motora i_a . Vektor \mathbf{u} , predstavujúci vstupy systému obsahuje napätie motora u_a . Poruche systému odpovedá zaťažovací moment T_L . Vektor výstupov \mathbf{y} obsahuje stavy systému.

5.2. Riaditeľnosť

Aby mohla byť sústava regulovaná je nutné určiť jej riaditeľnosť. Sústava je riaditeľná vtedy, keď sú vstupy \mathbf{u} schopné v určitom čase spôsobiť zmenu stavu \mathbf{x}_0 do iného ľubovoľného stavu \mathbf{x}_k [7].

Podmienka, ktorá stanovuje riaditeľnosť sústavy, je aby hodnota matice riaditeľnosti \mathbf{M}_c n -tého rádu bola rovná n , alebo determinanty vyššieho stupňa ako n boli nulové [7].

$$\mathbf{M}_c = [\mathbf{B} \ \mathbf{A}\mathbf{B} \ \mathbf{A}^2\mathbf{B} \ \dots \ \mathbf{A}^{n-1}\mathbf{B}] \quad (13)$$

V Matlabe príkazom `rank(ctrb(A,B))` určíme riaditeľnosť, kde `ctrb` vypočíta maticu riaditeľnosti a `rank` určí jej hodnotu.

5.3. Návrh stavového regulátora s kompenzáciou poruchy

Pre regulátor s integrátorom na vstupe platí zákon riadenia uvedený v [7] v tvare:

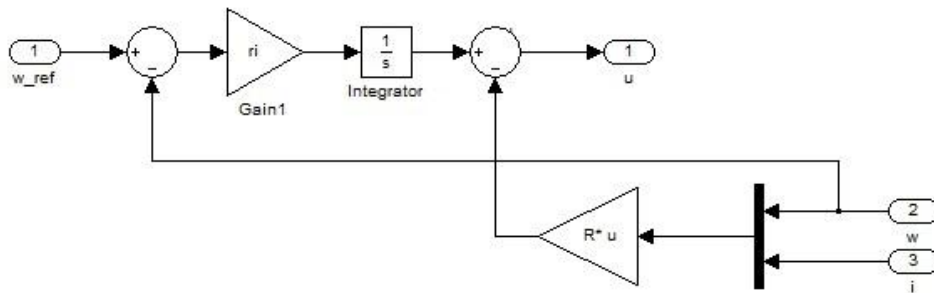
$$u = -\mathbf{R}\mathbf{x} + \mathbf{r}_i \cdot \int_0^t (w - y) d\tau \quad (14)$$

$$v = \int_0^t (w - y) d\tau \quad (15)$$

$$u = -\mathbf{R}\mathbf{x} + \mathbf{r}_i \cdot v \quad (16)$$

$$v' = w - y \quad (17)$$

Vektor \mathbf{R} predstavuje zisky stavového spätnoväzobného regulátora, \mathbf{r}_i zisky integrátora a w definuje referenčný signál. Zisky regulátorov boli vypočítané pomocou funkcie `place`.

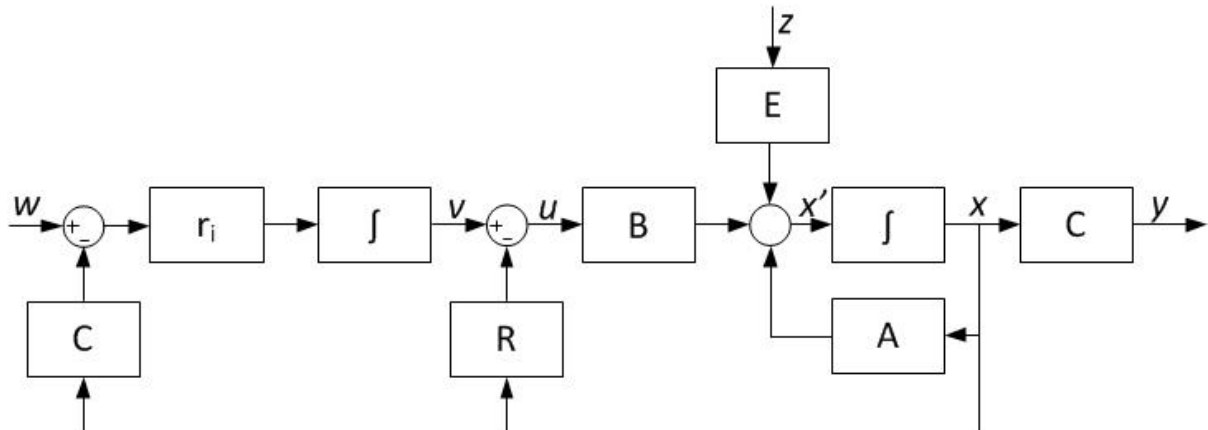


Obr. 14: Model stavového regulátora s integrátorom na vstupe

Zo vzťahu (17) vidno, že pribudol jeden stav. Je nutné doplniť stavový model o jednu rovnicu:

$$\begin{bmatrix} \dot{x}' \\ \dot{v}' \end{bmatrix} = \begin{bmatrix} A & 0 \\ 0 & 0 \end{bmatrix} \cdot \begin{bmatrix} x \\ v \end{bmatrix} + \begin{bmatrix} B \\ 0 \end{bmatrix} \cdot [u] + \begin{bmatrix} 0 \\ 1 \end{bmatrix} [w - y] = \left(\begin{bmatrix} A & 0 \\ -C & 0 \end{bmatrix} - \begin{bmatrix} B \\ -D \end{bmatrix} [R - r_i] \right) \cdot \begin{bmatrix} x \\ v \end{bmatrix} + \begin{bmatrix} 0 \\ 1 \end{bmatrix} [w] \quad (18)$$

