

# Potlačenie chýb snímačov pomocou neurónových sietí

Jozef Vojtko

## Abstrakt

Článok predstavuje široké možnosti využitia umelých neurónových sietí za účelom potlačenia chýb snímačov a poukazuje na výhody a nevýhody jednotlivých typov sietí v aplikáciách meracích systémov. Pridaním takýchto prvkov umelej inteligencie už môžeme hovoriť o inteligentných meracích systémoch, ktoré sa čoraz viac uplatňujú v technickej praxi.

**Kľúčové slová:** meranie, snímače, neurónové siete, potlačenie chýb

## Úvod

Moderné priemyselné distribuované systémy využívajú stále komplexnejšiu a rozsiahlejšiu štruktúru navzájom prepojených podsystémov. Na najnižšej úrovni sa nachádzajú práve meracie systémy, ktoré zabezpečujú úlohu merania riadeného procesu. Merací systém môže obsahovať jeden alebo niekoľko snímačov. Snímač je nutné chápať ako funkčný celok zložený zo vstupnej citlivej časti označovanej ako senzor (čidlo) a z výstupnej časti označovanej ako prevodník, ktorý pretransformuje zmenu vnútorného stavu senzora na elektrickú veličinu. Snímače predstavujú najdôležitejší článok meracieho reťazca, nimi je limitovaná celková presnosť merania, takže sú na ne kladené stále vyššie nároky na presnosť. Obyčajne táto úloha je podporená progresívnymi technikami pre automatickú kalibráciu a chybovú kompenzáciu, ktorá je prevádzaná v obvodoch spracovania údajov. Tieto môžeme rozdeliť do dvoch veľkých skupín - konvenčné, alebo klasické spracovanie dát pomocou číslícových metód, a nekonvenčné spracovanie dát, využívajúce metódy umelej inteligencie

Pridaním číslícových alebo inteligentných metód spracovania dát do meracieho systému už hovoríme o inteligentnom meracom systéme, ktorý sa vyznačuje nasledujúcimi charakteristikami:

- linearizácia prevodových charakteristík
- redukcia vplyvu šumu digitálnou filtráciou a kompenzácia vonkajších vplyvov
- redukcia nameraných dát - vylúčenie hrubých chýb
- diagnostika režimu práce - hlásenie kritických limitov, detekcia poruchových stavov
- autokalibrácia
- konfiguračné schopnosti – napr. zmena medzi rozsahmi citlivosti
- uchovávanie informácií
- komunikačné schopnosti

Článok sa zameriava len na časť z uvedených charakteristík, konkrétne na vhodnosť použitia neurónových sietí za účelom potlačenia chýb vybraných typov snímačov. Pri požiadavke na zvýšenie presnosti meracieho systému má dobre navrhnutá neurónová sieť celý rad kladných vlastností, predovšetkým pomerne dobrú odolnosť voči šumu a krátku dobu odozvy natrénovanej siete. Hlavnou výhodou sa javí odstránenie nutnosti vytvorenia matematického modelu daného systému. Všeobecne má použitie neurónových sietí taktiež nevýhody, najmä nájdenie optimálnej siete, dlhé

výpočtové časy pri tréningu siete (hlavne pri zložitejších sieťach), príp. verifikácia výsledku siete.

## 1. Metódy potlačenia chýb

Proces potlačenia chýb spôsobených externými zdrojmi využíva kompenzáciu týchto účinkov redundantnou informáciou z iných informačných zdrojov. Túto redundantnú informáciu možno získať:

- z referenčnej veličiny a zhodnými dvoma typmi snímačov s lineárnou prenosovou charakteristikou známych parametrov (drift, zisk), obr. 1a
- použitím minimálne dvoch vzájomne odlišných snímačov, na ktoré súčasne pôsobí rovnako meraná a poruchová veličina, obr. 1b
- použitím minimálne takého počtu meracích vetiev, koľko je neznámych prvkov tvorených meranou a poruchovými veličinami, obr. 1c
- použitím podporného signálu generovaného pomocou generátora poruchy

