

Zpracování naměřených diagnostických veličin neuronovými sítěmi a jejich využití v diagnostice elektrických strojů

P. Latina¹

¹ Ústav výrobních strojů, systémů a robotiky, Odbor elektrotechniky, VUT v Brně
Technická 2896/2, Brno
E-mail : latina@fme.vutbr.cz

Anotace:

V současné době můžeme aplikovat metody umělé inteligence jako efektivní nástroj v technické diagnostice. Tento článek popisuje výzkum zabývající se využitím jedné z metod umělé inteligence pro zpracování naměřených dat, která jsou získána nedestruktivním měřením elektrických veličin izolačního systému strojů pracujících v průmyslu, v tomto případě vyrábějících elektrickou energii. Neuronové sítě jsou zvolenou metodou, pomocí které se tato data zpracovávají a na jejich základě se popisuje funkční stav sledovaných strojů. Výhoda použití neuronových sítí v diagnostice je nejen v posouzení aktuálního stavu stroje, ale především v možnosti předpovídat stav stroje do budoucnosti.

ÚVOD

Diagnostika strojů je v současnosti důležitou vědní disciplínou popisující stav sledovaného stroje. Točivý elektrický stroj je v průmyslu nasazen převážně např. jako pohon obráběcích strojů, dopravníků apod. Významným užitím točivých elektrických strojů je energetika, kde tyto stroje, jako generátory vyrábí elektrickou energii. Diagnostiku takového stroje lze rozdělit na diagnostiku mechanických částí (např. ložiska) a diagnostiku elektrických částí, do kterých patří izolační systém elektrického stroje. Diagnostika této části v podobě OFF-LINE diagnostiky obnáší měření elektrických diagnostických veličin a prostřednictvím např. kritériálních hodnot se posuzuje funkční stav izolačního systému. Tento článek popisuje možnost rozšíření diagnostiky izolačních systémů o moderní přístup OFF-LINE diagnostiky využívající umělou inteligenci, a to neuronové sítě. V předchozím výzkumu [1] byla ověřena možnost využití neuronových sítí v diagnostice izolačních systémů elektrických strojů na vzorku materiálu. Vzorek materiálu byl tepelně stárnut a následně elektricky proražen, z čehož byla získána hodnota průrazného napětí, které jednoznačně ukončuje funkčnost materiálu. Hodnota průrazného napětí tvořila veličinu, kterou neuronová síť modelovala a predikovala. V praxi nastává problém toto průrazné napětí změřit z důvodu vzniku nefunkčního stavu celého stroje. Musí se tedy najít jiná vhodná veličina, která sebou nese informaci o schopnosti provozu stroje.

2. POPIS MĚŘENÝCH VELIČIN

Jak již bylo zmíněno, veličiny, které budou použity k modelování a k predikci veličiny charakterizující stav izolačního systému, byly získány nedestruktivním měřením na strojích, které vyráběly elektrickou energii, jednalo se o třífázové generátory. Data, která byla použita v tomto článku, byla

naměřena na generátoru, který pracoval 23 let. Měření probíhala v plánovaných odstávkách a revizích v intervalu 1, 2 nebo 3 let. K tomu, aby neuronová síť adekvátně modelovala stav stroje, je nutné této síti předložit veličiny, které obsahují dostatečný počet měření. S ohledem na uskutečnění jednotlivých měření, obsahovaly množiny naměřených veličin průměrně 17 prvků. Z výše uvedeného důvodu, byly vybrány následující veličiny:

- izolační odpor R_{I215} statorového vinutí měřený po patnácti sekundách od připojení měřícího napětí,
- izolační odpor R_{I260} statorového vinutí měřený po jedné minutě od připojení měřícího napětí,
- izolační odpor statoru R_{I2600} statorového vinutí měřený po deseti minutách od připojení měřícího napětí,
- nabíjecí proud I_{60} měřený po jedné minutě od připojení měřícího napětí,
- nabíjecí proud I_{600} měřený po deseti minutách od připojení měřícího napětí,
- ztrátový činitel $tg\delta$.

3. VÝBĚR VÝSTUPNÍ VELIČINY

Výstupní veličinou se myslí veličina, kterou se bude neuronová síť učit zapamatovat a také předikovat. Tato veličina se mimo jiné vybrala na základě korelační a regresní analýzy. U korelační analýzy byl vypočten výběrový koeficient korelace r_{XY} a Spearmanův korelační koeficient r_s . Výsledky korelační analýzy jsou uvedeny v tabulce 1 a 2.