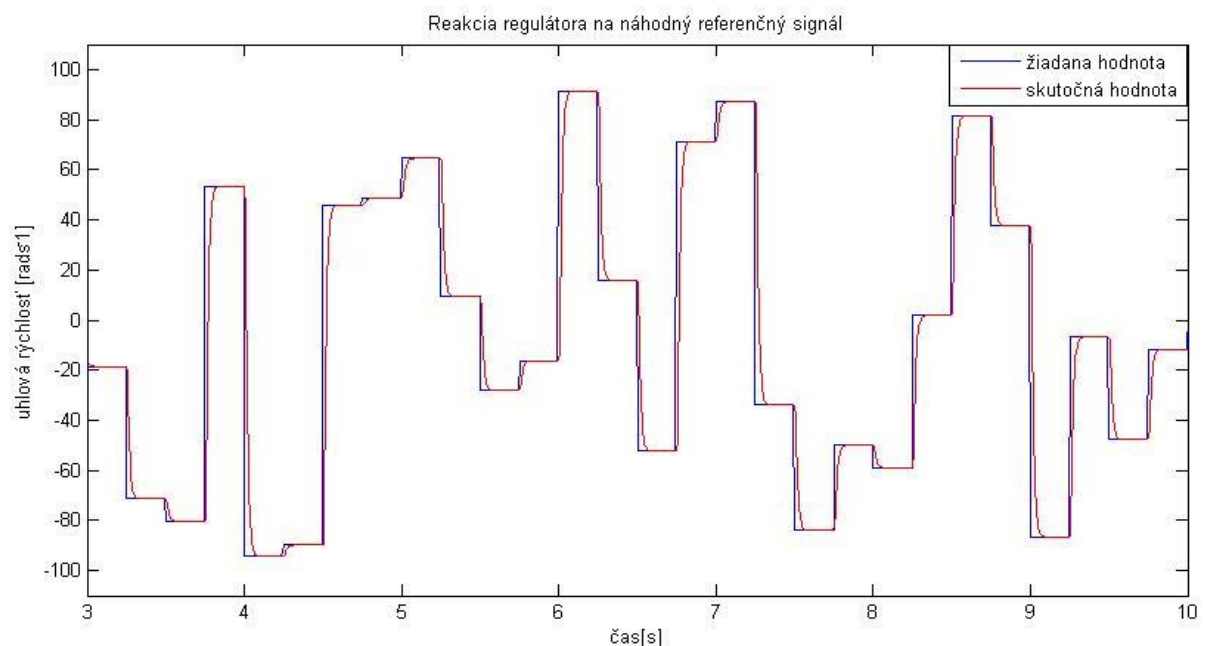
Schéma zapojenia stavového spätnoväzobného regulátora s kompenzáciou poruchy podľa [9] je znázornená na obr. 15.



Obr. 15: Stavový regulátor s kompenzáciou poruchy

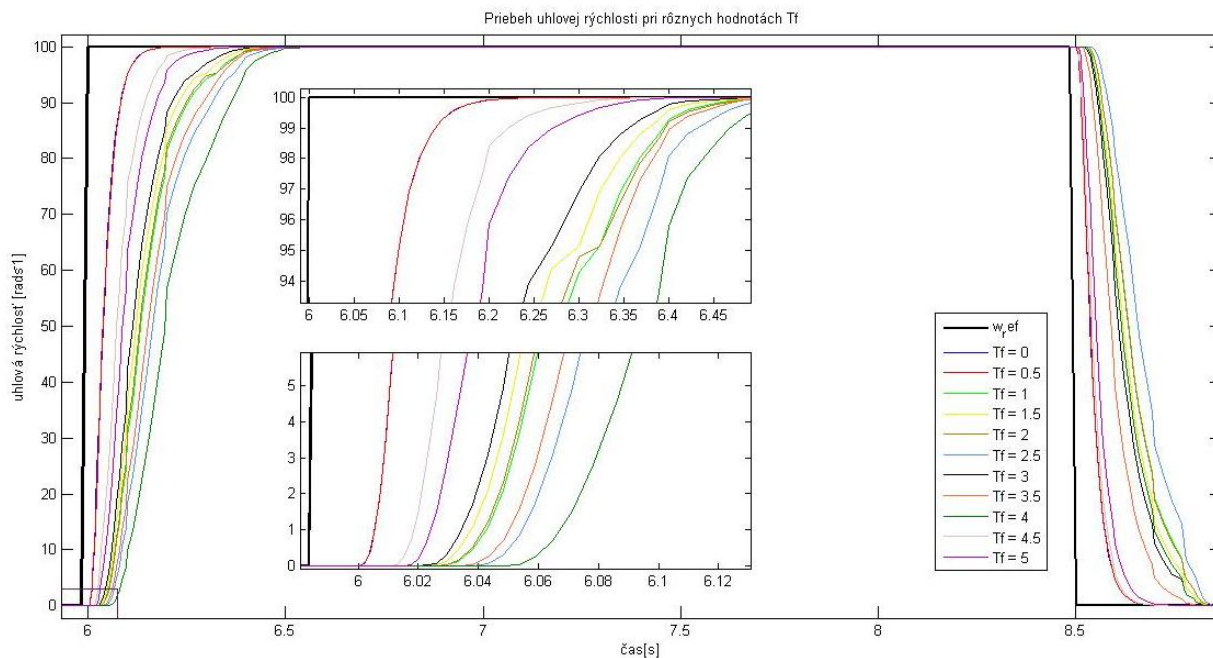
Rýchlosť s akou regulátor reaguje na zmenu referenčnej hodnoty môžeme jednoducho kontrolovať zmenou pólov (vlastných čísel) v zápornej komplexnej rovine. Vlastné čísla nám určujú stability resp. nestabilitu a rýchlosť dynamiky sústavy. Umiestnením vlastných čísel do zápornej časti komplexnej roviny získame lepšiu stabilitu a rýchlosť sústavy [7].

