

# UMĚLÉ NEURONOVÉ SÍTĚ JAKO PROSTŘEDEK PRO MODELOVÁNÍ DYNAMICKÉHO CHOVÁNÍ HYDRAULICKO-PNEUMATICKÉ SOUSTAVY USING OF ARTIFICIAL NEURAL NETWORK FOR THE IDENTIFICATION OF DYNAMIC PROPERTIES OF HYDRAULIC-PNEUMATIC SYSTEM

Pavel Seidl<sup>1</sup>, Ivan Taufer<sup>2</sup>

---

*Anotace: Cílem uvedeného příspěvku je demonstrovat použití umělých neuronových sítí k řešení praktických úloh identifikace dynamického chování složitých nelineárních soustav. Byl zkoumán matematicko-fyzikální model hydraulicko-pneumatické soustavy za účelem vytvoření alternativy tohoto modelu, a to ve tvaru umělé neuronové sítě (UNS). Model představuje obecně nelineární vícerozměrnou soustavu se dvěma vstupy a dvěma výstupy. Přičemž vstupními veličinami jsou průtoky čerpadly a výstupními veličinami jsou výšky hladin v dolních nádržích soustavy. Vstupy i výstupy soustavy jsou reprezentovány unifikovanými napěťovými signály. Řešení úlohy spočívalo v popisu jednotlivých závislostí mezi konkrétními vstupními a výstupními veličinami pomocí UNS. K řešení úlohy byl použit Neural Network Toolbox výpočetního systému MATLAB/SIMULINK.*

*Klíčová slova: Dynamický systém, umělá neuronová síť*

*Summary: The aim of the paper is to demonstrate using of artificial neural networks for the solution of practical problems of the identification of the complex non-linear systems' dynamic behavior. The mathematical model of the hydraulic-pneumatic system was investigated in order to build an alternative of this model, namely in the form of the artificial neural network (ANN). The model presents generally non-linear multi-dimensional system with two inputs and two outputs. Input variables are flows through controlled pumps and output variables are water levels in the bottom tanks of the system. Both inputs and outputs of the system are represented as unified voltage signals. Solution of the problem consisted in the description of selected single dependences between particular input and output variables by means of ANN. For the problem solution Neural Network Toolbox was used a toolbox of the computing system MATLAB/SIMULINK.*

*Key words: dynamic system, artificial neural network*

---

<sup>1</sup> Ing. Pavel Seidl, Univerzita Pardubice, Fakulta elektrotechniky a informatiky, Studentská 95, 532 10 Pardubice, tel.: +420 495 580 038, fax +420 495 585 077, e-mail: [seidl.p@email.cz](mailto:seidl.p@email.cz)


<sup>2</sup> Prof. Ing. Ivan Taufer, DrSc., Univerzita Pardubice, Fakulta elektrotechniky a informatiky, Studentská 95, 532 10 Pardubice, tel.: +420 466 037 123, fax +420 466 037 068, e-mail: [ivan.taufer@upce.cz](mailto:ivan.taufer@upce.cz)

## 1 ÚVOD

Umělé neuronové sítě (UNS) jsou podskupinou relativně nového vědního oboru – umělé inteligence. Jejich podstata spočívá v modelování struktury a činnosti biologických neuronových systémů a jejich aplikací na řešení technických problémů. Jejich použití má opodstatnění v případech, kdy při řešení daného problému buď není možné matematicky popsat všechny vztahy a souvislosti, které ovlivňují sledovaný proces, nebo se nám podaří sice exaktní matematický model sestavit, ale je tak složitý, že jeho případná algoritmizace řešení je buď časově a programově velmi náročná nebo dokonce nemožná. V příspěvku použití UNS demonstrováno na modelování hydraulicko-pneumatické soustavy.

