

Iraida Kolcunová, Marián Hrisko, Juraj Kurimský

Katedra elektroenergetiky, Fakulta elektrotechniky a informatiky, Technická univerzita v Košiciach

Detekcia porúch meraním čiastkových výbojov s využitím umelej inteligencie

Abstrakt. Tento článok je zameraný na nedeštruktívnu diagnostickú metódu vysokonapäťových rotačných strojov – meranie čiastkových výbojov. Hlavným cieľom bol návrh a reálne odskúšanie expertného systému rozpoznávania porúch v izolačnom systéme vysokonapäťových rotačných strojov na základe meraní čiastkových výbojov. Navrhnutým expertným systémom bola dopreďná neurónová sieť, ktorej vstupné dáta boli reprezentované normalizovanými (Min-max, Z-Score, Median, Sigmoid) deskriptívnymi charakteristikami (šikmosť, špicatosť, nábojová asymetria a korelačný faktor).

Abstract. This article is focused on non-destructive diagnostic method of high-voltage rotating machines - partial discharges measurements. The main aim of this article was design and real testing of expert system to faults detection in insulation system of high-voltage rotating machines based on the partial discharges measurements. Designed expert system was feed forward neural network which used normalized data (Min-Max, Z-Score, Median, Sigmoid) of descriptive characteristics (skewness, kurtosis, and the charge asymmetry correction factor) as inputs.

Kľúčové slová: Čiastkové výboje, modelovanie porúch vn strojov točivých, neurónová sieť.

Keywords: Partial discharges, fault modeling in hv rotating machines, neural network.

Úvod

Neodmysliteľnou súčasťou každého elektrického rotačného stroja je jeho izolačný systém. Kvalita izolačného systému je úzko spojená s bezporuchovosťou a spoľahlivosťou týchto strojov. S rastúcim výkonom stúpa aj dôležitosť zabezpečenia spoľahlivej a bezporuchovej prevádzky, pretože prípadná porucha alebo havária by mohla spôsobiť nemalé energetické a finančné straty. [1] [2]

Overenie kvality je realizované mnohými diagnostickými metódami, či už deštruktívneho alebo nedeštruktívneho charakteru. Medzi spoľahlivé nedeštruktívne metódy patrí meranie čiastkových výbojov, ktorej sa v súčasnej dobe venuje zvýšená pozornosť.

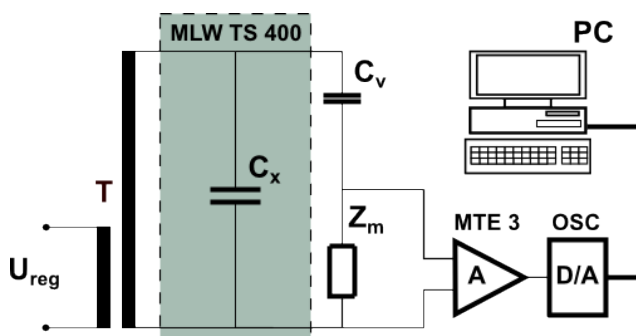
Čiastkové výboje sú neúplné samostatné výboje, ktoré podstatne znižujú spoľahlivosť a životnosť vysokonapäťových rotačných elektrických strojov. Ich účinky (elektrické, mechanické, chemické a tepelné) postupne narúšajú štruktúru použitých izolačných materiálov, čím v dôsledku času dochádza k prirazu izolácie. Diagnostikou čiastkových výbojov je možné pozorovať zmeny vo výbojovej aktivite v závislosti na čase a predchádzať tak možným poruchám. Aby bolo možné posúdiť kvalitu izolačného systému na základe výstupov z meraní čiastkových výbojov je nutná prítomnosť skúseného znalca - experta. Často krát nadobudnutie potrebných vedomostí je otázkou dlhodobého výskumu. Možným riešením daného problému je použitie autonómneho systému - neurónovej siete, ktorá by obsahovala potrebné vedomosti experta. [3]

Tento článok pojednáva o klasifikácii meraní čiastkových výbojov vysokonapäťových cievok, ktoré modelujú určité poruchové stavy, pomocou neurónovej siete. Zo zaznamenaných meraní výbojovej činnosti sú vytvorené dvojrozmerné grafy - fázové rozloženia čiastkových výbojov ($H_{qmax}(\varphi)$, $H_{qn}(\varphi)$, $H_n(\varphi)$). Na minimalizáciu fázových rozložení boli použité opisné charakteristiky (šikmosť, špicatosť, nábojová asymetria a korelačný faktor), ktoré koncentrovanou formou poskytujú informáciu o tvare fázového rozloženia čiastkových výbojov a sú vhodnými vstupnými údajmi do autonómneho systému rozpoznávania porúch izolačných systémov. Deskriptívne charakteristiky pred vstupom do neurónovej siete boli transformované

rôznymi typmi normalizácií (Min-max, Z-Score, Median, Sigmoid), ktoré znižujú časovú náročnosť výpočtu.

