

# IDENTIFIKÁCIA DYNAMIKY RAMENA MANIPULÁTORA S PNEUMATICKÝMI UMELÝMI SVALMI S VYUŽITÍM NEURÓNOVÝCH SIETI A UČIACICH ALGORITMOV V PROGRAME PYTHON

## Identification of dynamics of the manipulator arm with pneumatic artificial muscles with use neural networks and learning algorithms in program Python

Monika Trojanová, Alexander Hošovský, Ivo Bukovský

*Abstrakt:* Článok sa venuje identifikácii ramena manipulátora s dvoma stupňami voľnosti poháňaného pneumatickými umelými svalmi. Namerané dáta použité v procese identifikácie boli podrobené korelačnej analýze. Pre identifikáciu bola zvolená MLP sieť (Multi-Layer Perceptron Network) a LNU (Linear Neural Unit) s využitím učiaceho algoritmu Levenberg-Marquardt (LM). Program Python slúžil ako nástroj pre vytvorenie dynamických modelov, predikciu dát a grafickú interpretáciu výsledkov.

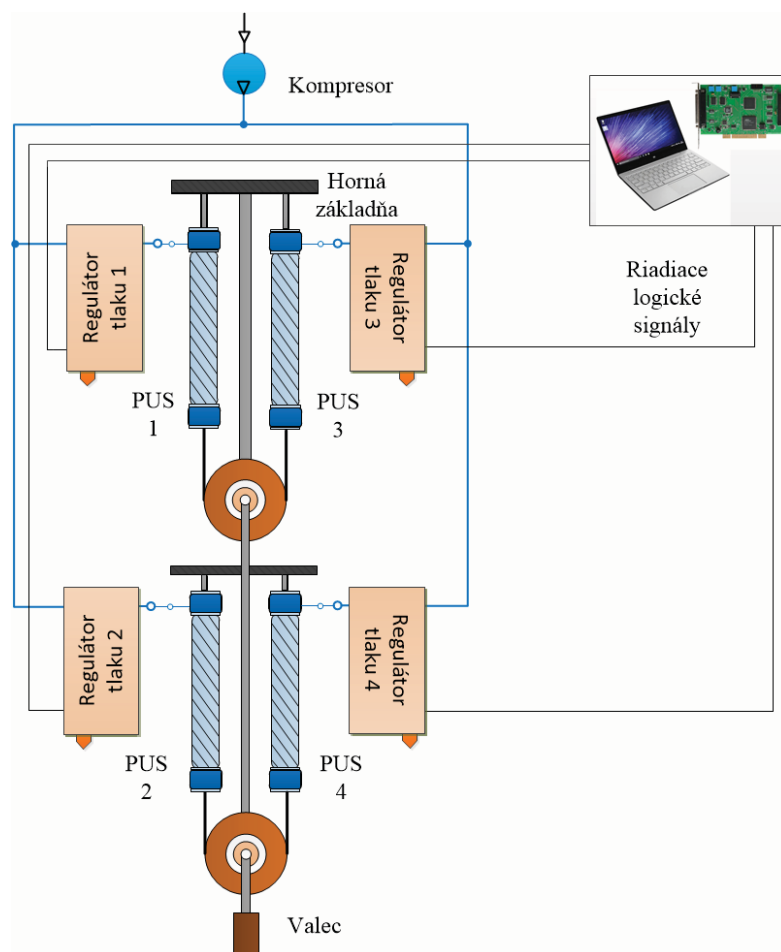
*Kľúčové slová:* identifikácia, umelý sval, MLP sieť, lineárna neurónová jednotka LNU, algoritmus učenia Levenberg-Marquardt, korelačná analýza

### 1. Úvod

V súčasnosti je automatizácia výrobného procesu bežným javom, ktorý má zabezpečiť vyššiu optimalizáciu výroby, produktivitu a v neposlednom rade konkurencieschopnosť. Manipulácia ako jedna z nevyhnutných činností podieľajúcich sa na procese výroby využíva mnohé manipulačné zariadenia, ktoré sú už v dnešnej dobe pomerne vysoko presné a taktiež výkonné. Napriek tomu sa zatiaľ nedokážu vyrovnáť flexibilitu ľudskej ruky ako manipulačného nástroja. Skúmané rameno manipulátora poháňaného pneumatickými svalmi tak poskytuje pohľad na síce atypický spôsob využitia umelých svalov v oblasti manipulácie, no s výhľadom do budúcnosti. Cieľom vývoja v danej oblasti je dosiahnuť čo najvyššiu presnosť pri manipulácii. Problém však nastáva pri narastajúcich nárokoch na riadenie, kde je potrebné čoraz viac riešiť problematiku prítomnosti nežiaducich javov. Pre vyššiu kvalitu riadenia je nevyhnutná správna identifikácia systému. [1],[2]