Tab. 1: Výběrové koeficienty korelace r_{xy}

| Měřená veličina | I_{60} | I_{600} | R_{iz15} | R_{iz60} | R_{iz600} | $tg\delta$ |
|-----------------|----------|-------------|------------|------------|-------------|-------------|
| I_{60} | 1 | 0,75 | 0,17 | 0,05 | 0,53 | 0,66 |
| I_{600} | 0,75 | 1 | -0,13 | 0,14 | 0,11 | 0,78 |
| R_{iz15} | 0,17 | -0,13 | 1 | -0,15 | 0,60 | 0,01 |
| R_{iz60} | 0,05 | 0,14 | -0,15 | 1 | 0,04 | -0,03 |
| R_{iz600} | 0,53 | 0,11 | 0,60 | 0,04 | 1 | 0,34 |
| $tg\delta$ | 0,66 | 0,78 | 0,01 | -0,03 | 0,34 | 1 |

Tab. 2: Spearmanovy koeficienty korelace r_s

| Měřená veličina | I_{60} | I_{600} | R_{iz15} | R_{iz60} | R_{iz600} | $tg\delta$ |
|-----------------|----------|-------------|------------|------------|-------------|-------------|
| I_{60} | 1 | 0,48 | -0,07 | 0,001 | 0,70 | 0,68 |
| I_{600} | 0,48 | 1 | -0,18 | 0,01 | 0,10 | 0,54 |
| R_{iz15} | -0,07 | -0,18 | 1 | -0,34 | 0,15 | -0,14 |
| R_{iz60} | 0,001 | 0,01 | -0,34 | 1 | 0,03 | 0,08 |
| R_{iz600} | 0,70 | 0,10 | 0,15 | 0,03 | 1 | 0,62 |
| $tg\delta$ | 0,68 | 0,54 | -0,14 | 0,08 | 0,62 | 1 |


V tabulce 1 a 2 jsou tučným písmem označeny hodnoty korelačních koeficientů, u kterých byla vypočtená hladina významnosti menší než 0,05. Výsledky regresní analýzy jsou uvedeny v tabulce 3, která ukazuje, že většina veličin určitou mírou závisí na čase. Z výše zmíněných výsledků se nabízí použití výstupní veličiny pro neuronovou síť veličina I_{60} nebo $tg\delta$. Provedenými experimentálními výpočty se ukázalo, že neuronová síť přesněji predikuje veličinu $tg\delta$, proto byla vybrána veličina $tg\delta$ jako veličina, kterou bude neuronová síť modelovat a predikovat.

Tab. 3: Výsledky regresní analýzy pro lineární model


| Lineární regresní model | |
|-------------------------|----------------------------|
| Měřená veličina | Korelační koeficient r_r |
| I_{60} | -0,735 |
| I_{600} | -0,432 |
| R_{iz15} | -0,121 |
| R_{iz60} | 0,315 |
| R_{iz600} | -0,585 |
| $tg\delta$ | -0,745 |

4. NEURONOVÁ SÍŤ A JEJÍ ARCHITEKTURA

Neuronová síť byla zvolena typu Back-propagation. Modelovaný výstup tvořila veličina $tg\delta$ a různé kombinace ostatních veličin byly použity jako vstupní vektory, dle kterých se neuronová síť učí pamatovat výstupní veličinu. Od neuronové sítě se ve fázi modelování očekává stejný průběh výstupní veličiny, jako byl předložen ve fázi učení. Z tohoto důvodu není třeba, aby krok vstupního vektoru byl stejný, tzn., že časový interval mezi jednotlivými měřeními nemusí být stejný, např. jeden rok. Princip modelování naznačuje obr. 1, kde $Y(k)$ je označen průběh modelované veličiny a $M(k)$ je odezva neuronové sítě. Výsledek modelování se pozoroval v závislosti na změně architektury neuronové sítě, což je počet skrytých vrstev a počet neuronů skrytých vrstev a dále se pozorovala odezva na konkrétní zvolenou veličinu popř. počet veličin na vstupu.

