

Ľubomír Pallaj, Jaroslav Petráš, Ardian Hyseni, Matej Vaľko

Využitie lineárneho strojového učenia na klasifikáciu signálov čiastkových výbojov v statorových cievkach

Článok sa zameriava na využitie lineárnych modelov strojového učenia pri klasifikácii čiastkových výbojov na statorových cievkach elektrických strojov. Merané signály čiastkových výbojov boli spracované pomocou Waveletovej transformácie, čím sa získala ich časovo-frekvenčná charakteristika vo forme škálogramov. Tieto škálogramy následne slúžili ako vstupné dáta pre lineárny klasifikačný model strojového učenia, ktorého úlohou bolo rozlíšiť jednotlivé typy výbojov na základe odlišných vzorov a frekvenčného rozloženia v škálogramoch. Výsledky naznačujú, že aj jednoduchý lineárny model strojového učenia bol schopný rozlíšiť časovo-frekvenčné charakteristiky škálogramov a úspešne ich rozoznať medzi sebou, čím sa potvrdila dostatočná účinnosť pre základnú klasifikáciu dát.

Kľúčové slová: čiastkové výboje, Waveletová transformácia, strojové učenie, klasifikácia dát

The article focuses on the application of linear machine learning models for classifying Partial Discharges in the stator coils of electrical machines. The measured PD signals were processed using the Wavelet Transform, which yielded their time-frequency characteristics in the form of scalograms. These scalograms subsequently served as input data for a linear machine learning classification model, whose task was to differentiate individual discharge types based on distinct patterns and frequency distribution within the scalograms. The results demonstrate that even a simple linear machine learning model was able to distinguish the time-frequency characteristics of the scalograms and successfully differentiate them from each other, thereby proving sufficient effectiveness for basic data classification. **(Utilization of Linear Machine Learning for the Classification of Partial Discharge Signals in Stator Coils)**

Keywords: partial discharge (PD), Wavelet Transform, machine learning (ML), data classification.

I. ÚVOD

Z oblasti údržby a diagnostiky elektrických točivých strojov je dôležitou úlohou monitorovanie čiastočných výbojov (PD), ktoré predstavujú jednu z hlavných príčin zlyhania izolačných systémov v elektrických zariadeniach, a to najmä v takých dôležitých častiach, ako sú statorové cievky točivých elektrických strojov [1]. Úspešné riadenie životnosti týchto strojov závisí od presnej identifikácie typu signálov čiastkových výbojov. Z tohto dôvodu je zvýšená pozornosť venovaná kombinácii metód spracovania signálov a strojového učenia (ML). Hoci pokročilé nelineárne modely ponúkajú vysokú presnosť, často so sebou prinášajú nevýhody vo forme výpočtovej náročnosti. Z tohto dôvodu sa v analýze signálov uplatňujú aj prístupy založené na lineárnom strojovom učení. Tie slúžia ako počiatočný model tréningu neurónovej siete a zároveň poskytujú efektívnu klasifikáciu s lepšou interpretovateľnosťou získaných výsledkov [2][3].

Táto práca sa konkrétne zameriava na aplikáciu Waveletovej transformácie (WT) ako metódy spracovania signálu v kombinácii s lineárnymi klasifikačnými algoritmami strojového učenia [4]. Cieľom nie je posudzovať kompletný diagnostický stav zariadenia, ale zlepšiť a zefektívniť samotný proces klasifikácie transformovaných signálov čiastočných výbojov. Výskum rieši problémy efektívneho spracovania impulzných signálov PD, ktoré boli zamerané priamo na izolácii statorových cievok. Tieto signály boli následne transformované pomocou WT. Aplikáciou Waveletovej transformácie vzniká časovo-frekvenčná charakteristika, ktorá je vizualizovaná ako škálogram, ktorý slúži ako vstupné dáta pre vytvorený lineárny model strojového učenia. Hlavným cieľom je vytvoriť a porovnať výkonnosť lineárnych modelov ML pri učení sa rozlišovať škálogramy PD medzi sebou a na základe tohto rozlíšenia ich správne klasifikovať, pričom sa kladie dôraz na ich schopnosť generalizácie aj na neznáme vstupy.