## 2. Popis systému ramena manipulátora s pneumatickými umelými svalmi

Systém, ktorý bol skúmaný je planárne robotické rameno poháňané pneumatickými umelými svalmi. Princiálna schéma zapojenia systému pre daný experiment je zobrazená na Obr. 1. Rameno manipulátora je uchytené o hornú základňu a disponuje dvoma rotačnými kĺbmi, ktoré mu tak poskytujú dva stupne voľnosti. Pohon rotačných kĺbov je zabezpečený pomocou pneumatických umelých svalov (PUS) od výrobcu FESTO typu MAS-20 – jednému kĺbu prislúcha pár svalov. Do svalov bolo kompresorom privádzané médium – stlačený vzduch, ktorý bol regulovaný pomocou elektronického regulátora tlaku (ERT) MATRIX EPR50. Každý sval mal vlastný regulátor tlaku, ktorého úlohou bolo zabezpečiť presné nastavenie tlaku vo svale. Tlak vo svaloch bol meraný pomocou snímača tlaku zabudovaného v regulátore tlaku. Prenos krútiaceho momentu, ktorý vyvíjajú PUS bol zabezpečený pomocou mechanizmu reťaz – reťazové koleso. Celý systém pozostáva z dvoch ramien, pričom na spodnom ramene manipulátora je uchytený valec, ktorý predstavuje záťaž s určitou hmotnosťou a momentom zotrvačnosti. Práve uhol natočenia kĺbu, ku ktorému je valec pripojený je sledovanou veličinou. Na meranie uhla kĺbu bol použitý typ snímača Kubler 3610 (inkrementálny snímač), ktorého rozlíšenie je 2500 impulzov/otáčku. Signály boli spracovávané pomocou I/O PCI karty Humusoft MF624 a rameno bolo riadené pomocou programu Matlab/Simulink.




Obr. 1 Princiálna schéma ramena manipulátora poháňaného pneumatickými umelými svalmi

## 2.1. Trénovacie a testovacie dáta


Dáta použité pre trénováciu a testováciu časť jednotlivých neurónových modelov boli získané meraním. Vstupnou meranou veličinou bol rozdiel tlakov vo svaloch  $\Delta p$  priamo závislý od zmeny vstupného napätia. Výstupnou veličinou bol uhol natočenia kĺbu  $\theta$ . Dáta získané z merania sa týkali len jednej z osí manipulátora, nakoľko pri uvažovaní oboch osí by došlo k skresľovaniu informácií v dôsledku pôsobenia dynamických väzieb. V rámci celého merania bolo získaných 16 667 vzoriek so vzorkovacou periódou 3 ms, ktoré boli čiastočne upravené.

Časový priebeh rozdielu tlakov trénovacích dát (pozri Obr. 2) má klesajúcu tendenciu v dôsledku použitia trojuholníkového budiaceho signálu s lineárne klesajúcou amplitúdou. Svaly boli spočiatku natlakované na hodnotu rozdielu tlakov približne 300 kPa a následne bol jeden zo svalov napúšťaný a druhý vypúšťaný.



Obr. 2 Časová závislosť rozdielu tlakov dát použitých pre učiacu fázu

Dáta, ktoré boli použité pre testovanie boli generované pri náhodnej amplitúde budiaceho signálu. Krivka časového priebehu rozdielu tlakov (Obr. 3) má preto náhodne vyvíjajúci sa charakter.