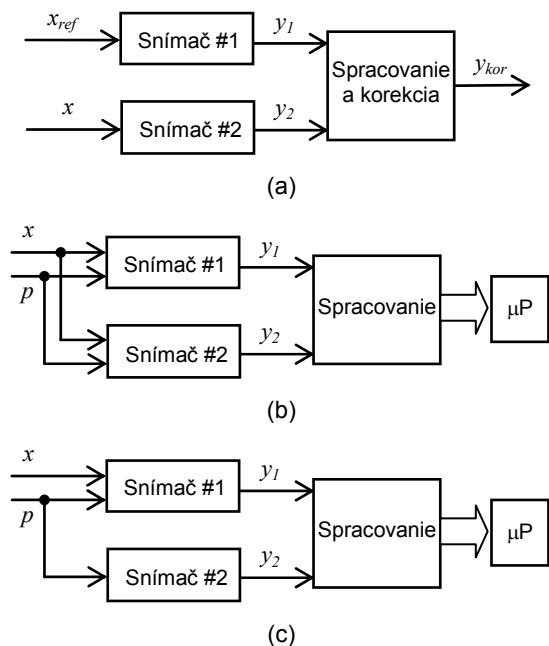
Pri prvej metóde je nutná referenčná hodnota meranej neelektrickej veličiny. K potlačeniu driftu a chyby zisku dôjde, len ak snímače budú mať identické prenosové charakteristiky. To zatiaľ súčasnými technológiami nie je možné dosiahnuť. Ďalším problémom sú chyby linearity, ktoré môžu výrazne ovplyvniť výslednú presnosť pri meraní v extrémnych podmienkach. Navyše, generovať referenčnú hodnotu meranej veličiny v praxi nie je jednoduchá úloha, preto sa táto metóda používa len na kompenzáciu driftu [2].

Druhá metóda využíva dva snímače s rozdielnymi, ale známymi prenosovými charakteristikami. Na obidva snímače pôsobí rovnako meraná a poruchová veličina. Predpokladajme, že výstupné veličiny snímačov #1 a #2 sú:

$$y_1 = f_1(x, p) \text{ a } y_2 = f_2(x, p) \quad (1)$$

kde  $f_1$  a  $f_2$  reprezentujú prenosové charakteristiky snímačov,  $x$  reprezentuje meranú a  $p$  poruchovú veličinu. Snímače musia mať rozdielne prenosové charakteristiky, navyše tieto charakteristiky musia byť známe. Ak poznáme aktuálne hodnoty výstupných veličín  $y_1$  a  $y_2$ , potom hodnotu meranej veličiny  $x$  dostaneme z riešenia sústavy dvoch nelineárnych rovníc o dvoch neznámych. Systém rovníc (1) však môže nadobudnúť vysoký stupeň zložitosti. Preto je potrebný výkonný signálový procesor. V inteligentných snímačoch sa prepočet najprv urobí na PC a pri reálnom meraní sa použi-

je vyhľadávacia tabuľka uložená v internej EEPROM. Nevýhoda spočíva vo vysokých nárokoch na kapacitu EEPROM [4].



**Obr.1 Schémy metód potlačenia chýb snímačov**  
**Fig.1 Schemes of sensor errors reduction**

Pri tretej metóde sa merajú priamo poruchové veličiny. Pomerne často je poruchovou veličinou zmena teploty. Predpokladajme dva snímače, pričom jeden je na meranie teploty. Podobne ako pri predošlej metóde, hodnota meranej veličiny sa určí z riešenia sústavy nelineárnych rovníc (2) alebo sa použije vyhľadávacia tabuľka.

$$y_1 = f_1(x, p) \text{ a } y_2 = f_2(p) \quad (2)$$

Štvrtá metóda nachádza využitie v aplikáciách, kde sa vyžaduje diaľková kontrola stavu snímača (napr. meranie teploty v aktívnej časti jadrovej elektrárne). Snímač je doplnený technickými prostriedkami na generovanie definovanej poruchy v jeho okolí. Po realizácii tejto poruchy sa sleduje priebeh výstupného signálu a podľa potreby sa upravujú prenosové konštanty meracieho kanála v číslicovej časti spracovania.