Takto vytvorený regulátor použijeme na reguláciu rýchlosti nelineárneho systému – DC motor s coulombovým trením, v programe Matlab/Simulink budeme sledovať jeho vlastnosti.



Obr. 16: Reakcia stavového regulátora s kompenzáciou poruchy na náhodný referenčný signál

Obr. 17 demonštruje správanie sa regulátora pre rôzne hodnoty coulombového trenia. So zväčšujúcim sa koeficientom trenia sa priebeh uhlovej rýchlosti pravidelne nezhoršuje akoby sme očakávali. Napríklad pre hodnotu $T_f = 3$ (čierna) regulátor pomalšie reaguje ako pre hodnotu $T_f = 5$ (fialová).



Obr. 17: Priebeh uhlovej so stavovým regulátorom s kompenzáciou poruchy pre rôzne hodnoty coulombového trenia

6. Inverzný neurónový *PID* regulátor

Jednoduchá a efektívna metóda ako docieľať kvalitnejšej regulácie uhlovej rýchlosti DC motora je kombinácia *PID* regulátora s inverzným neurónovým modelom. Prvým krokom je natrénovanie neurónovej siete na inverznú dynamiku systému. Tento krok je popísaný v kapitole 4.5. Pre kompenzáciu chyby regulácie sa k inverznému modelu pridá klasický *PID* regulátor. Výstupy z *PID* regulátora budú zároveň tvoriť vstupy pre inverzný neurónový model.

6.1. Návrh a ladenie *PID* regulátora metódou Ziegler-Nichols

Metóda ladenia *PID* regulátora podľa Ziegler-Nicholsa je experimentálna metóda, ktorá slúži k nájdeniu jednotlivých zložiek P_p , P_I , P_D regulátora. Výhodou tejto metódy je, že nie je nutné poznať matematický model regulovanej sústavy [4].

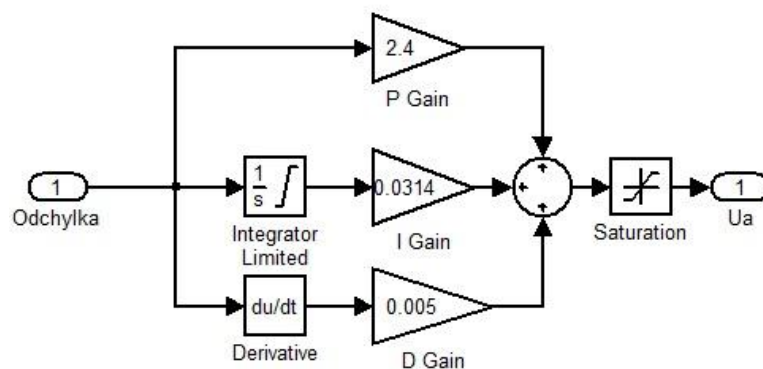
Základnou ideou použitia metódy Ziegler-Nicholsa je priviesť regulovanú sústavu na hranicu stability, tzn. do zápornej spätnej väzby pridáme zosilnenie K . Hodnota, pri ktorej sa v sústave prejaví netlmené kmity sa nazýva kritické zosilnenie K_m . Odmeraním periódy netlmených kmitov získame tzv. kritickú dobu periódy T_k . Pomocou týchto dvoch parametrov z tab.1 uvedenej v [10], zistíme optimálne parametre *PID* regulátora.

Regulátor	K_p	T_i	T_d
<i>P</i>	$0,5 K_m$	-	-
<i>PI</i>	$0,45 K_m$	$10\pi^2/3\omega_m^2$	-
<i>PID</i>	$0,6 K_m$	π/ω_m	$\pi/4\omega_m$

Tab. 1: Nastavenie zložiek regulátora

Postup nastavovania regulátora pomocou Ziegler-Nicholsa:

- ako prvé vyradíme integračnú P_I a derivačnú P_D zložku ($T_i \rightarrow \infty$, $T_d \rightarrow 0$)
 - zvyšujeme zosilnenie r_0 dovtedy, kým sa neprejaví netlmené kmity. Netlmené kmity sú charakteristické konštantnou amplitúdou a periódou kmitov. Odčítame kritické zosilnenie K a dobu kmitu T_k .
 - z parametrov K a T_k pomocou tab. 1 vypočítame optimálne parametre regulátora
- Na obr. 15 je znázornený *PID* regulátor s vypočítanými parametrami podľa Ziegler-Nicholsa.