Princíp merania a skúšobné vzorky

Meraným objektom boli tri vysokonapäťové cievky z asynchrónneho stroja, ktoré modelovali rôzne poruchové stavy – cievka s poškodením vodivej vrstvy drážkovej časti, tepelne namáhaná cievka a nepoškodená cievka. Cievka s poškodenou vodivou vrstvou bola z asynchrónneho stroja s menovitým výkonom $P_n = 2,1$ MW a menovitým napätím $U_n = 6$ kV. Tepelne namáhaná cievka a nepoškodená cievka bola z asynchrónneho stroja s menovitým výkonom $P_n = 0,2$ MW a menovitým napätím $U_n = 6$ kV. Tepelná degradácia bola vykonaná v teplovzdušnej sušičke MLW TS 400 pri teplote 150 °C 100 hodín. Každá cievka bola odmeraná päť krát, t.j. 15 meraní s tromi rôznymi poruchovými stavmi.




Obr.1 Principiálna schéma zapojenia.

Meranie bolo vykonávané od napätia pri ktorom bola zaznamenaná stabilná výbojová činnosť po napätie 6 kV s krokom 0,2 kV. Každé meranie pri danej napäťovej hladine trvalo 3 minúty počas ktorých boli zaznamenané hodnoty zdanlivých nábojov a im prislúchajúcich početností.


Analýza nameraných výsledkov

Namerané údaje boli zaznamenané v dvoch základných súboroch, ktoré obsahovali informácie o hodnotách zdanli-


vého náboja a hodnotách početnosti, z ktorých boli vykreslené fázové rozloženia maximálnych hodnôt $H_{qmax}(\varphi)$ (Obr. 2), stredných hodnôt $H_{qn}(\varphi)$ (Obr. 3) a početnosti $H_n(\varphi)$ (Obr. 4) zdanlivých nábojov.



Obr. 2 Fázové rozloženie maximálnych hodnôt zdanlivých nábojov $H_{qmax}(\varphi)$.



Obr. 3 Fázové rozloženie stredných hodnôt zdanlivých nábojov $H_{qn}(\varphi)$.



Obr. 4 Fázové rozloženie početností zdanlivých nábojov $H_n(\varphi)$.

Pri odhaľovaní porúch čiastkových vývojoch je dôležitá fáza ich vzniku a rozvoja. Preto sú fázové rozloženia $H_{qmax}(\varphi)$, $H_{qn}(\varphi)$, $H_n(\varphi)$ rozdelené na kladnú a zápornú polvlnu priloženého napätia $H^+_{qmax}(\varphi)$, $H^+_{qn}(\varphi)$, $H^+_n(\varphi)$ a $H^-_{qmax}(\varphi)$, $H^-_{qn}(\varphi)$, $H^-_n(\varphi)$.

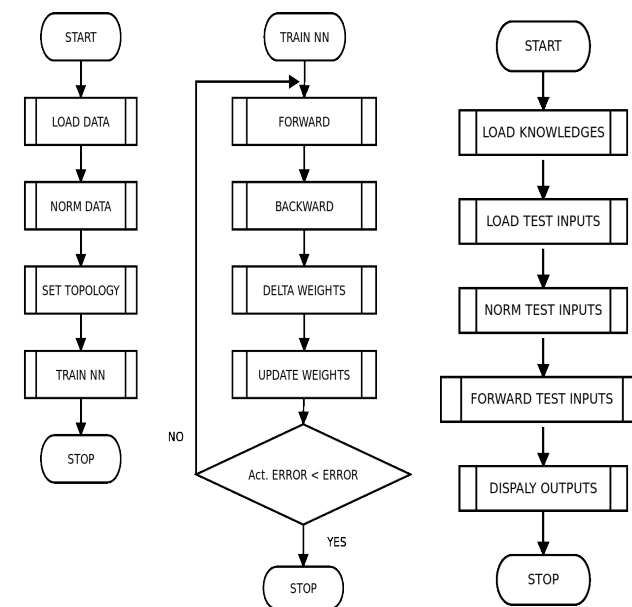
Z histogramov fázových rozložení boli vypočítané deskriptívne charakteristiky šikmosti S_{k_s} , špicatosti K_u , nábojovej asymetrie Q a korelačného faktora cc , ktoré koncentrovanou formou poskytujú informáciu o tvare fázových rozložení.