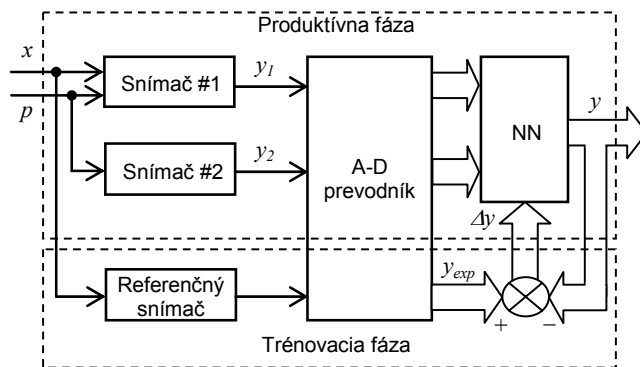
## 2. Využitie neurónových sietí

V dôsledku načrtnutých problémov s riešením systému rovníc vysokého stupňa zložitosti v druhej a tretej metóde, je výhodne zaradiť namiesto bloku  $\mu P$ , ktorý predstavuje výpočtový aparát týchto rovníc, umelú neurónovú sieť. V takomto prípade odpadá nutnosť poznania prenosových charakteristík snímačov  $f_1$  a  $f_2$ . Návrh neurónovej siete prebieha v dvoch krokoch:

- v prvom kroku je to výber vhodnej architektúry a tréning siete pomocou vhodného algoritmu. V tejto fáze sa neurónovej sieti poskytne informácia o prostredí formou tréningovej množiny dát, ktorá predstavuje štatistický model prostredia. Úspech tohto prístupu závisí od množstva tréningových dát a od toho ako presne tieto dáta reprezentujú prostredie.
- testovanie siete, vyhodnotenie reakcií siete na dáta, ktoré nemala pri učení k dispozícii (táto fáza súvisí s generalizáciou).

Všeobecný príklad využitia neurónových sietí v úlohách potlačenia chýb snímačov je znázornený na obr. 2, ktorý

korešponduje s treťou metódou spomínanou v predchádzajúcej kapitole.



**Obr.2 Potlačenie chýb snímačov neurónovou sieťou**  
**Fig.2 Sensor errors reduction by neural network**

Životný cyklus takého to systému sa skladá z tréningovej a produktívnej fázy. V tréningovej fáze sa počas učenia adaptujú voľné parametre siete (synaptické váhy) pomocou stimulácie prostredia, v ktorom sa sieť nachádza. V aplikáciách potlačenia chýb sa najčastejšie využíva učenie korigujúce chybu. Jeho cieľom je minimalizovať účelovú funkciu založenú na chybovom signáli  $\Delta y$ , aby očakávaná  $y_{exp}$  a aktuálna odpoveď  $y$  boli v istom štatistickom zmysle veľmi blízke. Jedná sa o klasický optimalizačný problém, kde kritérium pre účelovú funkciu  $J$  je založené na strednej kvadratickej chybe. Pre neurón  $k$  v čase  $n$  môžeme zdefinovať:

$$\Delta y_k(n) = y_{expk}(n) - y_k(n) \quad (3)$$

$$J = E \left[ \frac{1}{2} \sum_k \Delta y_k^2(n) \right] \quad (4)$$

kde  $E$  je operátor strednej hodnoty. V produktívnej fáze má správne naučená sieť schopnosť odpovedať na vstupy nezahrnuté v procese učenia s určitou malou chybou. Táto produktívna fáza sa vykonáva opakovane, takmer počas celého životného cyklu systému na rozdiel od tréningovej, ktorá sa prevádza len raz na začiatku pred uvedením systému do reálnej praxe. Jednou z výhod inteligentných systémov je aj schopnosť prispôbiť sa zmenenému prostrediu, čo v tomto prípade znamená opätovné spustenie tréningovej fázy s novou množinou tréningových dát.

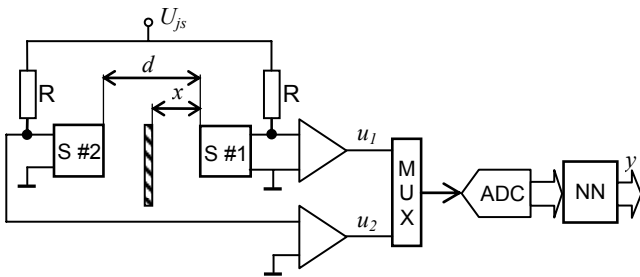
### 2.1 Snímač s premenlivým magnetickým odporom