## 2 POPIS HYDRAULICKO-PNEUMATICKÉ SOUSTAVY


Hydraulicko-pneumatická soustava (HPS) [1], [2] představuje soustavu tvořenou kombinací hydraulických a pneumatických prvků, obr. 1. Základní část soustavy tvoří čtyři hydraulické nádrže, přičemž vždy dvě jsou umístěny nad sebou ve dvou rovnoběžných sekcích. Přičemž výška všech nádob je shodná, průřezy levých a pravých nádrží jsou různé (průřez levých nádob je větší než pravých). Pneumatické objemy nad hladinami nádrží jsou uzavřeny a odděleny od atmosféry a vždy v sousedních dvou nádrží propojeny. Navíc pro zvýšení kapacity pneumatických objemů jsou ještě tyto objemy spojeny přes ručně ovládané ventily s přídatnými vzdušníky. Ve dnech vzdušníků jsou clonky, které slouží jako omezené propojení s atmosférou. Další částí soustavy je zásobní nádrž vody. Z této zásobní nádrže je kapalina pomocí čerpadel čerpána do horních nádrží. Následně kapalina vlivem vlastní tíhy a vlivem tlakového gradientu odtéká malým otvorem ve dně nádrže nejprve do spodních nádrží a následně zpět do zásobní nádrže. Nastavením různých kombinací poloh ventilů a velikostí clonek lze dosáhnout různého chování soustavy. Výstupní (regulovanou) veličinu soustavy představují výšky hladiny v dolních nádržích, které jsou měřeny elektrickými diferenčními tlakovými čidly. Výstupy z těchto tlakových čidel  $y_1$  a  $y_2$  jsou napěťové signály v rozsahu 0 až 10V. K regulaci průtoku čerpadly dochází změnou napájecího napětí čerpadel. Tato změna napětí představuje zároveň vstupní veličiny soustavy  $u_1$  a  $u_2$ . Uvedená soustava je propojena s PC pomocí akviziční karty.



Obr. 1 – Hydraulicko-pneumatická soustava

## 3 CÍL ŘEŠENÍ

Uvedený systém představuje z hlediska modelování vícerozměrnou (dva vstupy a dva výstupy) soustavu, kterou můžeme zobrazit blokovým schématem, které je uvedeno na obr. 2.



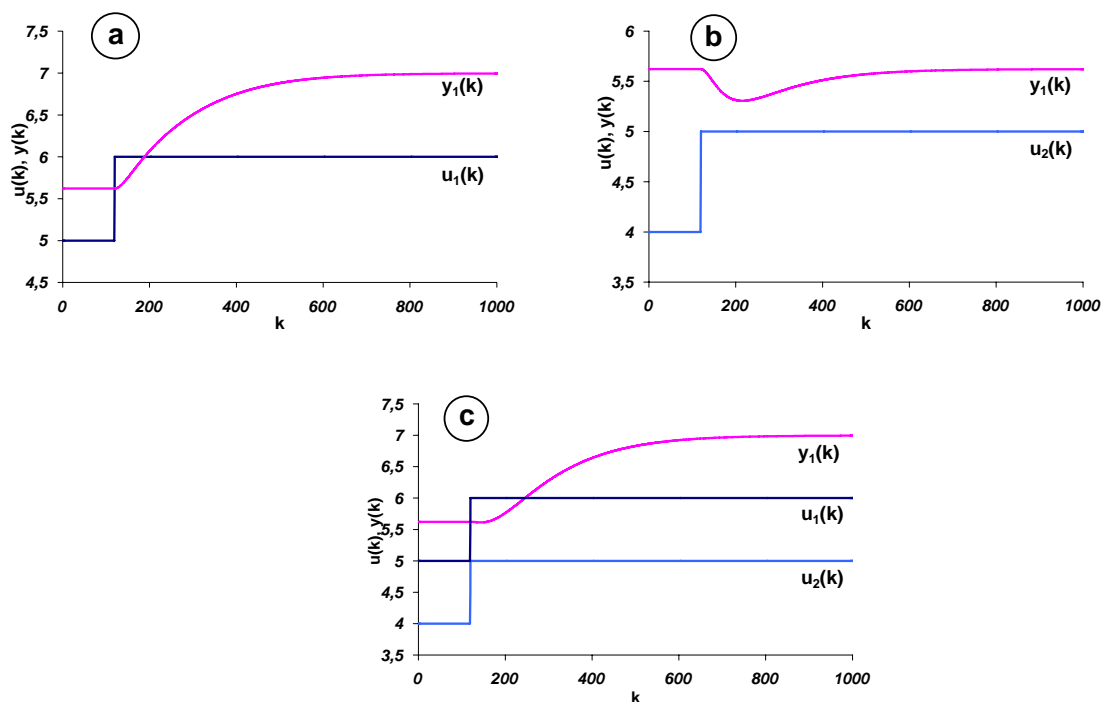
$u_1$  ..... průtok levým dávkovacím čerpadlem  
 $u_2$  ..... průtok pravým dávkovacím čerpadlem  
 $y_1$  ..... výška hladiny v levé nádrži  
 $y_2$  ..... výška hladiny v pravé nádrži