Obr. 3 Časová závislosť rozdielu tlakov dát použitých pre testováciu fázu

## 2.2. Korelačná analýza nameraných dát

Korelačná analýza ako metóda využívaná na vyjadrenie štatistickej závislosti medzi kvantitatívnymi premennými bola použitá pre zanalyzovanie nameraných dát určených pre učiacu fázu. Pomocou analýzy malo byť overené, či prvotne zvolené prevzorkovanie tréningových dát (frekvencia vzorkovania rovná 20) bolo zvolené vhodne. Pre výpočet korelačného koeficientu  $r$  bola použitá nasledujúca rovnica 1, ktorá bola doplnená o *lag*. Lag vyjadruje odhad časového posunu medzi  $x$  a  $y$ . Hodnoty  $x$  predstavovali vstupné namerané dáta (rozdiel tlakov  $\Delta p$ ) a hodnoty  $y$  výstupné dáta (uhol natočenia kĺbu  $\theta$ ). [3]

$$r(x, y, \text{lag}) = \frac{1}{N} \sum_k \frac{(x_{k-\text{lag}} - \bar{x})(y_k - \bar{y})}{\sigma_x \sigma_y} \quad (1)$$

Na Obr. 4 možno vidieť priebeh korelačného koeficientu (čierna krivka) neprevzorkovaných tréningových dát (zelená a modrá krivka). Z analýzy vyplýva, že v rozsahu časového posunu 20-40 jednotiek vzniká takmer čistá lineárna závislosť výstupných dát  $yr$  (resp.  $y$ ) od vstupných dát  $u$  (resp.  $x$ ), keďže hodnota korelačného koeficientu sa pohybuje v okolí hodnoty jeden. Pôvodné prevzorkovanie tak nebolo pre predikciu zvolené vhodne. Na základe zisteného bolo vhodnejšie pracovať s neprevzorkovanými dátami. Podľa analýzy by pre ďalší výskum vyhovovalo i prevzorkovanie s časovým posunom väčším ako 40, no pre učenie a testovanie by menší počet dát spôsoboval nepresnosť v učení a horšie výsledky pri testovaní.



Obr. 4 Korelačný koeficient neprevzorkovaných dát

## 3. Použité modely a algoritmy učenia pre experimentálnu časť

Pre identifikáciu ramena manipulátora boli použité dva modely neurónových sietí. Jedným z nich je lineárna neurónová jednotka, ktorý spadá pod koncepciu nekonvenčných neurónových jednotiek HONU. [4] Druhým zvoleným modelom je MLP sieť s jednou skrytou vrstvou. Ako algoritmus, ktorý mal byť implementovaný v učiacej fáze bol zvolený Levenberg-Marquardt. Základné matematické princípy, ktoré boli predpokladom pre zostavenie modelov sú uvedené v nasledujúcich častiach.

### 3.1. Levenberg-Marquardt

Levenberg-Marquardt je učiacim algoritmom, ktorý je obdobou Newtonovej metódy. Aplikáciou daného algoritmu dochádza k minimalizácii funkcie a výsledkom je číselné riešenie. Váhy neurónu, ktoré vyjadrujú jeho citlivosť sú aktualizované súčasne. Podstata metódy spočíva v stanovení Jacobianu  $J$ , ktorý sa určí na základe rovnice 2. Po výpočte Jacobianu  $J$  dôjde k výpočtu zmeny váh  $\Delta w$  (rovnica 3) a váhy sa následne aktualizujú. [4]

$$J = \begin{bmatrix} \frac{\partial f_n(k=0)}{\partial w_0} & \dots & \frac{\partial f_n(k=0)}{\partial w_n} \\ \dots & \dots & \dots \\ \frac{\partial f_n(k=N)}{\partial w_0} & \dots & \frac{\partial f_n(k=N)}{\partial w_n} \end{bmatrix} \quad (2)$$

$$\Delta w^T = \left( J^T \cdot J + \frac{1}{\mu} \cdot L \right)^{-1} \cdot J^T \cdot e \quad (3)$$