Týmito snímačmi je možné bezkontaktné snímať priblíženie sa, resp. posunutie kovového predmetu. Toto posunutie v magnetickom poli cievky snímača vyvolá zmenu vírivých prúdov v predmete a tým aj zmenu vlastnej indukčnosti cievky, čo sa prejaví na zmene amplitúdy signálu oscilátora. Ten je konvertovaný do jednosmerného výstupného signálu pomocou demodulátora. Chyby, ktoré sa uplatňujú v takýchto meraniach sú spôsobené nerovnorodosťou materiálu kovového predmetu, nepresnosťami v geometrických rozmeroch, vplyvmi prostredia a pod., ktoré navyše pôsobia na merací systém kombinovane a ich závislosti sú nelineárne. Nech všetky tieto komplexné vplyvy reprezentujú chybové veličiny  $p_1, p_2, \dots, p_k$ . Bloková schéma zapojenia je na obr. 3, kde snímače S #1 a S #2 (Honeywell 921AB3XM) sú zapojené oproti sebe v pevnej vzdialenosti  $d$ , merajúce vzdialenosť  $x$ , resp.  $d-x$ , čo korešponduje s druhou metódou popísanou v kap.1. Výstupné napätia  $u_1$  a  $u_2$  sú potom funkciami meraných vzdialeností, materiálu vzorky  $m$  a chybových veličín:

$$u_1 = f_1(x, m, p_1, p_2, \dots, p_k) \quad (5)$$

$$u_2 = f_2(x - d, m, p_1, p_2, \dots, p_k) \quad (6)$$

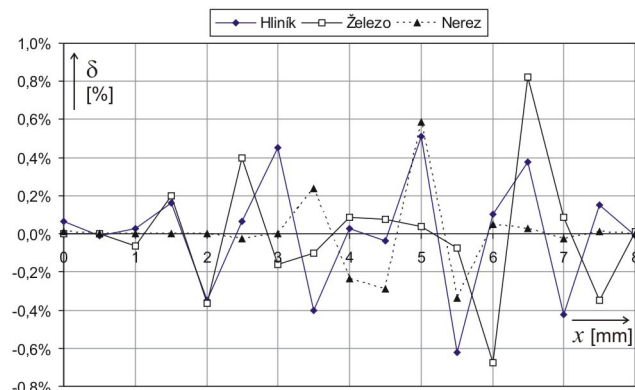
Exaktne popísať prenosové charakteristiky  $f_1$  a  $f_2$  takéhoto snímača je takmer neriešiteľná úloha. Ako najjednoduchšie a najefektívnejšie riešenie potlačenia chýb sa javí použitie dopredných neurónových sietí.



Obr.3 Schéma zapojenia snímača s premenlivým magnetickým odporom a neurónovej siete

Fig.3 Circuit diagram of the variable-reluctance transducer and neural network

Neurónová sieť bola vytvorená v prostredí MatLAB. Pre riešenie tohto problému postačuje architektúra siete s tromi vstupnými neurónmi (okrem informácií o snímaných napätiach aj informácia o materiáli vzorky), 8 skrytými neurónmi a jedným prípadne viacerými výstupmi (ak požadujeme aj informáciu o vzdialenosti  $d-x$ , príp. informáciu o materiáli vzorky). Za účelom získania presných hodnôt bol použitý referenčný mechanický kalibrátor MAHR (presnosť  $\pm 10 \mu\text{m}$ ). Potom množina tréningových dát je tvorená informáciami o vzdialenosti ( $x$ ), materiáli vzorky ( $m = 0,335$  hliník,  $0,7$  nerez a  $1,0$  pre železo) a snímaných napätiach ( $u_1, u_1+u_2$ ) [1].



