

Artificial Intelligence Approaches for Modeling and Analysis Fault in Power Distribution Networks

Seyed Mahmoud Hashemi

Faculty of Computer Engineering, Higher Education Institute of Kar, Qazvin, Iran

ABSTRACT

RESEARCH PAPER

Received: 2025-9-4

Accepted: 2025-12-22

KEYWORDS:

Fault Detection,
Fault Classification,
Power Distribution Network,
Adaptive Neuro-Fuzzy Inference
System,

¹ Corresponding author:

 sm_hashemi@kar.ac.ir

Background and Objectives: Fault of power distribution networks is based on the uncontrollable factors. Rapid approach to identification and localization of power network fault is critical to maintain system reliable. While traditional approaches use measurements from current and voltage transformers, this study proposes an artificial intelligence-driven approach for enhanced fault detection and analysis in power distribution networks. A custom-designed sensing prototype captured voltage and current data under simulated fault conditions, including short-circuit and open-circuit faults. The presented approach includes fundamental variables, such as fault type, sensor placement topology, and line distance, were rigorously controlled during data acquisition.

Methods: This paper presents two algorithms: an Artificial Neural Network (ANN) and an Adaptive Neuro-Fuzzy Inference System (ANFIS). Both used algorithms have many parameters that require to be tuned. While the values of these parameters affect on the performance, but the major target of this study is using of these algorithms. Steps of algorithms are described in the paper. The results of algorithms are shown with the used data. Performance was validated under variable load conditions across line distances of 200–800 meters.

Finding: Simulation results demonstrate that the ANFIS classifier achieved superior accuracy in fault classification (99.7%) and minimal distance estimation error (0.5%). Both ANN and ANFIS delivered high precision in fault detection, localization, and classification, with ANFIS exhibiting significantly faster training convergence (1 ms). Indeed ANFIS has more consistency.

Conclusion: The framework presents a robust, computationally efficient solution for real-time fault management (modeling), recommending (analysis) the integration of dedicated sensors by power distribution network utilities to enable targeted grid interventions.

Copyright © Author(s).



نشریه تخصصی آرمان پردازش، دوره ۶، شماره ۳، سال ۱۴۰۴

فصلنامه تخصصی آرمان پردازش
(APJ)Homepage: www.armanprocessjournal.ir

روشهای هوش مصنوعی برای مدلسازی و تحلیل خطا در شبکه های توزیع قدرت

سید محمود هاشمی

گروه مهندسی کامپیوتر، موسسه آموزش عالی کار، قزوین، ایران

چکیده

پیشینه و اهداف: خطا در شبکه های توزیع قدرت بر اساس پارامترهای غیرقابل کنترل بوجود می آید. روش سریعی که قادر به شناسایی و مکانیابی خطای شبکه های توزیع قدرت باشد برای نگهداری مطمئن این شبکه ها حیاتی است. روشهای معمول با اندازه گیری ولتاژ انتقال دهنده ها کار می کنند اما روش پیشنهادی استفاده از الگوریتمهای هوش مصنوعی برای تشخیص و تحلیل خطا در شبکه های توزیع قدرت است. مجموعه ای از حسگرها برای دریافت ولتاژ و سایر داده ها تحت شرایط شبیه سازی استفاده شده است که شامل خطا در مدارات کوتاه و مدارات باز است. روش پیشنهادی شامل متغیرهای اساسی مانند: نوع خطا، معماری جایگزاری حسگر و فاصله است که بوسیله داده های اخذ شده کنترل می شوند.

روشها: این مقاله دو الگوریتم را نمایش می دهد: یک شبکه عصبی مصنوعی و یک سیستم استنتاج انطباقی فازی-عصبی. هر دوی این الگوریتمها دارای پارامترهای زیادی هستند که نیاز به تنظیم دارند. هرچند مقدار هر کدام از آنها بر روی کارایی تاثیر می گذارد ولی هدف اصلی این مقاله نحوه استفاده از الگوریتمها است. مراحل الگوریتمها در مقاله توضیح داده شده است. نتایج الگوریتمها به همراه داده های استفاده شده نشان داده شده است. کارایی بدست آمده تحت متغیرهای شرایطی فراخوانده شده در فاصله ۲۰۰ تا ۸۰۰ متری قابل اعتبار هستند.