### 3.2. HONU-LNU

Lineárna neurónová jednotka predstavuje taký model neurónu  $y_n$ , ktorého snahou je identifikovať lineárnu závislosť medzi vstupnými dátami  $u_i$  a výstupnými reálnymi dátami  $y_r$ . Rovnice 4 a 5 vyjadrujú matematickú formuláciu hľadaného neurónového modelu, kde  $w$  je vektor váh,  $w_i$  sú jednotlivé neurónové váhy,  $u$  je vstupný vektor neurónu,  $u_i$  sú jednotlivé vstupy a  $k$  predstavuje index času. Mieru, v akej nájdený model interpretuje reálne výstupné dáta vyjadruje chyba neurónu  $e$ , ktorá je daná rozdielom medzi reálnymi výstupnými hodnotami a nájdenými hodnotami modelu (rovnica 6). [4],[5]

$$y_n(k) = \sum_{i=0}^n w_i \cdot u_i(k) = w \cdot u(k) \quad (4)$$

$$y_n(k) = [w_0 w_1 \dots w_n] \cdot \begin{bmatrix} u_0 \\ \vdots \\ u_n(k) \end{bmatrix} = w_0 \cdot u_0(k) + w_1 \cdot u_1(k) + \dots + w_n \cdot u_n(k) \quad (5)$$

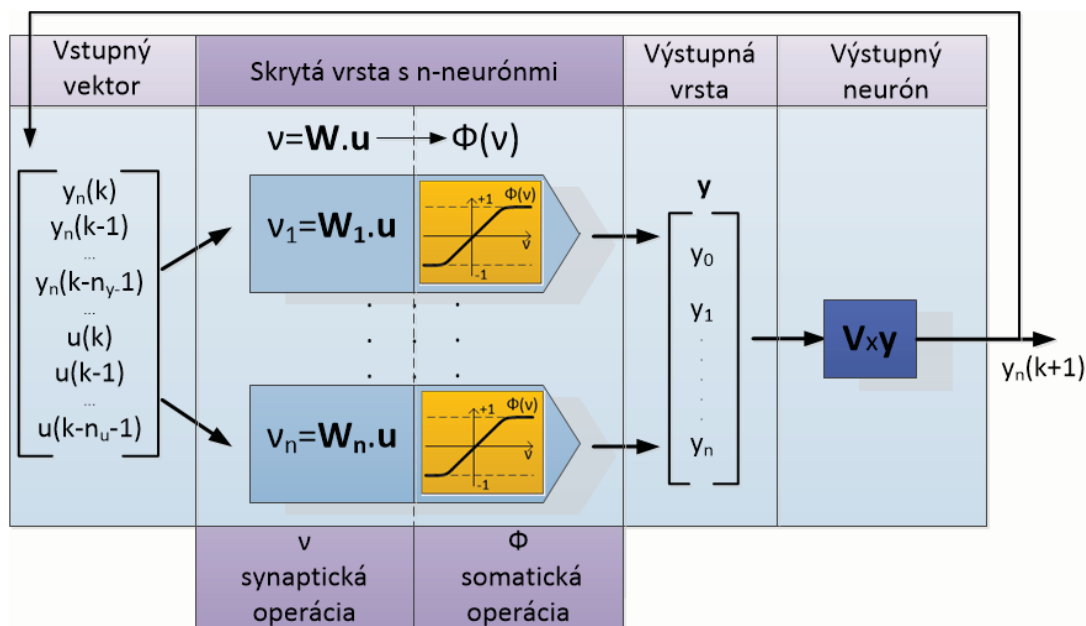
$$e(k) = y_r(k) - y_n(k) \quad (6)$$

### 3.3. MLP

Viacvrstvomá perceptrónová sieť je veľmi známou doprednou architektúrou neurónovej siete. Základným stavebným kameňom tohto druhu siete je neurón nazývaný perceptrón. Na Obr. 5 je znázornená schéma dynamickej MLP siete s jednou skrytou vrstvou. Sieť obsahuje vstupné dáta dvojakého druhu. Prvými sú dáta  $u$ , ktoré môžu byť získané napr. nameraním reálnych dát. Druhým typom sú dáta  $y_n$ . Ide o dáta, ktoré sú výstupom modelu z predchádzajúcich epoch (ide o výstup v čase  $k-1$  až  $k-n_y-1$ ). Na skrytej vrstve sú umiestnené perceptróny, ktorých počet sa pohybuje v intervale  $\langle 1; n \rangle$ . Každý perceptrón má svoj vektor váh  $W$ , ktorý vyjadruje citlivosť konkrétneho neurónu. Na skrytej vrstve dochádza k dvom operáciám, a to synaptickéj  $v$  a somatickej  $\phi$ . Synaptická operácia vytvára lineárne zoskupenia vstupov, zatiaľ čo somatická operácia je daná funkčným vzťahom  $\phi(v)$ , ktorý je daný nasledujúcou rovnicou 7. [4],[5]