Obr.4 Potlačenie chýb snímača s premenlivým magnetickým odporom pomocou neurónovej siete

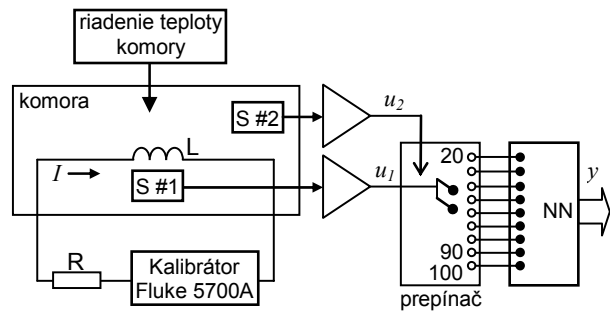
Fig.4 Errors reduction of the variable-reluctance transducer by neural network

Merací systém s vhodne naučenou neurónovou sieťou pre materiál vzorky hliník poskytuje v danom zapojení chybu presnosti  $\delta_{ma} = (-0,63\%; 0,51\%)$  oproti  $\delta_{na} = (-4,21\%; 4,29\%)$  určenej bez použitia siete (aproximácia metódou najmenších štvorcov kubickým polynómom). Podobne výsledky dosiahneme aj pre ostatné vzorky. Závislosť relatívnej chyby  $\delta$  výstupu neurónovej siete na meranej vzdialenosti  $x$  je na obr. 4.

## 2.2 Snímač intenzity magnetického poľa

Zvýšenie presnosti merania magnetických veličín pomocou snímačov s Hallovou sondou, magnetorezistívnych alebo indukčných sa dosahuje hardvérovou alebo softvérovou linearizáciou. Pri magnetorezistívnych snímačoch (KMZ10) ide zväčša o zapojenie snímacích rezistorov do Wheatstoneovho mostíka, ktorého zmena výstupného napätia od-


vedá zmene intenzity magnetického poľa. Teplotná závislosť takýchto snímačov sa pohybuje až do  $25\%$  v rozsahu teplôt  $20^\circ\text{C}$  až  $100^\circ\text{C}$  [5]. Kvôli eliminácii teplotnej závislosti môžeme využiť tretiu metódu popísanú v kap. 1. To znamená, že do meracieho systému pridáme snímač teploty S #2, ktorého výstupná informácia posluží na opravu chyby teplotného driftu snímača S #1, nachádzajúceho sa v mag. poli cievky L, obr. 5.



Obr.5 Schéma zapojenia snímača intenzity magnetického poľa a neurónovej siete

Fig.5 Circuit diagram of the magnetic field transducer and neural network

Opäť bola zvolená dopredná neurónová sieť s jednou skrytou vrstvou vytvorená v prostredí MatLAB. V tréningovej fáze bolo učených 9 blokov siete odpovedajúcich teplotám  $20^\circ\text{C}$ ,  $30^\circ\text{C}$ , ...,  $100^\circ\text{C}$ . Pre každú teplotu bola vytvorená tréningová množina pozostávajúca z dvojíc výstupného napätia snímača S #1 a presnej hodnoty intenzity mag. poľa určenej z kalibrátora (teda  $y = H$ ). Takto naučená neurónová sieť má schopnosť v produktívnej fáze potlačiť teplotný drift približne o jeden rád (z  $20\%$  na  $2\%$ ). Závislosť relatívnej chyby  $\delta$  výstupu neurónovej siete na budiacom prúde  $I$  je znázornená na obr. 6, kde parametrom je teplota.



Obr.6 Potlačenie chýb snímača intenzity magnetického poľa pomocou neurónovej siete

Fig.6 Errors reduction of the magnetic field transducer by neural network


## 2.3 Magnetoelastický snímač tlakovej sily

Magnetoelastické snímače sú principiálne založené na existencii Villariho javu. Tento sa prejavuje vo feromagnetickú látke (jadro snímača) zmenou permeability pri pôsobení mechanického namáhania. Snímač je zapojený ako transformátor, ktorého výstupné napätie je úmerne pôsobiacej sile. Zmeny výstupného napätia magnetoelastického snímača  $\Delta U_2$  od pôsobiacej sily  $F$  možno vyjadriť vzťahom (7), kde  $m$  a  $n$  sú počty lamiel,  $N_1$  a  $N_2$  sú počty závitov,  $f$  je frekvencia prúdu  $I_1$ ,  $\lambda_s$  koeficient magnetostrikcie v nasýtení,  $B_s$  magnetická indukcia pri nasýtení,  $a$  a  $b$  rozmery snímača,  $\mu$  permeabilita.

$$\Delta U_2 = m \cdot n \cdot \frac{2fN_2N_1I_1\lambda_s\mu^2}{B_s^2\pi b} \cdot \log \frac{b}{a} \cdot F \quad (7)$$