Využitie modelov strojového učenia na klasifikáciu signálov otvára nové možnosti k vytváraniu základných modelov pre automatizované spracovanie dát. Integrácia transformačných metód s lineárnymi klasifikátormi umožňuje objektívne posúdenie miery podobnosti medzi klasifikačnými triedami signálov. Výsledky tejto práce môžu byť využité pri návrhu inteligentných systémov, ktoré klasifikujú spracované dáta s nízkou výpočtovou náročnosťou, ktoré môžu slúžiť ako základ pre budúce komplexné diagnostické riešenia. [3][5].

II. PRÍPRAVA MERANIA TESTOVANÝCH VZORIEK

Na Katedre elektroenergetiky v Košiciach sa uskutočnili merania čiastočných výbojov na dvoch pripravených testovacích vzorkách. Na detekciu signálov čiastočných výbojov bola použitá galvanická metóda.

Zmerané impulzné signály PD boli zaznamenané pomocou digitálneho osciloskopu, uložené do dátového úložiska a následne spracované pomocou Waveletovej transformácie do podoby škálogramov. Nakoľko surové časové priebehy PD neposkytujú dostatok rozpoznávacích znakov pre lineárne modely, boli nakoniec transformované do podoby škálogramov, ktoré slúžili ako vstupné dáta pre vytvorený lineárny klasifikačný model strojového učenia. Tieto spracované dáta boli vyhodnotené pre ich implementáciu a využitie pri vytváraní modelu.

Ako testovacia vzorka bola použitá reálna cievka statorového vinutia. Cievka bola v meracom usporiadaní zavesená na izolačnom lane, aby sa minimalizovalo rušenie a vplyvy okolia. Pre zamedzenie koncentrácie elektrického poľa na koncoch vinutia a zabezpečenie homogenity bol každý koniec cievky pripojený k homogenizačnej guli. V experimentálnom súbore boli použité dve rôzne cievky statorového vinutia, ktoré boli zámerne vybrané tak, aby predstavovali rozdiely v izolačných parametroch. Líšili sa nielen základným materiálom, ale aj

typom použitej epoxidovej vrstvy, aplikovaným polovodičovým náteru a celkovými rozmermi. Pre prehľadnosť a zjednodušenie odkazovania na tieto vzorky v kontexte spracovania dát vytvoreným lineárnym modelom ich budeme v ďalších kapitolách označovať ako: Cievka – Hnedý náter (Obr. 1) a Cievka – Biely náter (Obr. 2).




Obr. 1. Sistorová cievka s polovodičovým náterom



Obr. 2. Sistorová cievka bez polovodičového náteru

Laboratórne meranie čiastočných výbojov bolo vykonané za kontrolovaných laboratórnych podmienok na Katedre elektroenergetiky. Postup sa riadil odporúčanými laboratórnymi štandardmi a normami. Schéma zapojenia priamej meracej metódy čiastočných výbojov je zobrazená na (Obr. 3)



Obr. 3. Schéma zapojenia priamej (galvanickej) metódy

Bloková schéma zapojenia pozostáva z:

U_{reg} – regulovateľný vysokonapäťový zdroj LSS020 (220V/250V), $I_n = 20A$, $S_n = 5kVA$; O_{chr} – ochrana; V_nTr – vysokonapäťový transformátor; C_a – skúšaný objekt; kV – kilovoltmeter; C_v – väzobný kondenzátor; Z_m – meracia impedancia; MTE 3 – meracie zariadenie čiastočných výbojov; OSC – digitálny pamäťový osciloskop DS07104B 1GHz.