$$\phi = \frac{2}{1 + e^{-v}} - 1 \quad (7)$$

Výstupom somatickej operácie je aktivačná funkcia. Na výstupnej vrstve sa nachádza výstupný neurón daný vektorom výstupných dát  $y$  a váhami výstupného neurónu  $V$ . Samotný výstupný neurón je lineárnou funkciou. MLP sieť môže byť tvorená jedným neurónom, ale i spojením niekoľkých perceptrónových neurónov, ktoré sú použité paralelne a sú pripojené k neurónu na výstupnej vrstve. [5],[6]



Obr. 5 Schéma dynamickej MLP siete s jednou skrytou vrstvou

#### 4. Porovnanie výsledkov z experimentálnej časti

V experimentálnej časti boli pre učenie a testovanie použité namerané neprevzorkované dáta. Každý z vybratých modelov (LNU, MLP) bol zostavovaný pomocou programu IDLEX (podprogram Python-u) a spracovaný v rámci samostatnej časti, v ktorej sa nachádza grafická interpretácia výsledkov identifikácie. Celkový obrázok je zložený zo 4 grafov, kde:

- na ľavom hornom grafe je zobrazená časová závislosť rozdielu tlakov reálnych dát, namodelovaných dát a chyby počas učenia po poslednej epoche,
- na ľavom dolnom grafe je zobrazený parameter SSE (Sum Squared Error) v závislosti od epoch počas učenia,
- na pravom hornom grafe je zobrazená časová závislosť rozdielu tlakov reálnych dát, namodelovaných dát a chyby počas testovania, pričom k testovaniu boli vždy vyberané najlepšie váhy z učenia a teda i graf je vykreslený pre najlepšie váhy,
- na ľavom dolnom grafe je zobrazený parameter SSE\_test učenia v závislosti od epoch.

Parameter SSE vyjadruje súčet kvadratických chýb medzi jednotlivými dátami a priemermi ich skupín. Pri identifikácii bolo počítané pre každú epochu minimálne SSE, pričom po vykonaní simulácie program vypísal najlepší parameter best SSE v rámci tréningu a najlepší best SSE\_test v rámci testovania. Pre parameter SSE platí, že čím sa hodnota približuje bližšie k nule, tým dochádza k menšej chybe medzi namodelovanými a reálnymi dátami. [3]

##### 4.1. Vstupné podmienky pre LNU a MLP

Dynamický model lineárneho neurónu s učiacim algoritmom Levenberg-Marquardt, ktorý bol vytvorený v pracovnom prostredí programu IDLEX mal zvolené nasledovné počiatkové podmienky:

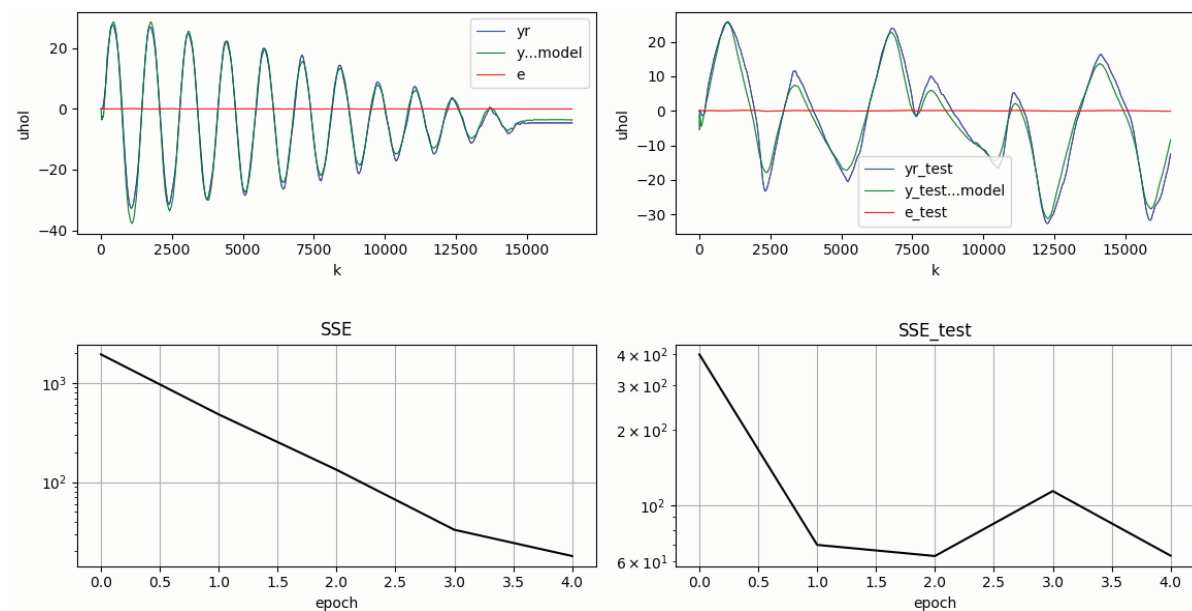
- rýchlosť učenia  $\mu$ : 0,05;
- počet epoch  $e$ : 5;
- počet vstupov  $mu$ : 10;
- počet vstupov  $ny$ : 5.