Vzťah (7) je aj napriek svojej zložitosti len linearizáciou prevodovej charakteristiky v jednom bode. Pre obsiahnutie celej prevodovej charakteristiky by bolo potrebné poznať hodnoty vstupných parametrov vo všetkých bodoch tejto charakteristiky. V praxi to nie je možné, preto môžeme previesť len určitú kvantizáciu, rozdeliť rozsah vstupnej veličiny na konečný počet bodov. Riešenie problému takýmto spôsobom však smeruje k vyhľadávacej tabuľke, ktorej nevýhodou by boli vysoké nároky na kapacitu internej EEPROM pamäte. Navyše hodnoty uložené v pamäti by sa vzťahovali len k presne definovaným vonkajším parametrom, z ktorých najvýznamnejší je teplota. Vhodnosť použitia neurónových sietí teda rezultuje zo spomínaných problémov. Taktiež, kompenzovanie externých vplyvov v prípade neurónových sietí znamená len prídanie ďalších vstupov do siete.

Vzhľadom na možnosti experimentálneho overenia funkcie a metrologických charakteristík magnetoelastického snímača bol zvolený typ EMS-120kN s nominálnou meracou silou 120 kN. Bloková schéma zapojenia je na obr. 7, [6].



Obr.7 Schéma zapojenia magnetoelastického snímača a neurónovej siete

Fig.7 Circuit diagram of the magnetoelastic sensor and neural network

Oprávnenosť využitia nielen dopredných ale aj rekurentných neurónových sietí, ktoré dokážu zahrnúť aj časový kontext vstupnej veličiny, potvrdzuje výrazne nelineárne správanie a značná hystereza predmetného snímača. V týchto systémoch budú pre použitie neurónových sietí rozhodujúce ich adaptačné a generalizačné vlastnosti. Cieľom je analyzovať tieto siete, nájsť pre ne vhodné parametre (typ a topológiu siete, učiaci algoritmus), ktorých vplyv bol pri experimentoch sledovaný a nájsť najvhodnejšie riešenia z hľadiska presností dosiahnutých výsledkov a z hľadiska výpočtovej a implementačnej náročnosti.

Od neurónových sietí očakávame jednak uľahčenie prevodu výstupného napätia snímača do jednotiek meranej veličiny a zároveň potlačenie chýb snímača. Z ohľadom na vhodnosť použitia boli vybrané nasledujúce typy neurónových sietí (všetky experimenty boli vykonávané v simulačnom prostredí MatLAB):


- viacvrstvová dopredná neurónová sieť (FFNN)
- RBF neurónová sieť (RBF)
- sieť s časovým oknom do minulosti (TDNN)
- Elmanova neurónová sieť (ELM)
- modulárne neurónové siete (MOD)

Pri modulárnych neurónových sieťach ide o systém pozostávajúci z dvoch modulov neurónových sietí. Označme jednotlivé neurónové moduly systému ako modul NN1 a NN2. V tréningovej fáze bude modul NN1 učení na hysterezu závislosť, tzv. „charakteristiku nahor“ a NN2 na „charakteristiku nadol“. Ďalej je do systému pridaný parameter  $\zeta(t)$ , ktorého znamienko určené funkciou  $Sign(\zeta(t))$  určuje, ktorý modul siete sa aktivuje pre spracovanie signálu z výstupu snímača  $U_2(t)$ . Parameter  $\zeta(t)$  určíme ako rozdiel aktuálnej

$U_2(t)$  a predchádzajúcej hodnoty napätia  $U_2(t-1)$  na výstupe snímača:

$$\zeta(t) = U_2(t) - U_2(t-1) \quad (8)$$

Navrhovaný modulárny systém neurónových sietí pre potlačenie chýb snímačov je znázornený na obr. 8.