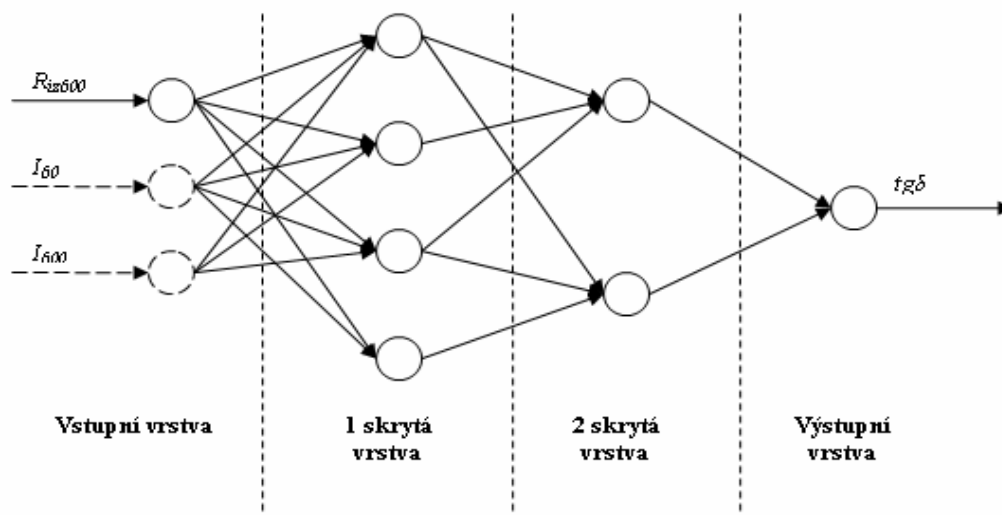


Obr. 1: Princip modelování výstupní veličiny



Obr. 2: Princip predikce výstupní veličiny

V případě predikce je odezva neuronové sítě tvořena na základě hodnoty aktuálního stavu a hodnot, které byly měřeny dříve, princip ukazuje obr. 2. Aby bylo možno ověřit predikovanou hodnotu výstupu, byl zmenšen počet vstupní i výstupní veličiny o několik hodnot a tyto zbylé hodnoty, které nebyly uplatněny ve fázi učení, byly použity k ověření predikce. Ve výsledcích uvedených níže byly predikovány 3 hodnoty výstupní veličiny. Ukázka architektury neuronové sítě je na Obr. 3.



Obr. 3: Příklad architektury neuronové sítě

5. PROGRAMOVÉ VYBAVENÍ PRO EXPERIMENT

Experiment modelování i predikce byl proveden prostřednictvím programového vybavení MATLAB® 7 a jeho Neural Network Toolboxu, ve kterém bylo také vytvořeno ovládací prostředí, pomocí kterého diagnostická obsluha volí kombinace vstupních veličin a měnila se architektura neuronové sítě změnou počtu skrytých vrstev a počtem neuronů těchto vrstev. Ovládací prostředí je znázorněno na obr. 4.

Obr. 4: Ovládací prostředí


6. VÝSLEDKY EXPERIMENTU

V následujících vybraných výsledcích modelování a predikce je zobrazena naměřená veličina $tg\delta$ černou přerušovanou křivkou a odpověď neuronové sítě $tg\delta_m$ plnou červenou křivkou. Dále je uveden graf absolutní chyby odezvy neuronové sítě. Před jednotlivými výsledky je uveden popis zvolených vstupních veličin a architektury neuronové sítě. V případě modelování byly použity všechny

naměřené hodnoty použitých veličin. V tomto případě 17 prvků. U výsledku predikce není již zobrazena fáze učení, proto tento výsledek obsahuje 3 predikované prvky, jak bylo popsáno výše.

6.1 Výsledek 1 (modelování, znázorňuje Obr. 5)

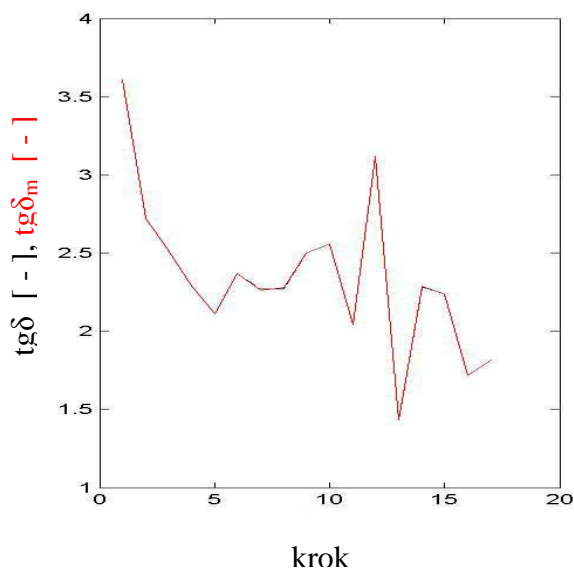
- vstupní veličina: R_{I260}
- výstupní veličina: $tg\delta$
- počet neuronů první skryté vrstvy: 7
- největší absolutní chyba odezvy neuronové sítě: 0,325 [-]



Obr. 5: Graf modelování výstupní veličiny pro zvolenou architekturu a absolutní chyba (Výsledek 1)