Dynamickému model viacvrstvovej perceptrónovej siete s jednou skrytou vrstvou a jedným neurónom na skrytej vrstve boli určené nasledujúce počiatkové podmienky:

- rýchlosť učenia  $\mu$ : 0,005;
- počet epoch  $e$ : 10;
- počet vstupov  $mu$ : 10;
- počet vstupov  $ny$ : 5;
- počet neurónov skrytej vrstvy  $nl$ : 1.

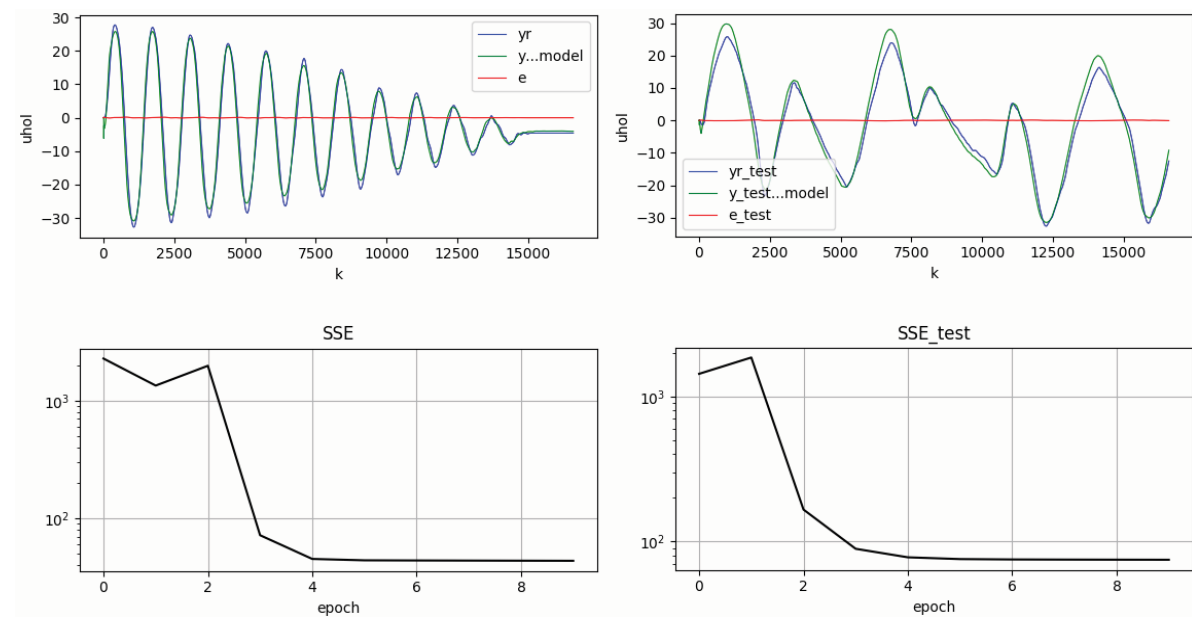
## 4.2. Výstupné modely LNU a MLP

Na Obr. 6 sa nachádza grafická interpretácia modelu LNU. Podľa parametra SSE pre testovaciu fázu a učiacu fázu možno skonštatovať, že zatiaľ čo parameter SSE má stabilný konvergujúci priebeh, pri parametri SSE\_test došlo v testovacej fáze k miernemu narušeniu priebehu.