Obr.8 Modulárny systém neurónových sietí

Fig.8 Modular system of neural networks

Funkcia popisujúca výstup modulárneho systému je daná vzťahom:

$$F_{NN}(t) = \begin{cases} sim(NN1, U_2(t)) & - \text{ak } \zeta(t) < 0 \\ sim(NN2, U_2(t)) & - \text{ak } \zeta(t) > 0 \\ F_{NN}(t-1) & - \text{ak } \zeta(t) = 0 \end{cases} \quad (9)$$

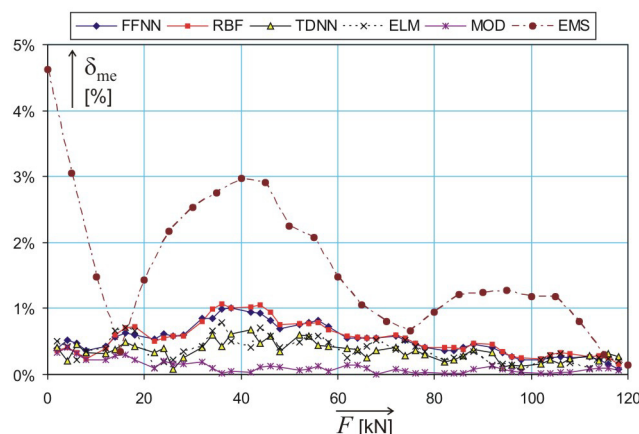
kde  $sim()$  je funkcia simulujúca daný modul neurónovej siete. Porovnanie potlačenia chýb systémami s neurónovými sieťami so štandardným algoritmom (bez neurónovej siete, označené ako EMS) je uvedené v nasledujúcej tabuľke.

Tab.1 Chyby systémov s neurónovými sieťami a snímačom EMS-120kN

	No.*	$\delta_{ina}$	$\delta_{hys}$	$\delta_{lin}$
EMS	-	-3,16%; 5,24%	2,13 %	4,63 %
FFNN	6	-1,25%; 1,27%	2,11%	0,24%
RBF	7	-1,34%; 1,37%	2,05%	0,25%
TDNN	6	-1,12%; 1,03%	1,28%	0,33%
ELM	4	-1,34%; 0,97%	1,40%	0,36%
MOD	5 + 5	-0,97%; 0,74%	0,56%	0,22%

(\* počet neurónov v skrytej vrstve,  $\delta_{ina}$  - chyba presnosti,  $\delta_{hys}$  - chyba hysterezy,  $\delta_{lin}$  - chyba linearity)

Obr. 9 reflektuje účinné potlačenie relatívnej meranej chyby  $\delta_{me}$  určenej štandardizovaným postupom podľa normy STN EN 60 770 [3]. Najvýznamnejšie potlačenie sa dosahuje modulárnymi systémami, ktoré využívajú prirodzenú vlastnosť magnetoelastických snímačov – hysterezu.



Obr.9 Potlačenie meranej chyby v závislosti od pôsobiacej sily

Fig.9 Measured error reduction depending upon acting force

## 2.4 Magnetoelastický snímač krútiaceho momentu

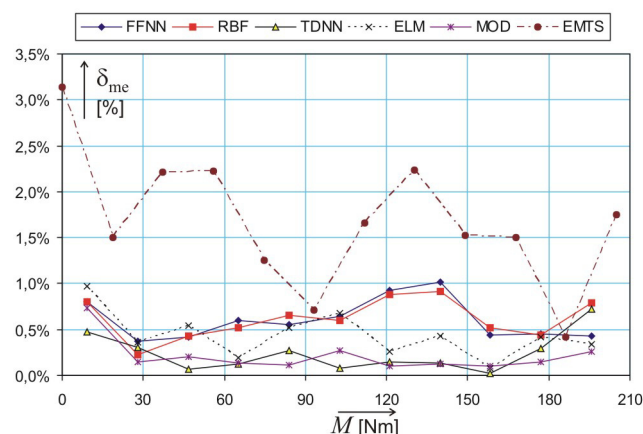
Jeho princíp je podobný ako v predchádzajúcom prípade [7]. Schéma zapojenia snímača S (EMTS-200Nm), na ktorý pôsobí krútiaci moment  $M$ , je na obr. 7. Podobne, aj v tomto prípade boli použité rôzne neurónové siete na potlačenie chýb snímača. Ich porovnanie so štandardným algoritmom (bez neurónovej siete, označené ako EMTS) je uvedené v tab. 2.