Pred samotným začiatkom merania sa dôkladne skontrolovalo zapojenie meracieho obvodu, aby sa predišlo chybám v zapojení. Každé meranie sa uskutočnilo vo vnútri kovovej kobky, aby sa zabránilo vonkajšiemu elektromagnetickému rušeniu. Na začiatku merania osciloskop pripojený k meraciemu zariadeniu čiastočných výbojov MTE3 zaznamenal rušivé signály, ktoré boli spôsobené samotným zariadením MTE3. Toto rušenie sa odstránilo pridaním dodatočného tienenia a filtra medzi meracou impedanciou a meracím zariadením MTE3. Následne sa napätie postupne zvyšovalo pomocou autotransformátora, pričom jeho hodnota bola indikovaná a priebežne sledovaná na fyzickom kilovoltmetersi. Prvé identifikované čiastkové výboje na sistorových cievkach, zobrazené na osciloskope, boli

zaznamenané a uložené vo formáte CSV na USB. Výsledné dáta z osciloskopu boli následne spracované a vyhodnotené v softvéri Scilab, kde boli využité na grafické zobrazenie prostredníctvom Waveletovej transformácie. Jednotlivé výsledky z meraní a spracovania nameraných signálov čiastkových výbojov pomocou WT boli ďalej upravené pre ďalšie spracovanie a pripravené ako vstupné klasifikačné hodnoty pre lineárny model strojového učenia.

III. SPRACOVANIE NAMERANÝCH DÁT

Všetky namerané signály čiastkových výbojov boli spracované do formátu vhodného na použitie pri strojovom učení. Konverzia meraných dát bola realizovaná pomocou vlastného skriptu v prostredí Scilab, kde boli aplikované úpravy zamerané na zlepšenie čitateľnosti a interpretácie výsledných transformovaných údajov.


Celkovo bolo spracovaných 436 zaznamenaných čiastkových výbojov na sistorových cievkach, ktoré boli následne transformované do podoby škálogramov (Obr. 4). Z pohľadu neurónových sietí ide o pomerne malú dátovú sadu, keďže typické tréningové datasety pre učenie neurónových sietí bežne obsahujú tisíce vstupných obrazcov. To, či bude tento menší dataset postačujúci na správnu klasifikáciu jednotlivých tréningových tried, sa ukáže počas učenia lineárneho modelu.



Obr. 4. Signál čiastkového výboja transformovaný WT


Hlavným cieľom kombinácie Waveletovej transformácie s metódami hlbokého učenia je dosiahnuť schopnosť automatickej kategorizácie aj neznámych vzoriek čiastkových výbojov. Preto sa neurónová sieť nevyužíva iba na klasifikáciu známych vzoriek, ale aj na zhlukovanie dát neznámych vzoriek s cieľom objaviť nové vzory a súvislosti od naučených dát.

Z nameraných a spracovaných dát bolo potrebné rozdeliť a priradiť jednotlivé reprezentácie čiastkových výbojov do zodpovedajúcich dátových tried. Bez daného rozdelenia by nebolo možné aplikovať zvolený typ strojového učenia pod dozorom (supervised learning). Tento typ strojového učenia vyžaduje pre svoju funkciu, aby sa model učil klasifikovať na základe vopred známej a označenej sady dát. Tieto definované triedy tak slúžia ako známe referenčné kategórie, ktoré umožňujú modelu rozlišovať charakteristické vzory medzi vytvorenými triedami. Konkrétne rozdelenie klasifikačných tried je znázornené na Obr. 5, kde možno vizuálne pozorovať nielen charakteristické rozdiely v časovo-frekvenčnej štruktúre signálov medzi dvoma testovanými sistorovými cievkami, ale aj variácie vzorov v závislosti od úrovni napätia, pri ktorých boli čiastkové výboje zaznamenané. Tieto rozdiely v škálogramoch tvoria pre vytvorený lineárny model charakteristické vstupné vlastnosti pre úspešné rozlíšenie jednotlivých kategórií.



IV. NÁVRH LINEÁRNEHO MODELU

Prvým krokom vo vytváraní počiatočného lineárneho modelu bolo rozdelenie vytvorených klasifikačných dátových sád na tréningovú sadu, ktorá modelu poskytuje dáta na rozpoznávanie a učenie sa vzorov, a validačnú sadu, ktorá slúži ako nezávislé overenie jeho predikcií. Pri takomto rozdelení je potrebné určiť vhodný pomer medzi tréningovou a validačnou sadou, pretože nesprávne rozdelenie by mohlo viesť k skreslenému vyhodnoteniu modelu. Z tohto dôvodu bol zvolený konzistentný pomer 80 % pre tréningovanie a 20 % pre validáciu. Tým sa zabezpečil dostatočný počet vzoriek pre dostačujúce tréningovanie, pričom validačná sada zostala pomerne rozsiahla na objektívne posúdenie správnosti. Taktiež pri rozdeľovaní tréningových a validačných dát je potrebné zabezpečiť aby tréningová a validačná sada neobsahovali tie isté spracované škálogramy. Ak by boli v oboch sádach prítomné identické dáta, výsledky by mohli byť nepresné a model by sa namiesto skutočných vzorov učil iba rozpoznávať duplikáty.