Operátor šikmosti porovnáva histogramy fázových rozložení s normálnym rozložením. Je zameraný na sklon, ako je dané fázové rozloženie naklonené - do pravej alebo do ľavej strany. Operátor špicatosti podobne ako operátor šikmosti porovnáva histogramy fázových rozložení s normálnym rozdelením, pričom sleduje plochosť alebo ostrosť fázového rozloženia. Nábojová asymetria porovnáva hodnoty sumačných nábojov v kladnej a zápornej polperióde. Korelačný faktor popisuje lineárnu závislosť medzi kladnou a zápornou polperiódou aplikovaného napätia.

Návrh a implementácia neurónovej siete

Na základe teoretických poznatkov uvedených v článku [4] bola navrhnutá viacvrstvá dopredná neurónová sieť so spätným šírením chybového signálu

(Multilayer Feedforward Neural Network). Celá sieť bola implementovaná v programe Octave 3.6.2 pod operačným systémom Ubuntu 12.04. Základný algoritmus je uvedený na Obr.5.



Obr. 5 Vývojové diagramy návrhu neurónovej siete.

Vstupom do neurónovej siete boli deskriptívne charakteristiky fázového rozloženia maximálnych hodnôt zdanlivých nábojov pre 6 kV hladinu. Na normalizáciu boli použité štyri typy normalizácii – Min-max, Z-Score, Median, Sigmoid.

Min-Max transformácia vstupných vychádza zo všeobecnej rovnice priamky podľa vzťahu:

$$(1) \quad x_i = \frac{x_{ij} - \min(x_j)}{\max(x_j) - \min(x_j)}$$

Z-Score normalizácia je definovaná podľa nasledujúcej rovnice:

$$(2) \quad x_i = \frac{x_{ij} - \mu_j}{\sigma_j}$$

kde σ_j , μ_j predstavujú smerodajnú odchýlku a priemernú hodnotu transformovaných údajov.

Médianová technika normalizácie dát využíva výpočet štatistického parametra polohy – médianu:

$$(3) \quad x_i = \frac{x_{ij}}{\text{Med}(a_j)}$$

kde $\text{Med}(a_j)$ predstavuje stred usporiadaného vektora deskriptívneho operátora.

Pri sigmoid technike sú dáta nelineárne transformované funkciou sigmoid, podľa vzťahu:

$$(4) \quad x_i = \frac{1}{1 + e^{-\frac{x_{ij} - \mu_j}{\sigma_j}}}$$

kde σ_j , μ_j predstavujú smerodajnú odchýlku a priemernú hodnotu transformovaných údajov.

Jedným z cieľom predkladaného článku bolo nájsť typ normalizácie deskriptívnych charakteristík fázových rozložení maximálnych hodnôt zdanlivých nábojov, ktorý by z hľadiska časovej náročnosti vykazoval najlepšie výsledky.

Vyhodnotenie klasifikácie bolo realizované z hľadiska troch rôznych počtov trérovacích vzorov vo fáze učenia:

- jedno meranie (meranie č.1)
- dve merania (meranie č.1, meranie č.2)
- tri merania (meranie č.1, meranie č.2, meranie č.3)

Topológia neurónovej siete

Topológia navrhutej neurónovej siete pozostávala zo štyroch vrstiev.

Počet neurónov vstupnej vrstvy je závislý od počtu deskriptívnych charakteristík, na základe ktorých má byť trévaná sieť. V tomto prípade sa jednalo o šesť deskriptívnych charakteristík ($S^*_k, K^*_u, S^-_k, K^-_u, Q, cc$) fázového rozloženia $H_{qmax}(\varphi)$. Počet neurónov v prvej skrytej vrstve je definovaný podľa [5], je o jeden neurón vyšší ako počet neurónov vo vstupnej vrstve. Počet neurónov v druhej skrytej vrstve je vypočítavaný podľa [6], kde počet neurónov v druhej skrytej vrstve bol vypočítavaný ako druhá odmocnina súčinu počtu neurónov vo vstupnej a výstupnej vrstve:

$$(5) \quad N_h = \sqrt{N_{in} N_{out}}$$

Počet neurónov vo výstupnej vrstve bol tri, s kombináciami výstupov 1-0-0 pre cievku s poškodenou vodivou vrstvou, 0-1-0 pre tepelne namáhanú cievku a 0-0-1 pre nepoškodenú cievku.