**Tab.2 Chyby systémov s neurónovými sieťami a snímačom EMS-200Nm**

	No.*	$\delta_{ina}$	$\delta_{hys}$	$\delta_{lin}$
EMTS	-	-2,60%; 3,16%	2,18 %	3,11 %
FFNN	4	-1,32%; 1,09%	2,02%	0,57%
RBF	10	-1,21%; 1,11%	2,04%	0,50%
TDNN	4	-0,74%; 0,88%	0,94%	0,29%
ELM	4	-1,08%; 0,97%	1,45%	0,55%
MOD	4 + 4	-0,99% ; 0,42%	1,18%	0,27%

(\* počet neurónov v skrytej vrstve,  $\delta_{ina}$  - chyba presnosti,  $\delta_{hys}$  - chyba hysterézy,  $\delta_{lin}$  - chyba linearity)

Podobne, na obr. 10 je znázornená závislosť  $\delta_{me}$  od krútiaceho momentu  $M$ . Najvýznamnejšie potlačenie dosahujú modálne systémy.



**Obr.10 Potlačenie meranej chyby v závislosti od krútiaceho momentu**

**Fig.10 Measured error reduction depending upon torque**

## Záver

Článok predstavuje na konkrétnych príkladoch možnosti potlačenia chýb snímačov pomocou neurónových sietí. Porovnanie systémov s neurónovými sieťami vedie k týmto záverom:

- návrh neurónových sietí pre potlačenie chýb snímačov je stále kompromis medzi rýchlosťou neurónovej siete, implementačnou zložitou, stabilitou a poskytovanou presnosťou
- využitie viacvrstvových dopredných neurónových sietí a taktiež RBF neurónových sietí je relatívne jednoduché, stabilné a rýchle riešenie, avšak tieto siete nedokážu potlačiť hysterézu snímačov, pozri tab. 1 a 2
- rekurentné siete majú vďaka zahrnutiu časového kontextu schopnosť potlačiť chybu hysterézy. Najmä siete s časovým oknom do minulosti sa javia ako veľmi presné, rýchle a relatívne ešte jednoduché a stabilné riešenie.

Elmanove siete, aj keď efektívne potláčajú chyby snímača (aj hysterézu), ich použitie eliminuje implementačnú zložitú, horšia stabilita a výpočtová rýchlosť

- najlepšie výsledky z hľadiska presnosti a stability poskytujú modálne systémy s doprednými neurónovými sieťami za cenu väčšej implementačnej zložitosti.

## Podakovanie

prof. Ing. Linusovi Michaelimu, DrSc.

Výskum bol podporený Grantovou agentúrou Slovenskej Republiky, grantom VEGA No. 1/2180/05.

## Literatúra

- [1] Arpaia, P. et al: Systematic error correction for experimentally modelled sensors by using ANNs. Proceedings of IEEE IMCT'99, Venice, Italy, May 24-26, 1999, pp. 1635-1640.
- [2] Chudý, V., Palenčár, R., Kureková, E., Halaj, M.: Meranie technických veličín. Vydavateľstvo STU Bratislava, s. 688, 1999.
- [3] IEC 60770, Transmitters for Use in Industrial-process Control Systems - Part 1: Methods for Performance Evaluation, 1999-02, Part 2: Methods for Inspection and Routine Testing, 2003-01.
- [4] Kollár, M.: Vybrané kapitoly o inteligentných snímačoch. C-Press, Košice, s.136, 2005.
- [5] Dias Pereira, J.M. et al: A Temperature Compensated System for Magnetic Field Measurements Based on Artificial Neural Networks
- [6] Vojtko, J., Kováčová, I., Madarász, L., Kováč, D.: Neural network for error correction of pressure force sensor based on elastomagnetic phenomena. Proceedings ICC'2004: 2nd IEEE International Conference on Computational Cybernetics, Austria, 2004, pp. 143-146.
- [7] Vojtko, J. et al: Torque sensor based on Villar's phenomena. Acta Electrotechnica et Informatica. Vol. 4, No. 3, 2004, pp. 27-30.

## Abstract

The article introduces wide spectrum of neural network use in order to reduce sensor errors and it presents also advantages and disadvantages of individual networks in measurements. By adding such elements of artificial intelligence one can deal with intelligent measurement systems, which are used more and more in technical praxis.

Ing. Jozef Vojtko, PhD.

RWE Systems Slovakia, s.r.o., SIS-DT Testfactory  
 Južná Trieda 6  
 040 01 Košice  
 Tel.: +421 55 610 4069  
 e-mail: jozef.vojtko@rwe.com