Obr. 18: Model *PID* regulátora

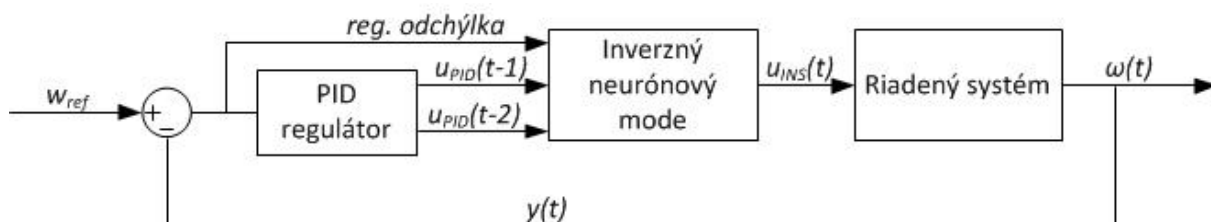
Pôvodné hodnoty jednotlivých zložiek *PID* regulátora vypočítaných pomocou Ziegler-Nichols sme upravili pre lepšie vlastnosti regulácie. P_I zložka zostala nezmenená.

$$P_p = 2,1 \rightarrow P_p = 2,4 \quad (19)$$

$$P_D = 0,0075 \rightarrow P_D = 0,005 \quad (20)$$

6.2. Inverzný neurónový *PID* regulátor

Ako inverzný neurónový model použijeme už hotový model inverznej dynamiky systému vytvoreného v kapitole 4.5. Kombináciou inverzného modelu a *PID* regulátora získame inverzný neurónový *PID* regulátor, ktorého schéma je znázornená na obr. 19.