Zhodnotenie výsledkov

Vyhodnotenie neurónovej siete bolo sledované z hľadiska typu použitej normalizácie a hľadiska klasifikácie meraní čiastkových výbojov k určitej poruche.

Časy a počty iterácií pre jednotlivé typy použitých normalizácií vstupných údajov potrebných k získaniu vedomostí klasifikácie meraní čiastkových výbojov neurónovou sieťou sú uvedené v Tab. 1. Grafické znázornenie časov a počtov iterácií je na Obr. 6.

Tabuľka 1. Počty iterácií a časov fázy učenia NN.

Normalizácia	Min-max			Z-Score		
	1	2	3	1	2	3
Počet vzorov	1	2	3	1	2	3
Počet cyklov	7200	5765	4942	3752	4806	4366
Doba učenia	26.2	40.0	50.4	13.8	33.4	44.5
Normalizácia	Median			Sigmoid		
	1	2	3	1	2	3
Počet vzorov	1	2	3	1	2	3
Počet cyklov	3737	4217	3444	5791	7209	6365
Doba učenia	14.4	29.1	35.4	21.2	50.3	64.9



Obr. 6 Počty iterácií a časov fázy učenia NN.

Percentuálne vyjadrenie správnosti zatriedenia zvyšných meraní čiastkových výbojov odmeraných cievok v závislosti od počtu meraní vo fáze učenia s použitím rôznych typov normalizácií sú uvedené v Tab. 2 – Tab. 5. Za správnu klasifikáciu merania je považované zatriedenie s úspešnosťou nad 80 % (vyznačenou červenou farbou).

Tabuľka 2. Správnosť zatriedenia meraní Min-max normalizáciou.

Vyhodnotenie pre 1 vzor (meranie č. 1) [%]			
	Namáhaná	Poškodená	Nepoškodená
Meranie č.2	0.09	3.65	0.97
Meranie č.3	0.18	2.53	0.05
Meranie č.4	0.10	2.53	0.24
Meranie č.5	0.09	12.8	1.86
Vyhodnotenie pre 2 vzory (meranie č. 1 a č. 2) [%]			
Meranie č.3	98.5	0.02	1.70
Meranie č.4	98.6	1.22	90.8
Meranie č.5	98.7	98.5	20.6
Vyhodnotenie pre 3 vzory (meranie č. 1, č. 2 a č.3) [%]			
Meranie č.4	99.1	27.5	97.8
Meranie č.5	99.1	97.1	97.3

Tabuľka 3. Správnosť zatriedenia meraní Z-Score normalizáciou.

Vyhodnotenie pre 1 vzor (meranie č. 1) [%]			
	Namáhaná	Poškodená	Nepoškodená
Meranie č.2	47.2	76.8	4.39
Meranie č.3	66.7	0.89	55.5
Meranie č.4	52.4	1.67	4.09
Meranie č.5	45.2	82.4	59.3
Vyhodnotenie pre 2 vzory (meranie č. 1 a č. 2) [%]			
Meranie č.3	98.4	0.49	69.0
Meranie č.4	98.4	0.92	97.2
Meranie č.5	98.4	97.9	95.2
Vyhodnotenie pre 3 vzory (meranie č. 1, č. 2 a č.3) [%]			
Meranie č.4	97.8	85.3	98.2
Meranie č.5	98.6	98.9	96.4

Tabuľka 4. Správnosť zatriedenia meraní Median normalizáciou.

Vyhodnotenie pre 1 vzor (meranie č. 1) [%]			
	Namáhaná	Poškodená	Nepoškodená
Meranie č.2	7.29	96.9	0.98
Meranie č.3	4.25	1.95	57.5
Meranie č.4	6.39	2.79	3.88
Meranie č.5	7.88	97.6	54.1
Vyhodnotenie pre 2 vzory (meranie č. 1 a č. 2) [%]			
Meranie č.3	96.8	0.97	1.56
Meranie č.4	98.3	4.03	2.68
Meranie č.5	98.4	98.5	1.76
Vyhodnotenie pre 3 vzory (meranie č. 1, č. 2 a č.3) [%]			
Meranie č.4	98.6	91.5	72.5
Meranie č.5	98.3	98.4	97.4

Tabuľka 5. Správnosť zatriedenia meraní Sigmoid normalizáciou.