Obr. 2 – Blokové schéma HPS

Cílem řešení uvedené úlohy je sestavit dynamické modely vybraných závislostí (podle obr. 2) mezi vstupními a výstupními veličinami ve tvaru UNS – tzn. určit neznámé funkční závislosti  $f$ .

Byly modelovány tyto závislosti:  
 $y_1 = f(u_1)$ ,  $y_1 = f(u_2)$ ,  $y_1 = f(u_1, u_2)$ .  
 Přechodové charakteristiky uvedených závislostí jakožto odezvy výstupních veličin na skokovou změnu veličin vstupních jsou uvedeny na obr. 3.

Z tvaru, resp. průběhu uvedených přechodových charakteristik lze přibližně stanovit řád dynamického chování konkrétní dílčí závislosti [3] – (tab. 1).



Obr. 3 – Vybrané dílčí přechodové charakteristiky HPS

- a)  $y_1 = f(u_1)$
- b)  $y_1 = f(u_2)$
- c)  $y_1 = f(u_1, u_2)$

Tab. 1 – Řád dílčí závislosti HPS určený na základě analýzy konkrétní přechodové charakteristiky

Dílčí závislost	Řád soustavy
$y_1 = f(u_1)$	1.
$y_1 = f(u_2)$	2.
$y_1 = f(u_1, u_2)$	2.

## 4 ŘEŠENÍ ÚLOHY

Uvedená úloha byla kompletně řešena s využitím programového produktu Neural Network Toolbox ve výpočetním systému MATLAB/SIMULINK [4], přičemž cílem bylo navrhnout takové modely výše vybraných vstupně-výstupních závislostí soustavy ve formě UNS, aby měly stejné vstupně-výstupní vlastnosti jako výchozí soustava, resp. její matematický model, který byl sestaven pomocí klasické matematicko-fyzikální analýzy.

### 4.1 Popis dynamického chování soustavy ve tvaru UNS

Použití umělé neuronové sítě jako prostředku pro modelování dynamických vlastností vychází z předpokladu, že model lze popsat v diskrétním tvaru pomocí nelineární diferenční rovnice [6]. To podmiňuje, resp. předurčuje sestavení struktury neuronové sítě, trénovací a testovací množiny. K učení takové UNS lze využít známý BPG algoritmus učení, případně některou jeho.

Pro případ jednorozměrné (SISO – singl input, singl output - jeden vstup a jeden výstup) diskrétní soustavy (obr. 4), můžeme její dynamické chování vyjádřit diferenčním vztahem



Obr. 4 – Schéma SISO soustavy

$$y_S(k+1) = f[y_S(k), \dots, y_S(k-n+1), u(k), \dots, u(k-m+1)] \quad m \leq n \quad (1)$$

kde  $y_S$  – pořadnice odezvy na výstupu soustavy  
 $u$  – pořadnice vstupního signálu  
 $k$  – diskrétní pořadnice času  
 $n$  – řád diferenčního vztahu  
 $f$  – symbol závislosti mezi vstupem a výstupem soustavy.