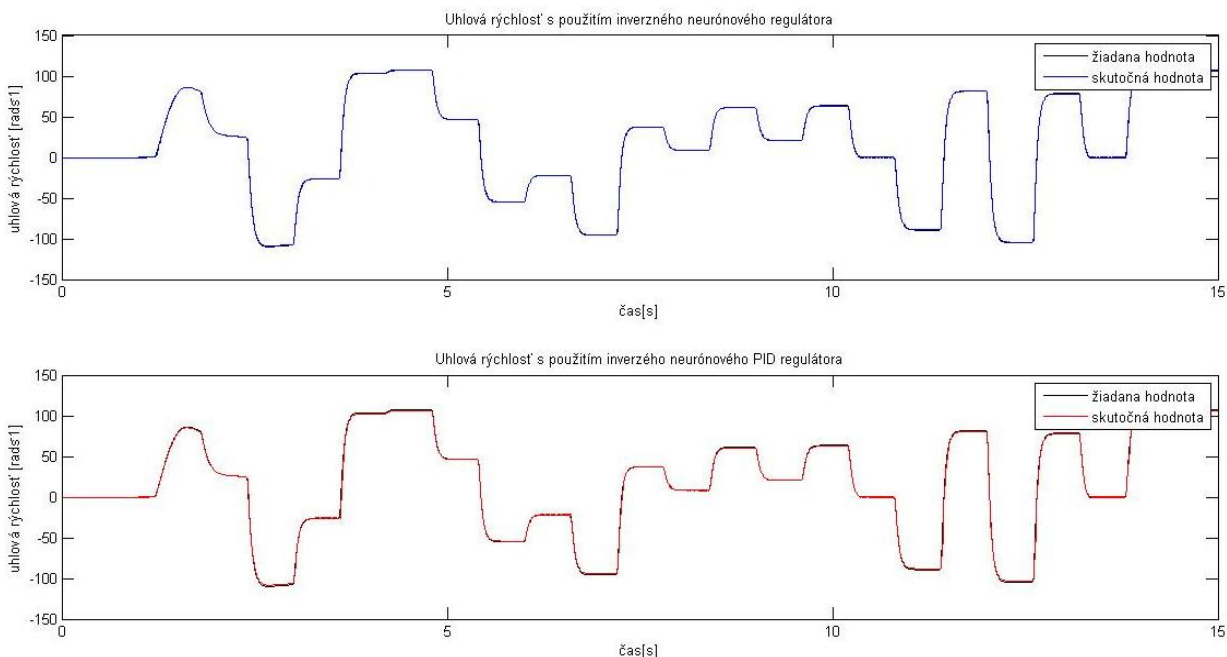


Obr. 19: Inverzný neurónový regulátor

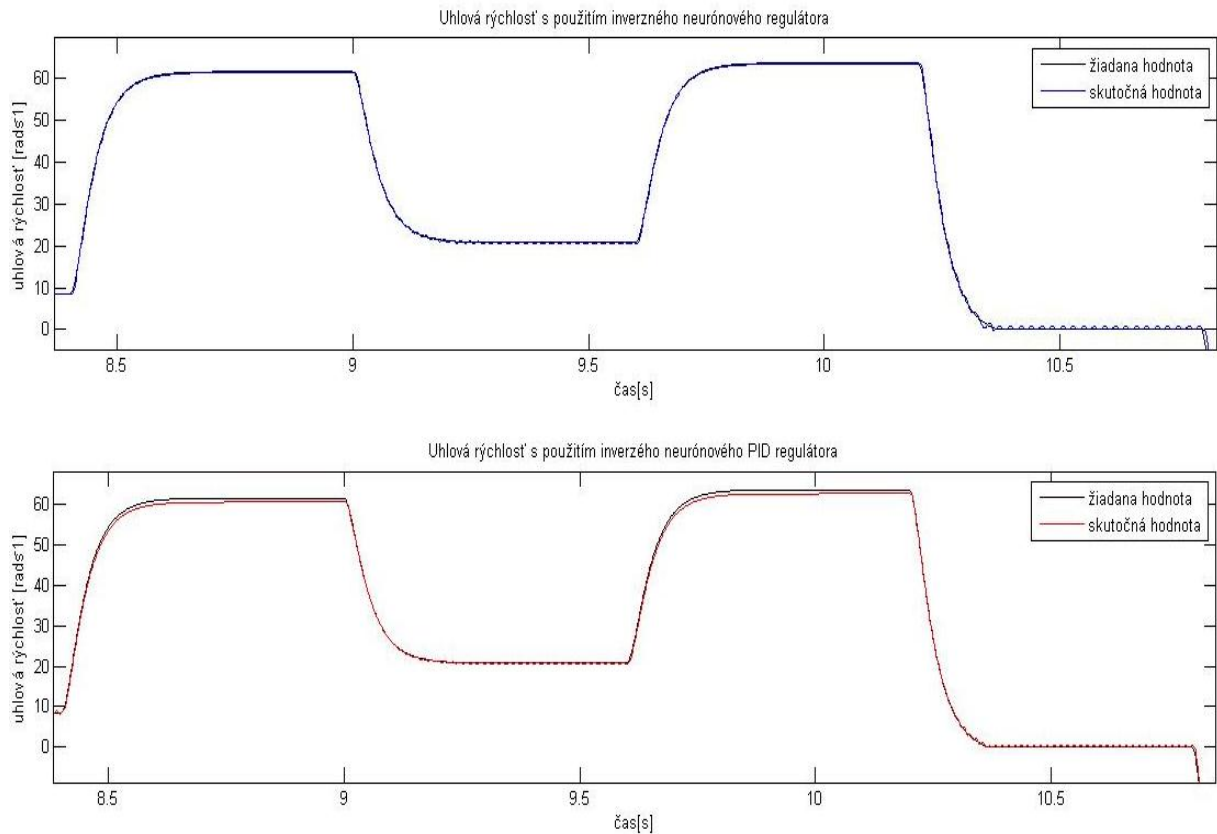
Vstupom do inverzného modelu je regulačná odchýlka uhlovej rýchlosti, akčný zásah $u_{PID}(t)$ a jeho oneskorené vzorky. Inverzný neurónový model na základe dostupných informácií vyvodí taký akčný zásah $u_{INS}(t)$ tak, aby na výstupe riadeného systému sme dosiahli požadovanú hodnotu uhlovej rýchlosti $\omega(t)$.

Ako bolo spomenuté v kapitole 4.5., že použitím samotného inverzného regulátora dochádza v určitých miestach k rozkmitaniu výstupu riadeného systému. Tento problém kombinácia inverzného modelu a *PID* regulátora úplne neodstraňuje.

Funkčnosť neurónového *PID* regulátora je znázornená na nasledujúcich obrázkoch :



Obr. 20: Reakcia inverzného neurónového *PID* regulátora na náhodný signál



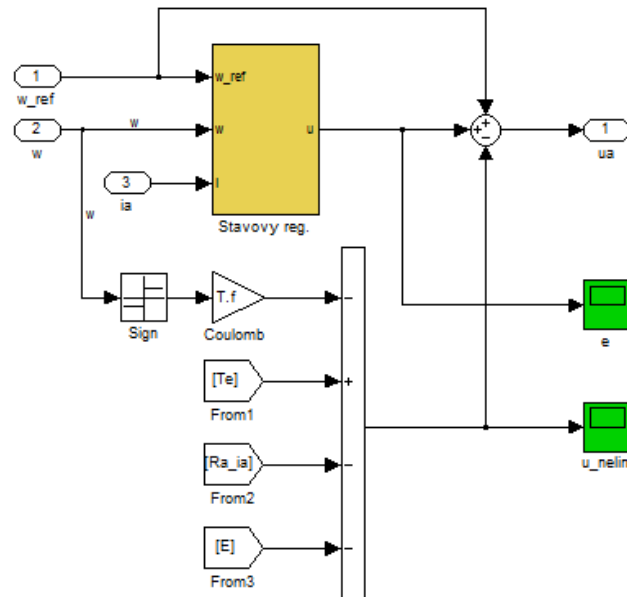
Obr. 21: Reakcia inverzného neurónového *PID* regulátora na náhodný signál

Na obr. 21 je detail priebehu skutočnej hodnoty uhlovej rýchlosti s použitím *INS* a kombinácie *INS* a *PID*. Kombináciou týchto dvoch regulátorov sa nám nepodarilo úplne odstrániť kmitanie v určitých miestach charakteristiky. Pridaním *PID* regulátora sa amplitúda kmitov zmenšila, avšak kopírovanie priebehu referenčnej hodnoty nie je až tak presné, ako pri použití samotného inverzného neurónového modelu.

7.2. Aplikovanie stavového regulátora

Odstránením nelinearity sa nám ponúka možnosť použitia ľubovoľného lineárneho regulátora. Ako lineárny regulátor bol zvolený stavový regulátor s kompenzáciou poruchy. Postup návrhu regulátora je popísaný v kapitole 5.3.