Obr. 6 Učiacia a testovacia fáza LNU s učiacim algoritmom Levenberg-Marquardt

Na Obr. 7 je zobrazený výstupný model MLP siete. Podľa parametra SSE pre testovaciu fázu a učiacu fázu možno skonštatovať, že oba parametre majú podobný stabilný a konvergujúci priebeh.



Obr. 7 Učiacia a testovacia fáza MLP siete



### 4.3. LNU vs MLP

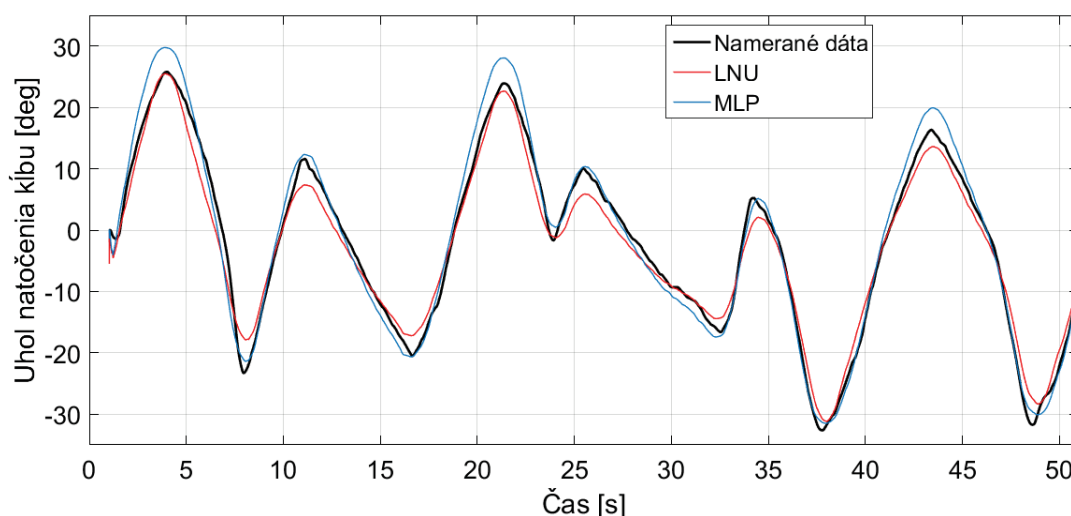
Výstupom experimentálnej časti sú jednotlivé modely, ktorých efektívnosť bola sledovaná pomocou parametra fit (Tab. 1). Tento parameter bol počítaný v programe Matlab pomocou nasledujúceho príkazu: `fit = goodnessOfFit(y, yr, 'NRMSE')`. Daným príkazom sa určí štatistický parameter NRMSE (Normalized Root Mean Square Error), ktorý vyjadruje mieru rozdielu medzi predpokladaným modelom a skutočnosťou. Údaj má percentuálny charakter, kde najideálnejší model by dosiahol hodnotu parametra rovnú 100%. [3]

Na základe parametra fit je lepším modelom lineárna neurónová jednotka. Model aj pri simulácií vykazoval pomerne vysokú stabilitu a konvergenciu parametra SSE, hoci pri testovaní bol mierne nestabilný. Druhým v poradí bola dynamická MLP sieť s jednou skrytou vrstvou a s jedným neurónom (fit 80,87 %). Pri tejto sieti je potrebné podotknúť, že boli vykonané simulácie vo vyššom počte v porovnaní s modelom LNU, keďže sieť je pri tréňovaní nestabilnejšia. Avšak v prípade, že sa sieť naučila dobre, tak hodnoty SSE konvergovali. Táto sieť môže byť výhodnejšou alternatívou aj pre komplikovanejšie dáta.