Vyhodnotenie pre 1 vzor (meranie č. 1) [%]			
	Namáhaná	Poškodená	Nepoškodená
Meranie č.2	0.24	5.18	0.66
Meranie č.3	0.79	1.92	0.05
Meranie č.4	0.32	1.74	1.52
Meranie č.5	0.21	40.2	0.74
Vyhodnotenie pre 2 vzory (meranie č. 1 a č. 2) [%]			
Meranie č.3	98.9	0.18	1.43
Meranie č.4	98.0	0.58	79.5
Meranie č.5	98.1	97.8	28.7
Vyhodnotenie pre 3 vzory (meranie č. 1, č. 2 a č.3) [%]			
Meranie č.4	99.0	11.5	98.2
Meranie č.5	98.9	54.2	98.4

Zatriedovanie meraní čiastkových výbojov do skupiny cielok s určitým typom poruchy je závislé od typu použitej normalizácie vstupných údajov. Najlepšie výsledky pre jeden vstupný vzor boli dosiahnuté pri použití medianovej normalizácie vstupných vzorov, kde úspešnosť klasifikácie dosiahla 17 %. Sieť natrénovaná dvoma a tromi vstupnými vzormi dokázala najlepšie klasifikovať merania v prípade použitia Z-Score normalizácie. Pre dva vstupné vzory úspešnosť klasifikácie dosiahla 67 % a pre tri vstupné vzory 100 %.

Záver

Na základe výsledkov vyhodnotenia normalizácií vstupných údajov boli najlepšie výsledky dosiahnuté pri tréningu siete Z-Score normalizáciou. Využitím tejto skutočnosti vo fáze učenia siete je možné ušetriť čas a tým urýchliť samotný proces autonómneho vyhodnocovania meraní čiastkových výbojov neurónovou sieťou.

Úspešnosť klasifikácie meraní čiastkových výbojov značne súvisela s počtom tréningových vzorov. Vo všetkých typoch použitých normalizácií boli najlepšie výsledky dosiahnuté pri troch vstupných vzoroch. Neurónová sieť získala dostatočný rozsah vedomostí, ktorým dokázala správne zatriediť všetky merania pri použití Z-Score normalizácie.

So zreteľom na dosiahnuté výsledky je možno neurónovú sieť považovať za vhodný matematický aparát, ktorý s nadobudnutými vedomosťami, t.j. s dostatočným počtom reprezentatívnych vstupných vzorov, môže byť použitý ako nástroj na určovanie kvality izolačného systému.

Literatúra

- [1] STONE, G.C.: Partial Discharge Diagnostics and Electrical Equipment Insulation Condition Assessment. IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 12 No. 5, October 2005, pp. 891-903. ISSN: 1070-9878.
- [2] CIMBALA, R., BALOG, J., DŽMURA, J.: Diagnostika výkonových transformátorov s využitím prvkov umelej inteligencie 2. Elektrotechnický magazín ETM. Vol. 14, no. 2 (2004), p. 14. - ISSN 1210-5422.
- [3] CIMBALA, R., BALOG, J., DŽMURA, J.: Diagnostika výkonových transformátorov s využitím prvkov umelej inteligencie 1. Elektrotechnický magazín ETM. Vol. 14, no. 1 (2004), p. 8-9. ISSN: 1210-5422.
- [4] GULSKI, E., KRIVDA, A: Neural Networks as a Tool for Recognition of Partial Discharges. IEEE Transactions on Electrical Insulation, ISSN: 0018-9367. December 1993, Vol. 28, No. 6, s. 984-1001.
- [5] SAW, C.: Backpropagation using Octave. [online]. Dostupný z: <http://sawcordwell.wordpress.com/2013/01/31/backpropagationusing-octave/>.
- [6] SHIBATA, K.: Effect of number of hidden neurons on learning in large-scale layered neural networks. ICROS-SICE International Joint Conference 2009 August 18-21, 2009, Fukuoka International Congress Center, Japan.

PodĎakovanie



„Táto práca bola podporovaná Agentúrou Ministerstva školstva Slovenskej republiky pre štrukturálne fondy EÚ na základe projektu Vývoj unikátneho nízkoenergetického statického

zdroja pre elektrosystémy (číslo projektu: 26220220029, prioritná os 2 Podpora výskumu a vývoja)“ .

Autori: Iraida Kolcunová, Katedra elektroenergetiky, Fakulta elektrotechniky a informatiky Technickej univerzity v Košiciach, Letná 9, 042 00 Košice, E-mail: iraida.kolcunova@tuke.sk

Marián Hrinko, Katedra elektroenergetiky, Fakulta elektrotechniky a informatiky Technickej univerzity v Košiciach, Letná 9, 042 00 Košice, E-mail: marian.hrisko@tuke.sk

Juraj Kurimský, Katedra elektroenergetiky, Fakulta elektrotechniky a informatiky Technickej univerzity v Košiciach, Letná 9, 042 00 Košice, E-mail: juraj.kurimsky@tuke.sk