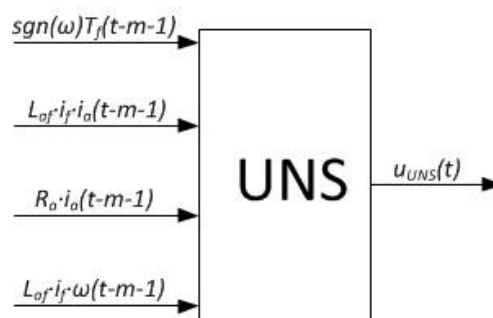
Vzťah, ktorý je potrebný pridať na pravú stranu rovnice (21) pričítame ku akčnému zásahu stavového regulátora, čím sa bude podieľať na výslednom priebehu napätia vstupujúceho do motora.



Obr. 24: Aplikovanie stavového regulátora s kompenzáciou poruchy

7.3. Nahradenie nelinearity umelou neurónov siet'ou

Aby sme mohli nahradiť nelinearitu zo vzťahu (21) je potrebné natrénovať *UNS*. Model neurónovej siete nelinearity DC motora je znázornený na obr. 25:

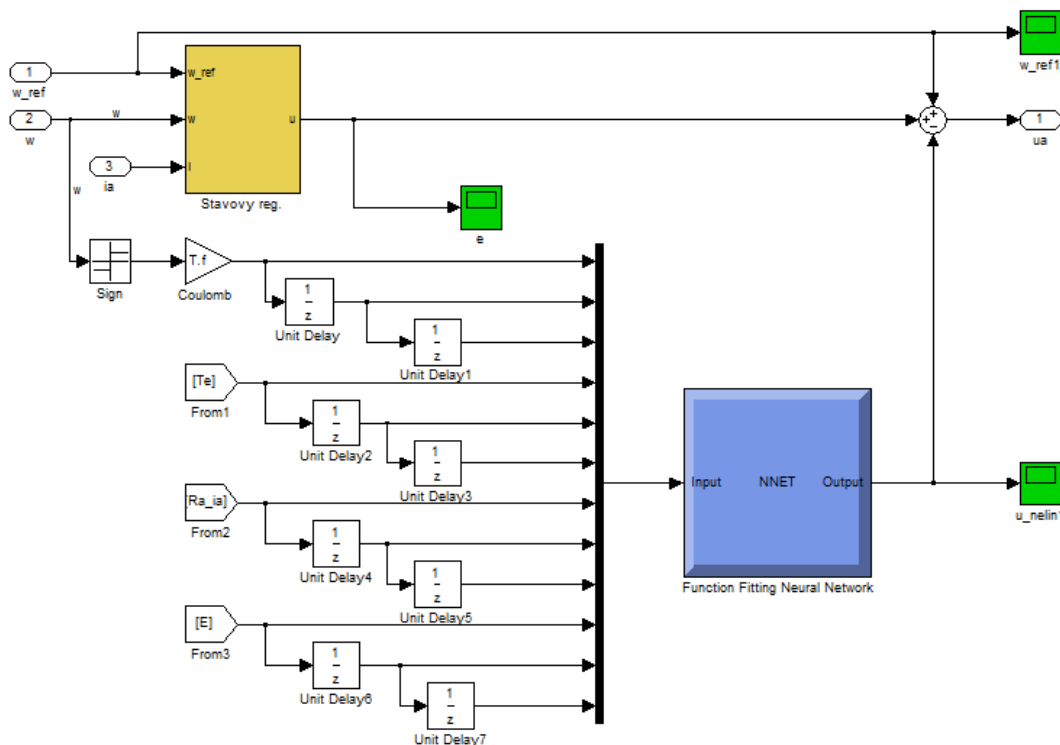


Obr. 25: Model *UNS* nelinearity DC motora

Vstupnými parametrami budú veličiny $T_{fsgn}(\omega)$, L_{afifl_a} , R_{afl_a} , $L_{afif\omega}$ a ich oneskorené vzorky. Hodnota m značí počet oneskorených signálov od jednotlivých vstupov. Celkový počet vstupov je 12, tzn. okrem každej vstupnej veličiny do UNS vstupujú aj 2 oneskorené vzorky signálu. Výstupom je akčná veličina $u_{UNS}(t)$.

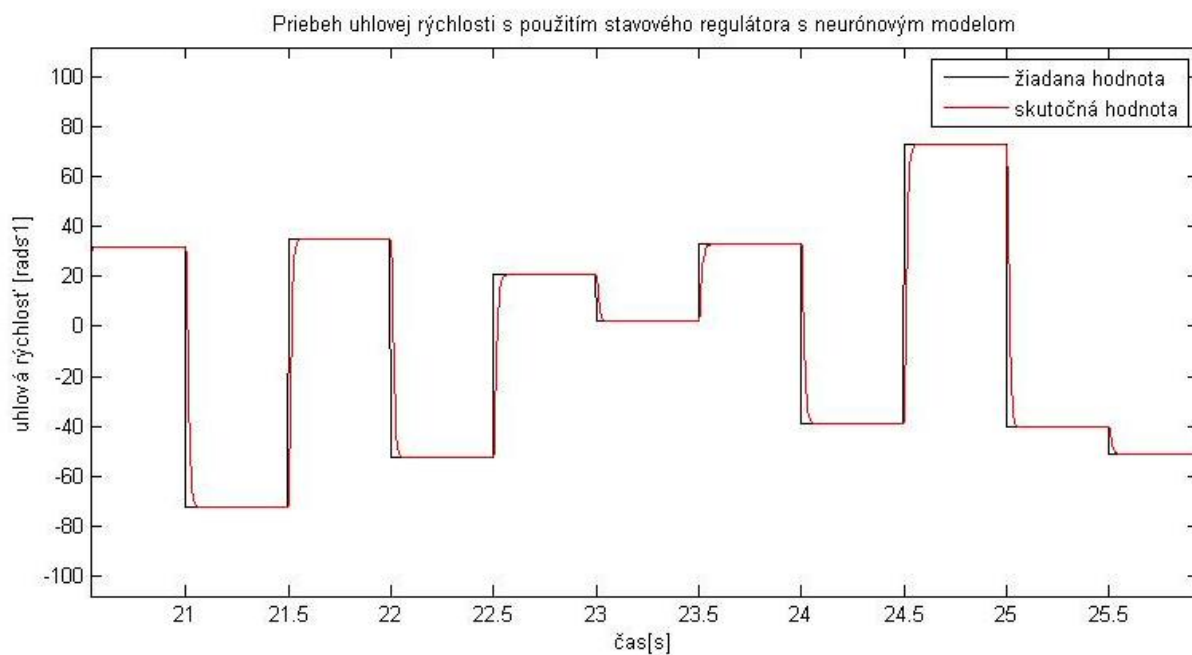
7.4. Stavový regulátor s neurónovým modelom