Pri návrhu lineárneho modelu pre klasifikáciu čiastočných výbojov na statorových cievkach bola zvolená sekvenčná architektúra, ktorá je ideálna pre transparentné spracovanie dát v lineárnom poradí a tvorí základ pre implementáciu takého typu klasifikátora. Cieľom bolo vytvoriť model schopný správne extrahovať¹ naučené vzory zo škálogramov a následne ich klasifikovať² do zodpovedajúcich dátových

V. VÝSTUP LINEÁRNEHO MODELU

Na nasledujúcich výstupoch na Obr. 8 sú zobrazené priebehy presnosti a stratovej funkcie počas tréningovania lineárneho modelu. Tieto priebehy ilustrujú, ako sa model postupne učil rozlišovať jednotlivé triedy škálogramov a optimalizoval svoje váhy počas jednotlivých epoch. Na ľavej strane grafu je zobrazená presnosť (accuracy) modelu, ktorá vyjadruje podiel správne klasifikovaných vzoriek vzhľadom na ich celkový počet. Na pravej strane je zobrazená strata (loss), ktorá predstavuje rozdiel medzi predikovanými výstupmi modelu a skutočnými triedami. Čím je hodnota straty nižšia, tým lepšie model prispôbuje svoje váhy. Osa x predstavuje epochy, teda opakované iterácie modelu celým tréningovacím datasetom, počas ktorých sa váhy modelu postupne optimalizujú.



Obr. 8 Proces učenia lineárneho modelu

Na ľavej strane grafu na Obr. 8 možno pozorovať nárast tréningovej presnosti (modrá krivka), ktorá s rastúcim počtom epoch postupne stúpa a dosahuje približne 86 %. Validačná presnosť (oranžová krivka) nasleduje podobný trend až približne do 40. epochy, po ktorej začína výraznejšie kolísť a mierne klesá na úroveň okolo 70 %. V druhej časti grafu na Obr. 8 je možné sledovať hodnotu tréningovej straty (modrá krivka), ktorá sa postupne znižuje, čo naznačuje, že model sa úspešne učí rozlišovať medzi predikovanými a skutočnými triedami v tréningových dátach. Validačná strata (oranžová krivka) vykazuje podobný klesajúci trend až do približne 60. epochy, kde začína prudko kolísť a jej hodnota sa zvyšuje. Toto správanie naznačuje začiatok preučenia, keď model pri vyššom počte epoch začína si zapamätávať konkrétne vzory z tréningových dát namiesto učenia sa ich všeobecných charakteristických vzorov. V dôsledku toho sa znižuje jeho schopnosť správne aplikovať naučené črty pri predikcii na validačnej množine.


Z priebehu tréningovania znázorneného na Obr. 8 je zjavné, že príliš dlhé tréningovanie môže viesť k preučeniu modelu a môžeme potvrdiť z validačnej stratovej krivky, že lineárny model nie je správne optimalizovaný. Možnosti, ako tomuto predísť, zahŕňajú použitie viacerých regulačných funkcií, ako sú napríklad early stopping, regularizácia, aplikácia augmentácie na tréningovú sadu, zvýšenie hodnôt v dropout

vrstve alebo využívať väčšiu množinu dátových vzoriek. Celkovo by bolo potrebné prejsť na využitie konvolučných neurónových sietí (CNN), ktoré predstavujú zložitejší typ modelu schopný extrahovať podrobnejšie črty zo škálogramov. V nasledujúcej časti sa však zameriame na podrobnú analýzu jednotlivých validačných vzoriek, aby sme overili, do akej miery dokáže navrhnutý lineárny model správne rozlišovať nové vstupy.