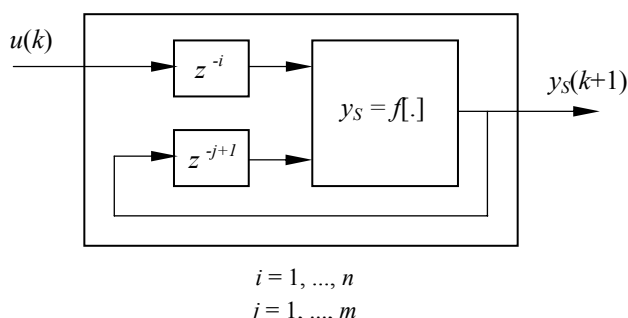
Model ve tvaru dopředné neuronové sítě (DNS), jak bylo na příkladu dvouvrstvé DNS uvedeno v [7], je dán matematickým vyjádřením tj. rovnicemi vstupních potenciálů a rovnicemi aktivačních funkcí jednotlivých neuronů. Dále budeme hovořit o nelineárním modelu ve tvaru umělé neuronové sítě, který lze vzhledem k vztahu (1) vyjádřit ve tvaru

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

kde  $\hat{f}$  je aproximace funkce  $f$  rovnice (1)

$y_M$  – výstupní hodnoty z neuronového modelu.

Vnitřní struktura modelu takovéto soustavy je pak na obr. 5,




Obr. 5 – Schéma struktury diskrétní soustavy

kde bloky  $z^{-i}$ , resp.  $z^{-j+1}$  představují posun příslušných pořadnic proměnných  $y_S$  a  $u$  o  $i$  nebo  $j$  intervalů vzorkování vlevo.

#### 4.2 Volba topologie a základních parametrů umělé neuronové sítě

Volba topologie UNS je klíčovou etapou celého procesu identifikace. V této fázi je třeba na základě dostupných informací o soustavě stanovit strukturu vstupních a výstupních proměnných navrhovaného modelu. Konkrétní počty vstupních terminálů a výstupních neuronů uvažované DNS je dán jednak počtem skutečných vstupních, resp. výstupních fyzikálních veličin soustavy a dále pak řádem diferencčního vztahu (2) (pravá strana této rovnice představuje vstupy a levá strana rovnice výstup UNS). Následně se pak navrhne struktura vlastní sítě, počet skrytých vrstev a počet neuronů v těchto vrstvách. I když výstavba UNS předurčuje úspěšnost celé identifikace, není žel k dispozici žádné jednotné pravidlo jak UNS jednoznačně sestavit. Řada doporučení uváděna v literatuře a shrnuta v [6] mají spíše orientační charakter.

Za základní topologii umělé neuronové sítě byla pro řešení dané úlohy vybrána



Obr. 6 – Dvouvrstvá dopředná neuronová síť

topologie dvouvrstvé dopřední sítě s vrstvou vstupních terminálů (zdrojových uzlů), s jednou vrstvou skrytých neuronů a s jedním výstupním neuronem (obr. 6). Aktivační funkce neuronů ve skryté vrstvě byly zvoleny ve tvaru bipolární sigmoidy (hyperbolický tangens) s konstantními strmostmi rovnými 1, aktivační funkce výstupního neuronu byla zvolena lineární, rovněž s jednotkovou a konstantní strmostí.

Aplikací výše popsané teorie a s využitím závěrů uvedených tab.1 přechází obecný diferencní vztah (2) pro jednotlivé závislosti do následujících podob:

a) pro  $y_1 = f(u_1)$

$$y_{1M}(k+1) = \hat{f}[y_{1M}(k), u_1(k)] \quad (3)$$

b) pro  $y_1 = f(u_2)$

$$y_{1M}(k+1) = \hat{f}[y_{1M}(k), y_{1M}(k-1), u_1(k), u_1(k-1)] \quad (4)$$

c) pro  $y_1 = f(u_1, u_2)$

$$y_{1M}(k+1) = \hat{f}[y_{1M}(k), y_{1M}(k-1), u_1(k), u_1(k-1), u_2(k), u_2(k-1)] \quad (5)$$

Na základě rovnic (3), (4) a (5) lze tedy stanovit počty vstupních terminálů jednotlivých závislostí následovně – 2 pro závislost a), 4 pro závislost b) a 6 pro závislost c).