Nahradenie nelinearity natrénovanou neurónov sieťou a zapojenie so stavovým regulátorom s kompenzáciou poruchy je na obr. 26:



Obr. 26: Stavový regulátor s neurónovým modelom nelinearity

Na nasledujúcom obrázku je reakcia regulátora na náhodný signál:



Obr. 27: Priebeh uhlovej rýchlosti s použitím stavového regulátora s neurónovým modelom nelinearity

Problémy s kmitaním u inverzného regulátora a jeho kombinácie s PID regulátorom sa nám podarilo odstrániť pomocou stavového regulátora s neurónovým modelom.

8. Záver

Hlavným cieľom tejto práce bolo zoznámiť sa a analyzovať zaujímavú oblasť použitia neurónových sietí akou je riadenie dynamických systémov. V úvodnej časti práce bola načrtnutá problematika riadenia a riadenie pomocou neurónových sietí. Bolo vysvetlené čo je to neurónová sieť a aplikačný potenciál v praxi.

Druhá časť práce bola zameraná na reguláciu uhlovej rýchlosti pomocou inverzného neurónového modelu nelineárneho systému. Nelineárny systém bol reprezentovaný jednosmerným motorom s cudzím budením. Nelinearitu v tomto systéme spôsobuje coulombové trenie. Aby bolo možné vytvoriť inverzný model musíme najprv poznať dopredný model dynamiky systému. Zo znalosti dopredného modelu bol následne vytvorený inverzný model jednosmerného motora. Takto vytvorený model, ktorý plní funkciu regulátora sme zapojili do serie s riadeným systémom. Funkčnosť regulátora bola testovaná na vzorke náhodných signálov uhlovej rýchlosti. Regulátor kopíroval s minimálnou chybou priebeh referenčnej hodnoty, avšak v niektorých častiach charakteristiky sa výstup riadeného systému rozkmitá. Rozšírenie vstupov, zvýšenie počtu vnútorných neurónov nemal pozitívny vplyv na odstránenie kmitania.

Ďalšia časť práce popisuje postup a návrh stavového spätnoväzobného regulátora s kompenzáciou poruchy. Regulátor tohto typu je primárne určený na reguláciu lineárnych systémov. My sme ho použili v zapojení s nelineárnym systémom. Funkčnosť regulátora bola testovaná pre rôzne koeficienty coulombovho trenia. Stavový regulátor vykazoval dobré schopnosti v tomto zapojení. Priebeh skutočnej hodnoty sa však pravidelne nezhoršoval so zvyšujúcim sa koeficientom coulombovho trenia.

Dobrou možnosťou ako dosiahnuť lepší priebeh regulácie je použitie kombinácie neurónového a *PID* regulátora navrhnutého pomocou metódy Ziegler-Nichols. Regulačná odchýlka *PID* regulátora tvorila jeden vstup inverzného modelu systému. Ďalšie dva vstupy inverzného modelu boli reprezentované akčným zásahom *PID* regulátora. Vo výsledku bol takto vytvorený inverzný neurónový *PID* regulátor testovaný na náhodný referenčný signál. Kmitanie, ktoré vzniklo u inverzného modelu sa nám pomocou *PID* podarilo minimalizovať.

Štvrtá časť je zameraná na kombináciu stavového regulátora a neurónového modelu nelinearity riadeného systému. Neurónová sieť bola natrénovaná na nelinearitu systému a v kombinácii so stavovým regulátorom tvorili kontrolér. Funkčnosť bola testovaná na náhodný referenčný signál. Pri tomto regulátore nastali mierne prekmity ako pri ostatných regulátoroch, avšak tento nedostatok sme odstránili úpravou pólov stavového regulátora.