VI. VALIDAČNÁ KLASIFIKÁCIA LINEÁRNEHO MODELU

Zameriavame sa na klasifikáciu škálogramov čiastkových výbojov v satorových cievkach pomocou validačnej množiny dát. Model priradzuje jednotlivé vzorky k najvhodnejšej triede na základe znalostí získaných z tréningovej množiny. Okrem toho sa hodnotí aj schopnosť modelu generalizovať na neznáme dáta, ktoré neboli súčasťou ani tréningovej, ani validačnej množiny. Tieto neznáme dáta tvoria tzv. verifikačnú množinu, ktorá sa používa na posúdenie celkovej robustnosti a schopnosti modelu správne klasifikovať nové vstupy. Z validačnej množiny bol vybraný jeden škálogram čiastkového výboja, pričom natrénovaný model priradil vzorku k najzodpovedajúcejšej triede na základe znalostí získaných počas tréningovania (obr. 9). Škálogram z validačnej množiny však nikdy nemôže byť úplne totožný so škálogramom z tréningovej množiny, pretože tieto datasety neobsahujú identické vzory. Správnosť predikcie modelu bola overená na validačnej množine, pričom vzorky boli úspešne priradené k najvhodnejšej triede.

Real: Cievka - Hnedý náter 8kV Prediction: Cievka - Hnedý náter 8kV



Real: Cievka - Hnedý náter 7kV Prediction: Cievka - Hnedý náter 7kV




Obr. 9 Validačné overenie na tréningovej sade

Klasifikácia bola úspešne overená vo všetkých variáciách skupín satorových cievok. Na ilustráciu validačnej klasifikácie je zobrazený príklad na Obr. 9, kde boli zobrazené len dve vyhodnotené vzorky. Overenie pritom prebiehalo celkovo z každej triedy, kde bola vybraná jedna vzorka, pričom pre každú triedu bol zvolený jeden reprezentatívny škálogram. Validačné vzorky boli následne porovnané s najpodobnejším škálogramom z tréningovej množiny, teda s tým, z

ktorého model identifikoval najvýraznejšie črty charakteristické pre predikovanú triedu validačnej vzorky. Pri vizuálnom porovnaní týchto škálogramov voľným okom je však náročné určiť, či patria do rovnakej triedy, na rozdiel od tradičných obrazových datasetov (napr. tvary alebo objekty), ktoré sa dajú rozlíšiť oveľa jednoduchšie.

Každá validačná vzorka z príslušných tried bola samostatne overená, čo umožnilo modelu preukázať schopnosť rozpoznávať charakteristické črty medzi škálogramami čiastkových výbojov v statorových cievkach. Presnosť klasifikácie validačných vzoriek bola približne zhodná s výsledkami dosiahnutými počas tréningu modelu (Obr. 8) a dosiahla hodnotu presnosti okolo 70,11 %.

Vyhodnotené predikcie pre celé validačné množiny dosiahli priemernú presnosť približne 70 %, pričom bolo nesprávne klasifikovaných 25 škálogramov čiastkových výbojov zo statorových cievok. Podrobnejšia analýza jednotlivých tried ukázala, v ktorých prípadoch mal model najväčšie ťažkosti s rozlišovaním medzi triedami a so správnym určením predikcie. Z tohto dôvodu je na Obr. 10 znázornené porovnanie počtu skutočných validačných vzoriek s počtom predikovaných tried podľa lineárneho modelu.




Obr. 10 Počet skutočných a odhadovaných vzoriek

Výsledky ukazujú, že natrénovaný lineárny model nedokázal spoľahlivo rozpoznať a predikovať triedu Cievka – Biely náter 5 kV, kde bol počet správne predikovaných vzoriek výrazne nižší v porovnaní so skutočným počtom vzoriek v danej triede. Naopak, väčšina nesprávnych predikcií bola priradená k triede Cievka – Biely náter 3.5 kV, čo naznačuje, že model bol aspoň schopný identifikovať správnu cievku, pričom chybovosť vznikala najmä v dôsledku rozdielov v napätí, pri ktorom boli čiastkové výboje merané. Pokiaľ ide o triedy Cievka – Hnedý náter 7 kV a 8 kV, rozdiely medzi predikovanými a skutočnými vzorkami boli menej výrazné. Napriek menšiemu rozdielu v napätí v tomto prípade v porovnaní s bielou cievkou dokázal model tieto triedy efektívnejšie rozlišovať a predikovať s vyššou presnosťou.