Tab. 1 Porovnanie vstupných podmienok a parametra fit pre skúmané modely

Parametre	MLP	LNU_LM
learning rate $\mu$	0,005	0,05
počet epoch $e$	10	5
počet vstupov $n_u$	10	10
počet vstupov $n_y$	5	5
počet neurónov na skrytej vrstve $n_1$	1	---
fit	80,87 %	81,54 %

Nakoľko LNU a MLP sú na základe fit podobné, výsledky boli porovnané vzhľadom k nameraným dátam i graficky v programe Matlab (Obr. 8). Čierna krivka prezentuje reálne namerané náhodné dáta, červená krivka LNU a modrá MLP. Oba modely neboli schopné presného naučenia sa a následného testovania, o čom svedčia i hodnoty parametra fit a graficky interpretovaná nepresnosť modelov vzhľadom k vrcholom čiernej krivky. Zo zobrazeného je možné vyjadriť, že MLP je presnejšie pri záporných vrcholoch (záporných uhloch natočenia), no pri kladných presahuje čiernu krivku, kým to u LNU sa nedá presne definovať, v ktorom smere natočenia kľbu presnejšie kopíruje vrcholy nameraných dát.



Obr. 8 Porovnanie výstupných modelov LNU a MLP voči reálne nameraným dátam

## 5. Záver

Cieľom analýzy bolo identifikovať dynamiku ramena manipulátora s PUS pomocou zvolených modelov a učiacich algoritmov neurónových sietí v programe Python. Pre predikciu nameraných dát vyhovoval ako model LNU s učiacim algoritmom Levenberg-Marguardt, tak i MLP s jednou skrytou vrstvou a s jedným neurónom, čo nasvedčuje tomu, že dáta vykazujú pomerne vysokú lineárnu závislosť. Napriek tomu by bolo vhodné v nasledujúcej štúdií:

- analyzovať korelačný koeficient pre pohyb ramena zvlášť v každom zo smerov natočenia kĺbu,
- použiť program Matlab pre zostavenie rovnakých modelov a porovnať výsledky,
- meraním získať ďalšiu sadu nezávislých dát a použiť ju pre testovanie modelov,
- vytvoriť pre systém ďalšie modely a porovnať ich efektívnosť.

## PodĎakovanie

Výskum je podporený grantom z Výskumnej grantovej agentúry v rámci Ministerstva školstva, vedy, výskumu a športu Slovenskej republiky a Slovenskej akadémie vied Číslo 1/0822/16 Výskum 3-stupňového inteligentného manipulátora založeného na pneumatických umelých svaloch a taktiež Projektom štrukturálnych fondov EÚ s ITMS kódom: 26220220103.

## Použitá literatúra

- [1] Piteľ, J. et al.: Pneumatický umelý sval – perspektívny prvok mechatroniky (1). AT&P journal. 2008, Vol.12, p. 59-60, ISSN 1336-233X.
- [2] Piteľ, J. et al.: Pneumatické umelé svaly: modelovanie, simulácia, riadenie. Košice: Technická univerzita v Košiciach, 2015, p. 275, ISBN 978-80-553-2164-6.
- [3] Rimarčík, M.: Štatistika pre prax. 2007, p. 199, ISBN 978-80-969813-1-1.
- [4] Bukovský, I.: Nonconventional Neural Architectures and their Advantages for Technical Applications. Faculty of Mechanical Engineering, Prague: Czech Technical University in Prague. 2012, ISBN:978-80-01-05122-1.
- [5] Nelles, O.: Nonlinear system identification: from classical approaches to neural networks and fuzzy models. Germany, Berlin: Springer. 2001, p. 786. ISBN 3-540-67369-5.
- [6] Kvasnička, V. et al: Introduction to the theory of neural networks, Slovakia, Bratislava: IRIS. 1997, p. 237. ISBN 9-788-088-77830-1.



**Selected article from**  
**Tento dokument byl publikován ve sborníku**

**Nové metody a postupy v oblasti přístrojové techniky,  
automatického řízení a informatiky 2017**  
**New Methods and Practices in the Instrumentation,  
Automatic Control and Informatics 2017**  
**29. 5. – 30. 5. 2017, Svatý Jan pod Skalou**

**ISBN 978-80-01-06300-2**

**Web page of the original document:**  
<http://control.fs.cvut.cz/nmp>  
<http://iat.fs.cvut.cz/nmp/2017.pdf>

**Obsah čísla/individual articles:**  
<http://iat.fs.cvut.cz/nmp/2017/>