6.2 Výsledek 2 (modelování, znázorňuje Obr. 6)

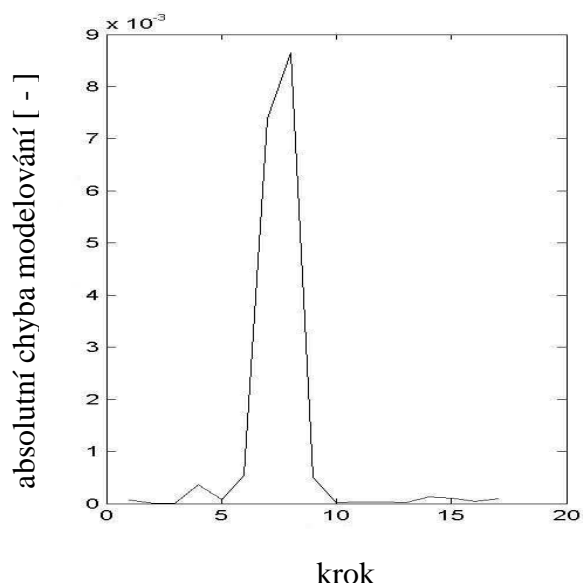
- vstupní veličiny: $I60$, $I600$
- výstupní veličina: $tg\delta$
- počet neuronů první skryté vrstvy: 10
- počet neuronů druhé skryté vrstvy: 7
- největší absolutní chyba odezvy neuronové sítě: 0,0086 [-]





Obr. 6: Graf modelování výstupní veličiny pro zvolenou architekturu a absolutní chyba (Výsledek 2)

6.3 Výsledek 3 (predikce, znázorňuje Obr. 7)

- vstupní veličiny: $I60$, $I600$
- výstupní veličina: $tg\delta$
- počet neuronů první skryté vrstvy: 7
- počet neuronů druhé skryté vrstvy: 5
- počet minulých hodnot: 2
- největší absolutní chyba odezvy neuronové sítě: 0,0722 [-]





Obr. 7: Graf predikce výstupní veličiny pro zvolenou architekturu a absolutní chyba (Výsledek 3)

7. ZÁVĚR

Z dosud provedených experimentů modelování a predikce vyplývá několik důležitých poznatků. Prvním z nich je, že neuronová síť se dokáže adaptovat na tato předložená data což je předpoklad pro následnou predikci. Toto je provedeno v režimu modelování. V případě, že je na vstupu neuronové sítě jedna veličina, vzrůstá schopnost adaptace prostřednictvím zvyšování počtu neuronů skrytých vrstev. Toto řešení je z hlediska výpočtu časově náročnější. Jak ukazuje výsledek na Obr. 5, tato architektura není ještě schopna dostatečně přesně modelovat výstupní veličinu. Pokud je na vstup neuronové sítě přivedena více jak jedna veličina (Obr. 6), snižuje se výrazně časová náročnost výpočtu a také se snižuje chyba odezvy neuronové sítě. Významnějším poznatkem pro praxi je schopnost předpovídat hodnotu veličiny do budoucna. To je znázorněno v provedených výsledcích predikce (Obr. 7). Byly zde pozorovány podobné závislosti jako v režimu modelování, a to na zvolené architektuře sítě a počtu veličin předložených na vstup neuronové sítě. Z výsledků predikce vyplývá že tento postup lze použít jako rozšiřující nástroj OFF-LINE diagnostiky, v tomto případě elektrických točivých strojů. Výhoda tohoto užití umělé inteligence je v získání informace o budoucí hodnotě sledované veličiny charakterizující stav izolačního systému a může se tak předejít neplánované odstávce stroje, nebo odhalit blížící se poruchu apod., což v konečném důsledku povede i k úspoře finančních prostředků.

LITERATURA

- [1] T. Kozlovský, Aplikace umělé inteligence v diagnostice izolačních systémů. Disertační práce, VUT Brno, 2004.
- [2] M. Pokorný, Umělá inteligence v modelování a řízení. BEN-technická literatura Praha, 1996.
- [3] Mařík, V. Štěpánková, O.: Umělá inteligence (4). ACADEMICA Praha, 2003.
- [4] M. Šnorek, Neuronové sítě a neuropočítače. Vydavatelství ČVUT Praha 2002, ISBN 80-01-02549-7
- [5] Barták, A, Mravináč, L. at al. *Diagnostika poruch izolací elektrických strojů*. Praha: SNTL – Nakladatelství technické literatury, 1984, 256 s.
- [6] M. Hammer, T. Kozlovský, P. Kratochvíl, M. Baroš, “Neural Network and the Life of Insulating Material for Windings in Electric Rotary Machines“. In: 12th International Conference on Flexible Automation and Intelligent Manufacturing, Dresden, Germany 2002, s. 55-63.
- [7] M. Hammer, Z. Říha, P. Latina, “Lifetime Prediction of Insulating Materials by Fuzzy Neural Networks and Expert Systems“, In: Conference Proceedings of 18. International Conference on Production Research ICPR 2005, University of Salerno, Fisciano (Italy), paper no. 481. ISBN 80–87030–96–0
- [8] M. Hammer, P. Latina, J. Kolčaba, P. Kratochvíl, “Artificial Intelligence for Diagnostics State of Electric Rotary Machina, XLIInd International Symposium on Electrical Machines SME 2006