VII. VERIFIKAČNÁ KLASIFIKÁCIA LINEÁRNEHO MODELU

Natrénovaný lineárny model bol testovaný na neznámych škálogramoch, ktoré neboli súčasťou tréningovej a ani validačnej množiny dát. Každý vložený škálogram reprezentoval triedu, na ktorej bol model pôvodne trénovaný. Cieľom bolo overiť schopnosť modelu správne klasifikovať a predikovať kategóriu neznámej vzorky (Obr. 11). Klasifikácia bola čiastočne úspešná, keďže model správne priradil neznáme škálogramy do kategórií Cievka – Hnedý náter 8 kV a Cievka – Biely náter 3.5 kV, pričom dosiahol presnosť približne 44 %. Naopak, pre kategórie Cievka – Hnedý náter 7 kV a Cievka – Biely náter 5 kV model nedokázal vzorky správne klasifikovať, s dosiahnutou presnosťou okolo 35 %.



Obr. 11 Verifikačná presnosť lineárneho modelu

Celkovo boli testované všetky kategórie statorových cievok s neznámymi vzorkami, pričom priemerná presnosť klasifikácie dosiahla približne 40 %. Tento výsledok naznačuje, že model zatiaľ nie je schopný spoľahlivo generalizovať na dáta, ktoré neboli súčasťou tréningu modelu.

VIII. ZÁVER

Zameriavalo sa na vývoj lineárneho modelu neurónovej siete a hodnotenie jeho klasifikačnej presnosti pri spracovaní signálov čiastkových výbojov, ktoré boli reprezentované vo forme škálogramov statorových cievok. Celkovo boli analyzované štyri známe kategórie, zodpovedajúce dvom rôznym statorovým cievkam, na ktorých boli čiastkové výboje merané pri rôznych úrovniach napätia. Počas tvorby štruktúry lineárneho modelu bol sledovaný priebeh tréningu a hodnotenie jeho klasifikačnej presnosti pri spracovaní signálov čiastkových výbojov, ktoré boli reprezentované vo forme škálogramov statorových cievok. Celkovo boli analyzované štyri známe kategórie, zodpovedajúce dvom rôznym statorovým cievkam, na ktorých boli čiastkové výboje merané pri rôznych úrovniach napätia. Počas tvorby štruktúry lineárneho modelu bol sledovaný priebeh tréningu a hodnotenie jeho klasifikačnej presnosti pri spracovaní signálov čiastkových výbojov, ktoré boli reprezentované vo forme škálogramov statorových cievok. Celkovo boli analyzované štyri známe kategórie, zodpovedajúce dvom rôznym statorovým cievkam, na ktorých boli čiastkové výboje merané pri rôznych úrovniach napätia. Počas tvorby štruktúry lineárneho modelu bol sledovaný priebeh tréningu a hodnotenie jeho klasifikačnej presnosti pri spracovaní signálov čiastkových výbojov, ktoré boli reprezentované vo forme škálogramov statorových cievok.

tisíc vzoriek, zatiaľ čo v našom prípade ich bolo len 436. Z hľadiska porovnania optimálneho množstva tréningových dát s našimi, možno dosiahnutú presnosť modelu považovať za relatívne vysokú, nie však dostatočnú. Postupným tréningom modelu sa dosiahlo jeho obmedzenie, pri ktorom zvyšovanie počtu epoch už nevedlo k zlepšeniu presnosti, ale naopak k preučeniu. Na zníženie tohto rizika by bolo vhodné implementovať do súčasného lineárneho modelu aj predtréningové modely na optimálnejšie rozloženie tréningových váh vzoriek.