یافته ها: نتایج شبیه سازی نشان می دهد که طبقه بندی ANFIS دارای درستی بهتری در طبقه بندی (۹۷٪) و خطای کمتری در تقریب فاصله (۰،۵٪) است. هر دو الگوریتم ANN و ANFIS بسیار سریع آموزش می بینند (۱ms) بعلاوه ANFIS پایداری بیشتری دارد. نتایج حاصل از این یافته ها، با یکدیگر مقایسه شده است.

نتیجه گیری: طرحی که نمایش داده شده است مقاوم، قابل محاسبه خطا در سیستمهای مدیریت بلادرنگ و قابل تجمیع حسگرها در یک شبکه توزیع قدرت را دارد.

مقاله پژوهشی

واژگان کلیدی:

تشخیص خطا، طبقه بندی خطا، شبکه توزیع قدرت، سیستم استنتاج تطابقی فازی-عصبی

۱. مقدمه

جامعه مدرن اساساً برای خدمات ضروری مراقبت‌های بهداشتی، حمل و نقل و خدمات صنعتی به شبکه‌های برق قابل اعتماد وابسته است. با افزایش سن زیرساخت‌های انرژی و مواجهه با تهدیدات فزاینده ناشی از بلایای طبیعی و اختلالات ناشی از فعالیت‌های انسانی، آسیب‌پذیری این شبکه‌های به هم پیوسته - به ویژه سیستم‌های توزیع ولتاژ پایین - به یک نگرانی ملی مبرم تبدیل شده است. شبکه برق، شامل اجزای تولید، انتقال ولتاژ بالا و توزیع ولتاژ پایین، برق را از تولیدکنندگان به کاربران نهایی می‌رساند. شبکه‌های توزیع ثانویه (که در حدود ۰,۴ کیلوولت تا ۱۱ کیلوولت کار می‌کنند) به دلیل نزدیکی به خطرات زیست‌محیطی، تعاملات حیات وحش، فعالیت‌های انسانی و بارهای متغیر، به ویژه در معرض اختلالات هستند.

محافظت از این سیستم‌های پراکنده و پیچیده جغرافیایی نیاز به تشخیص سریع خطا، جداسازی و بازیابی برای به حداقل رساندن آسیب و وقفه در سرویس دارد (Vidya, 2018). با این حال، مکان‌یابی سریع و دقیق خطا به دلیل توپولوژی‌های پیچیده شبکه و عدم قطعیت‌های عملیاتی همچنان چالش برانگیز است (Voziki et al., 2022).

روش‌های سنتی مکان‌یابی خطا مانند گشت‌زنی یا تکنیک‌های مبتنی بر امیدانس اکنون برای استانداردهای قابلیت اطمینان مدرن بسیار کند تلقی می‌شوند. طرح‌های حفاظتی مرسوم، اگرچه ضروری هستند، اما می‌توانند به دلیل مسائل مربوط به تعمیر و نگهداری مانند تعویض نادرست فیوز یا اتصال زمین ضعیف، تضعیف شوند (De La Cruz و همکاران، ۲۰۲۳). یک چارچوب حفاظتی قوی باید قابلیت اطمینان و امنیت را در تمام سناریوهای خطا حفظ کند (Alayande و همکاران، ۲۰۲۱). بنابراین، روش‌های سریع و دقیق تشخیص، مکان‌یابی و طبقه‌بندی خطا (FDLC) برای کاهش فرکانس و مدت زمان خاموشی ضروری شده‌اند (Özdemir و همکاران، ۲۰۲۵).

ظهور «شبکه‌های توزیع هوشمند» حسگرهای یکپارچه، پروتکل‌های ارتباطی پیشرفته و تجزیه و تحلیل داده‌های بلادرنگ را معرفی کرده است که امکان نظارت بر ولتاژ و جریان توزیع‌شده، کاهش خودکار خطا و تسریع گردش کار بازیابی را فراهم می‌کند (المسعودی، ۲۰۲۳). بررسی‌های تحقیقاتی بر دستاوردهای قابل توجه در کاهش قطعی برق و افزایش تاب‌آوری خطا از طریق اتوماسیون شبکه هوشمند تأکید دارند (لیانگ و همکاران، ۲۰۲۴؛ چاندا و سلطانی، ۲۰۲۳).