Co se týče počtů neuronů ve skryté vrstvě, tak simulačními výpočty byly provedeny a tabulkově vyhodnoceny pro různé jejich počty. Nicméně pro následný proces validace UNS, včetně grafické prezentace jejích výsledků, byly použity UNS s doporučeným minimálním počtem neuronů ve skryté vrstvě, který je dán vztahem podle [5]

$$p \geq n + m \quad (6)$$

kde  $n$  – počet vstupních terminálů  
 $m$  – počet výstupních neuronů.

#### 4.3.1 Sestavení trénovací množiny

Trénovací množina se v daném případě získala měřením časového průběhu odezvy soustavy na zadaný vstupní signál. Konkrétní trénovací signál představoval náhodný signál s rovnoměrným rozdělením pravděpodobností, který byl přiváděn na vstup soustavy s intervalem vzorkování 30s. Délka simulace byla volena tak, aby po skončení vlastní simulace bylo k dispozici 700 vzorů trénovací množiny. Tímto experimentem byla získána struktura dat, která je uvedena v tab. 2.

Tab. 2 – Struktura dat získaných experimentem

$k$	$u(k)$	$y_S(k)$
0	$u(0)$	$y_S(0)$
1	$u(1)$	$y_S(1)$
...	...	...
698	$u(698)$	$y_S(698)$
699	$u(699)$	$y_S(699)$

Připomeňme si nyní, že úkolem identifikace je najít takové parametry neuronové sítě (váhy spojení, případně strmosti aktivačních funkcí), aby došlo k maximální shodě vlastností DNS a identifikované soustavy, tj aby platilo  $y_M \approx y_S$ . Zmíněné shody lze dosáhnout tehdy, bude-li neuronová síť v průběhu trénování buzena stejnými signály jako identifikovaná soustava..

Tab. 3 pak představuje jako příklad konkrétní tvar trénovací množiny pro závislost pro  $y_1 = f(u_2)$ , která je dána vztahem (4). Trénovací množiny ostatních zkoumaných závislostí se získají analogicky.

Tab. 3 – Trénovací množina závislosti  $y_1 = f(u_2)$

$k$	Vstupní vzory				Výstupní vzory
	$u(k-1)$	$u(k)$	$y_S(k-1)$	$y_S(k)$	$y_S(k+1)$
0	$u(-1)$	$u(0)$	$y_S(-1)$	$y_S(0)$	$y_S(1)$
1	$u(0)$	$u(1)$	$y_S(0)$	$y_S(1)$	$y_S(2)$
...	...	...	...	...	...
697	$u(696)$	$u(697)$	$y_S(696)$	$y_S(697)$	$y_S(698)$
698	$u(697)$	$u(698)$	$y_S(697)$	$y_S(698)$	$y_S(699)$

### 4.3.2 Proces trénování (učení) DNS

Proces učení probíhá tak, že se vstupní vzory opakovaně v jednotlivých epochách přikládají na vstup neuronové sítě a výstupní vzory se porovnávají s výstupem z neuronové sítě. Cílem učení je pak postupnou změnou vah spojení mezi jednotlivými neurony, případně strmostí aktivačních funkcí, docílit po určitém počtu epoch trénování, minimálního rozdílu mezi výstupem ze soustavy  $y_S(k)$  a výstupem z neuronové sítě  $y_M(k)$ . Tento rozdíl je vyjádřen známou kriteriální funkcí (někdy také nazývaná chyba řešení) [5] ve tvaru

$$E_{tr}(p_e) = \frac{1}{\nu} \sum_{k=0}^{N-1} [e(p_e, k+1)]^2 = \frac{1}{\nu} \sum_{k=0}^{N-1} [y_S(k+1) - y_M(p_e, k+1)]^2 \quad (7)$$

kde  $p_e$  – pořadové číslo epochy trénování  
 $N$  – počet vzorů trénovací množiny  
 $k$  – pořadové číslo vzoru trénovací množiny  
 $\nu = N - pp - 1$  – počet stupňů volnosti  
 $pp$  – celkový počet určovaných parametrů  $\gamma$  (vah spojení a případně i strmostí aktivačních funkcí), který vychází ze zvolené topologie. (8)

Pro trénování neuronové sítě byl použit modifikovaný BPG algoritmus tzv. Levenbergův-Marquardtův algoritmus[4], [8]. Uvedený algoritmus je vyjádřen následujícím vztahem

$$w_{k+1} = w_k - [\mathbf{J}^T \mathbf{J} + \mu \mathbf{I}]^{-1} \mathbf{J}^T \mathbf{e} \quad (9)$$

kde  $w_k$  je množina všech vah v  $k$ -té epoše trénování;  
 $\mathbf{J}$  – Jakobián derivací chyb v závislosti na vahách;  
 $\mu$  – definovaná skalární hodnota;  
 $\mathbf{e}$  – chybový vektor.