Pri samostatnej analýze jednotlivých validačných vzoriek výsledky potvrdili presnosť podobnú tej z tréningovej krivky (Obr. 8). Model však nedokázal rozlíšiť triedy Cievka – Biely náter 3.5 kV a Cievka – Biely náter 5 kV (Obr. 10). Tento problém pravdepodobne súvisí s tým, že daná cievka neobsahovala polovodivý náter, v dôsledku čoho sa rozdiel v napäťových úrovniach menej výrazne prejavil v škálogramoch. Na druhej strane, pri cievke s polovodivým náterom teda Cievka – Hnedý náter bol model schopný efektívnejšie rozpoznať rozdiely medzi triedami, a to aj pri menšom rozdieli aplikovaného napätia.

Pri verifikačnom hodnotení na neznámych škálogramoch, ktoré neboli súčasťou tréningovej ani validačnej množiny, došlo v porovnaní s validačnou presnosťou k výraznému poklesu predikčnej výkonnosti. Správne klasifikácie dosiahli len približne 44 %, zatiaľ čo v prípadoch, kde presnosť klesla na približne 35 %, model nedokázal poskytovať spoľahlivé predikcie. Na základe týchto zistení možno konštatovať, že vytvorený lineárny model nie je schopný dostatočne presnej a spoľahlivej klasifikácie čiastkových výbojov na statorových cievkach, spracovaných vo forme škálogramov pomocou Waveletovej transformácie. Na dosiahnutie spoľahlivejšej klasifikácie by boli potrebné výrazné zlepšenia. Najdôležitejším krokom by bol prechod na konvolučnú neurónovú sieť, ktorá spracúva vstupy hierarchicky, analyzuje lokálne črty a identifikuje dôležité oblasti reprezentujúce

jednotlivé triedy. Takýto model by zároveň umožnil integráciu dodatočných algoritmických funkcií, ktoré by zlepšili rozpoznávanie vzorov a generalizáciu na neznáme vstupy. Napriek svojim obmedzeniam môže vytvorený lineárny model slúžiť ako východiskový bod a referenčný základ pre vývoj pokročilejších architektúr neurónových sietí určených na klasifikáciu čiastkových výbojov na základe škálogramov.

LITERATÚRA

- [1] KOLCUNOVÁ, I. – MILAN, K.: Meranie výbojovej činnosti v statorovej izolácii elektrických strojov točivých. 1. vyd. Košice: TU, 2011. 128 s. ISBN 978-80-553-0778-7.
- [2] GOODFELLOW, I. – BENGIO, Y. – COURVILLE, A.: Deep Learning. Cambridge, MA: MIT Press, 2016. ISBN 978-0-262-03561-3, DOI: <https://www.deeplearningbook.org/>.
- [3] BARRIOS, S. – BULDAIN, D. – COMECH, M. P. – GILBERT, I. – ORUE, I.: Partial Discharge Classification Using Deep Learning Methods—Survey of Recent Progress. *Energies*, vol. 12, no. 13, 2485, 2019. DOI: <https://doi.org/10.3390/en12132485>.
- [4] ZIMMERMANN, J.: Spektrálna skladba segmentov rečového signálu. DOI: https://www.ff.unipo.sk/jak/2_2010/zimmermann.pdf.
- [5] CHOLLET, F.: Deep learning v jazyku Python – knižnice Keras, TensorFlow. 2. vyd. Praha: 2023. 528 s. ISBN 978-80-271-5133-2.

ADRESY AUTOROV

Lubomír Pallaj, Technická Univerzita Košice, Katedra elektroenergetiky, Mäsiarska 74, Košice, SK 04210, Slovenská Republika, lubomir.pallaj@tuke.sk
Jaroslav Petráš, Technická Univerzita Košice, Katedra elektroenergetiky, Mäsiarska 74, Košice, SK 04210, Slovenská Republika, jaroslav.petras@tuke.sk
Ardian Hyseni, Technická Univerzita Košice, Katedra elektroenergetiky, Mäsiarska 74, Košice, SK 04210, Slovenská Republika, ardian.hyseni@tuke.sk
Matej Val'ko, Technická Univerzita Košice, Katedra elektroenergetiky, Mäsiarska 74, Košice, SK 04210, Slovenská Republika, matej.valko@tuke.sk