9. Zoznam použitej literatúry

- [1] ŠTOFAN, Daniel. Dynamické riadenie mobilného robota na báze neurónových sietí (Diplomová práca). Košice: TU – FEI, 2005.
- [2] HORNIK, K., STICHCOMBE, M., WHITE, H. (1989): *Multilayer feedforward networks are universal approximators*. Neural Networks 2, 259-366.
- [3] PASTOREKOVÁ, Lucia; MÉSZÁROS, Alojz; BRURIAN, Peter. Inteligentné riadenie systémov na báze inverzných neurónových modelov. *AT&P journal PLUS7*[online], 2005,[cit. 13. Máj 2012]. Dostupné na WWW: http://www.kirp.chtf.stuba.sk/publication_access.php?id=301&type=1
- [4] ŠVARC, Ivan; *Teórie automatického řízení*. Brno, listopad 2003
- [5] NÁVRAT, P.; BIELIKOVÁ, M; BENUŠKOVÁ, L; KAPUTSTÍK, I; UNGER, M. (2006) *Umelá inteligencia*, 2. vydanie Vydavateľstvo STU, Bratislava. ISBN 80-227-2354-1 (1. vydanie, 2002, ISBN 80-227-1645-6).
- [6] SINČÁK, P; NOVOTNÝ, D; KOSTELNIK, P. *Strojová inteligencia, inteligentné technológie – súčasnosť a budúcnosť*. Konferencia s medzinárodnou účasťou Kybernetika a informatika, Piešťany, Apríl, 2001
- [7] BŘEZINA, T. *State feedback control design in Matlab through pole placement method*. Brno, 2005 – 2011
- [8] JANEČEK, J; BÍLA, J. O jednom nebezpečí stavové regulace. *AUTOMA*[časopis, online], 2000, roč. 1, č. 10, [cit. 13. Máj 2012]
Dostupné na WWW: http://www.odbornecasopisy.cz/index.php?id_document=27943
- [9] BŘEZINA, T. Poznámky k přednáškám RIR, III., 2.11. 2005
- [10] BŘEZINA, T. Poznámky k přednáškám RIR, I., 2.11. 2005
- [11] CHIA-JU, WU; CHING-HUO HUANG: A Neural Network Controller with PID Compensation for Trajectory Tracking of Robotic Manipulators. Taiwan : Department of Electrical Engineering, National Yunlin Institute of Technology, 1996
- [12] SKALICKÝ, J. *Teórie řízení*. 2. vyd. Brno : VUT FEKT, 2002
- [13] HECHT – NIELSEN, R. *Neurocomputing*. Addison-Wesley 1990: I-XIII, 1-433
- [14] Help programu Matlab

10. Zoznam použitých skratiek a symbolov

<i>NNT</i>	- <i>neural-network toolbox</i>
<i>UNS</i>	- <i>umelá neurónová sieť</i>
<i>INS</i>	- <i>inverzná neurónová sieť</i>
i_f	- <i>budiaci prúd [A]</i>
u_f	- <i>budiace napätie [V]</i>
R_f	- <i>odpor budenia [Ω]</i>
L_f	- <i>indukčnosť budenia [F]</i>
L_{af}	- <i>spoločná indukčnosť [H]</i>
i_a	- <i>prúd na motore [A]</i>
u_a	- <i>napätie na motore [V]</i>
R_a	- <i>odpor motora [Ω]</i>
L_a	- <i>indukčnosť motora [F]</i>
ω	- <i>uhlová rýchlosť [$\text{rad}\cdot\text{s}^{-1}$]</i>
J	- <i>moment zotrvačnosti [$\text{kg}\cdot\text{m}^2$]</i>
K_E	- <i>napäťová konštanta [$\text{V}/\text{rad}\cdot\text{s}^{-1}$]</i>
K_T	- <i>momentová konštanta [Nm]</i>
B_m	- <i>koeficient viskózneho trenia [-]</i>
T_f	- <i>koeficient coulombového trenia [-]</i>
T_L	- <i>záťaž motora [N·m]</i>
F_c	- <i>trecia sila [N]</i>
\mathbf{x}	- <i>stavový vektor</i>
\mathbf{u}	- <i>vstupy systému stavového modelu</i>
\mathbf{Mc}	- <i>matica riaditeľnosti</i>
\mathbf{R}	- <i>zisky späťoväzobného regulátora</i>
\mathbf{r}_i	- <i>zisky integrátora</i>
K	- <i>zosilnenie</i>
K_m	- <i>kritické zosilnenie</i>
T_k	- <i>kritická doba periódy netlmených kmitov</i>
u_{PID}	- <i>akčný zásah PID regulátora</i>
u_{INS}	- <i>akčný zásah inverznej neurónovej siete</i>
u_{UNS}	- <i>akčný zásah umelej neurónovej siete</i>

11. Zoznam príloh

Príloha DC:

- Príloha č.1 – Elektronická verzia bakalárskej práce (Posouzení vhodnosti učení pro heuristické adaptivní řízení pohonů.pdf)
- Príloha č.2 – Příprava dat pre neurónovú sieť (DC_motor.mdl, priprava_dat.m)

- Príloha č.3 – Dopredný model DC motora (Dopredny_model_DC.m, Dopredny_model_DC_motor.mdl)
- Príloha č.4 – Inverzný model DC motora (DC_motor_INN.mdl, Inverzny_model_DC_motor.m, Inverzny_model_DC_motor.mdl)
- Príloha č.5 – Inverzný model s PID (DC_motor_INN_PID.mdl, Inverzny_model_DC_motor_PID.m, Inverzny_model_DC_motor_PID.mdl),
- Príloha č. 6 – Stavový regulátor DC motora s neurónovým modelom nelinearity (DC_motor.mdl, DC_motor_ss1.mdl, DC_motor_ss2.mdl, DC_motor_ss3.mdl, parametre.m, priprava_dat.m)