### 4.3.3 Výsledky trénování (učení) DNS

Výsledky procesu učení, vyjádřené hodnotou chyby  $E_{tr}$  (viz. rovnice (7)) na konci procesu trénování v závislosti na různém počtu neuronů ve skryté vrstvě, jsou souhrnně uvedeny v tab. 4. Přičemž veškeré uvedené experimenty byly provedeny pro 1000 trénovacích epoch [5].

Tab. 4 – Výsledky učení UNS – hodnota chyby  $E_{tr}(1000)$

Topologie UNS	Typ závislosti a) $y_1 = f(u_1)$	Topologie UNS	Typ závislosti b) $y_1 = f(u_2)$	Topologie UNS	Typ závislosti c) $y_1 = f(u_1, u_2)$
2-2-1	$6,026 \cdot 10^{-4}$	4-3-1	$1,826 \cdot 10^{-4}$	6-6-1	$4,433 \cdot 10^{-4}$
2-3-1	$5,981 \cdot 10^{-4}$	4-4-1	$1,698 \cdot 10^{-4}$	6-7-1	$4,257 \cdot 10^{-4}$
2-4-1	$5,953 \cdot 10^{-4}$	4-5-1	$1,657 \cdot 10^{-4}$	6-8-1	$4,178 \cdot 10^{-4}$
2-5-1	$5,910 \cdot 10^{-4}$	4-6-1	$1,597 \cdot 10^{-4}$	6-9-1	$3,940 \cdot 10^{-4}$
2-6-1	$5,804 \cdot 10^{-4}$	4-7-1	$1,591 \cdot 10^{-4}$	6-10-1	$3,938 \cdot 10^{-4}$
2-20-1	$5,083 \cdot 10^{-4}$	4-20-1	$1,306 \cdot 10^{-4}$	6-20-1	$2,684 \cdot 10^{-4}$

#### 4.3.4 Proces validace DNS

Adekvátnost modelu a identifikované soustavy lze ověřit její validací pomocí testovací množiny. K validaci byly použity dva testovací signály – stejný jako trénovací tzn. náhodný signál a dále pak signál ve tvaru stupňové funkce. V tabulce (5) jsou shrnuty výsledky validačního procesu – vyjádřené hodnotou maximální, minimální a průměrné absolutní chyby, které se určovaly pomocí rovnic (10) a (11).

$$e(k) = |y_S(k) - y_M(k)| \quad (10)$$

kde  $y_S(k)$  – hodnota změřena na experimentálním zařízení – matematickém modelu  
 $y_M(k)$  – hodnota vypočítaná z umělé neuronové sítě


$$\bar{e} = \frac{1}{N} \sum_{i=1}^N e(k) \quad (11)$$

Tab. 5 – Výsledky validace UNS


Validační signál	Validační kritérium	Typ závislosti a) $y_1 = f(u_1)$	Typ závislosti b) $y_1 = f(u_2)$	Typ závislosti c) $y_1 = f(u_1, u_2)$
		Topologie UNS 2 – 4 – 1	Topologie UNS 4 – 6 – 1	Topologie UNS 6 – 8 – 1
Náhodný signál	$e_{max.}$	$6,370 \cdot 10^{-2}$	$1,207 \cdot 10^{-2}$	$6,930 \cdot 10^{-2}$
	$e_{min.}$	$7,743 \cdot 10^{-5}$	$2,326 \cdot 10^{-5}$	$4,083 \cdot 10^{-5}$
	$e_{stř.}$	$2,060 \cdot 10^{-2}$	$1,040 \cdot 10^{-2}$	$1,740 \cdot 10^{-2}$
Stupňová funkce	$e_{max.}$	$6,760 \cdot 10^{-2}$	$1,221 \cdot 10^{-2}$	$2,095 \cdot 10^{-1}$
	$e_{min.}$	$5,904 \cdot 10^{-5}$	$2,427 \cdot 10^{-4}$	$1,077 \cdot 10^{-5}$
	$e_{stř.}$	$1,840 \cdot 10^{-2}$	$3,790 \cdot 10^{-2}$	$3,980 \cdot 10^{-2}$

Grafické znázornění odezvy příslušných UNS na testovací množiny jsou uvedeny na obr. 7, 8 a 9.






Validační množina: Trénovací množina




Validační množina: Stupňová funkce

Obr. 7 – Odezva závislosti  $y_1 = f(u_1)$  na validační množinu




Validační množina: Trénovací množina




Validační množina: Stupňová funkce

Obr. 8 – Odezva závislosti  $y_1 = f(u_2)$  na validační množinu



Validační množina: Trénovací množina



Validační množina: Stupňová funkce

Obr. 9 – Odezva závislosti  $y_1 = f(u_1, u_2)$  na validační množinu

## 5 ZÁVĚR

Na základě provedených experimentů lze konstatovat, model soustavy ve tvaru umělé neuronové sítě dobře aproximuje dynamické vlastnosti složité nelineární soustavy, kterou v této práci představovala hydraulicko-pneumatická soustava, resp. její vybrané dílčí křížové závislosti.

Příspěvek také dokládá vhodnost a relativní jednoduchost identifikace dynamických vlastností uvedené soustavy s použitím umělé neuronové sítě oproti metodám identifikace klasické, které se v daném případě mohou jevit jako velmi složité a často i nespolehlivé.

*Problematika je řešena v rámci výzkumného záměru MŠM 0021627505 „Řízení, optimalizace a diagnostika složitých systémů“.*

## LITERATURA

- [1] HONC, D., DUŠEK, F. Laboratory Plant for Control Experiments. In *Proceedings 7 th International Scientific-Technical Conference Process Control 2006*, Kouty nad Desnou, Czech Republic, June 13 - 16 2006. Pardubice : University of Pardubice, 2006, pp. 219 + CD ROM. ISBN 80-7194-860-8
- [2] HONC, D., HAVLÍČEK, L., DUŠEK, F. Modelling and TITO predictive control of laboratory system. *Sci. Pap. Univ. Pardubice, Faculty of Chemical Technology*, 2007, Series A, Vol. 13, pp. 139-146. ISBN 978-80-7395-044-6
- [3] OLEHLA, M.; NĚMEČEK, S. *Základy aplikované kybernetiky*. Liberec : Technická univerzita Liberec, 2005. 128 s.
- [4] DEMUTH, H.; BEALE, M. *Neural Network Toolbox for Use with MATLAB*. Natick (USA) : MathWorks, Inc., 1994.
- [5] TAUFER, I.; DRÁBEK, O.; SEIDL, P. Umělé neuronové sítě – základy teorie a aplikace (5). *CHEMagazín*, XVI, 2006, č. 4., s. 29 – 31. ISSN 1210 – 7409.
- [6] TAUFER, I.; DRÁBEK, O.; SEIDL, P. Umělé neuronové sítě – základy teorie a aplikace (8). *CHEMagazín*, XVII, 2007, č. 4., s. 28 – 30. ISSN 1210 – 7409.
- [7] TAUFER, I.; DRÁBEK, O.; SEIDL, P. Umělé neuronové sítě – základy teorie a aplikace (6). *CHEMagazín*, XVI, 2006, č. 5., s. 6 – 8. ISSN 1210 – 7409.
- [8] TUČKOVÁ, J. *Úvod do teorie a aplikací umělých neuronových sítí*. Praha: Vydavatelství ČVUT, 2003. 103 s. ISBN 80-01-02800-3.

Recenzent: doc. Ing. František Dušek, CSc.  
Univerzita Pardubice, FEI, Katedra řízení procesů