پیشرفت‌های اخیر در روش‌های FDLC مبتنی بر هوش مصنوعی شامل شبکه‌های عصبی عمیق، مکانیسم‌های توجه گراف و استخراج ویژگی تبدیل موجک است. مدل‌های کانولوشن و بازگشتی (مانند CNNها، LSTMها) دقت بالایی را در

طبقه‌بندی و مکان‌یابی خطا در شبکه‌های هوشمند نشان داده‌اند، اما به داده‌های آموزشی با کیفیت بالا و منابع محاسباتی قابل توجهی نیاز دارند (چاندا و سلطانی، ۲۰۲۳؛ بنگ و همکاران، ۲۰۲۲). شبکه‌های عصبی گراف (GNNها)، به ویژه مدل‌های GAT با توجه چند سر، نویدبخش ثبت تغییرات توپولوژیکی و وابستگی‌های متقابل غیرخطی در شبکه‌های توزیع هستند (باسکار و سلوام، ۲۰۲۰؛ میرشکالی و همکاران، ۲۰۲۲؛ رحمان و همکاران، ۲۰۲۱).

این مطالعه یک چارچوب مبتنی بر هوش مصنوعی برای تشخیص، طبقه‌بندی و مکان‌یابی خطا در زمان واقعی در شبکه‌های توزیع برق ثانویه که بین ۰,۴ کیلوولت و ۱۱ کیلوولت کار می‌کنند، ارائه می‌دهد. سیستم پیشنهادی، یک ماژول حسگر سفارشی را با مدل‌های یادگیری ماشین، به ویژه شبکه‌های عصبی مصنوعی (ANN) و سیستم‌های استنتاج عصبی-فازی تطبیقی (ANFIS)، برای افزایش دقت تشخیصی و زمان پاسخ، ادغام می‌کند. متغیرهای عملیاتی اساسی شامل نوع خطا (اتصال کوتاه و مدار باز)، توپولوژی قرارگیری حسگر و طول فیدر از ۲۰۰ متر تا ۸۰۰ متر به طور سیستماتیک برای اطمینان از استحکام و کاربردپذیری در نظر گرفته شده‌اند. این طراحی به چندین محدودیت در مطالعات موجود، مانند اتکا به داده‌های سطح پست، اعتبارسنجی ناکافی عملکرد تحت شرایط بار و مکانی متغیر، و کاربرد محدود در سناریوهای خطای سطح توزیع، می‌پردازد. عملکرد مدل از طریق شبیه‌سازی‌های MATLAB/Simulink روی یک شبکه ۴۱۵ ولتی که از روی یک فیدر واقعی مدل‌سازی شده بود، ارزیابی شده است. از داده‌های خطای مصنوعی برای آموزش و آزمایش استفاده شده است. ANFIS با دقت طبقه‌بندی ۹۹,۷٪، خطای محلی‌سازی ۰,۵٪ و زمان همگرایی ۱ میلی‌ثانیه تحت پروفایل‌های بار پویا، به نتایج برتری دست یافته است. این نتایج، پتانسیل این چارچوب را برای مدیریت دقیق و با تأخیر کم خطا در شبکه‌های توزیع مدرن برجسته می‌کند.

۲. پیشینه پژوهش

روش‌های سنتی تشخیص، مکان‌یابی و طبقه‌بندی خطا (FDLC) در سیستم‌های قدرت به شدت به محاسبات مبتنی بر امیدانس، تبدیل موجک و گشت‌های دستی متکی هستند که محدودیت‌هایی در سرعت، سازگاری با شرایط پویای شبکه و مقیاس‌پذیری برای شبکه‌های توزیع پیچیده نشان می‌دهند (Voziki و همکاران، ۲۰۲۲؛ De La Cruz و همکاران، ۲۰۲۳). تکنیک‌های هوش مصنوعی (AI)، به ویژه شبکه‌های عصبی مصنوعی (ANNs)، به عنوان جایگزین‌های قوی ظهور کرده‌اند. به عنوان مثال، (Thukaram 2004) شناسایی خطای

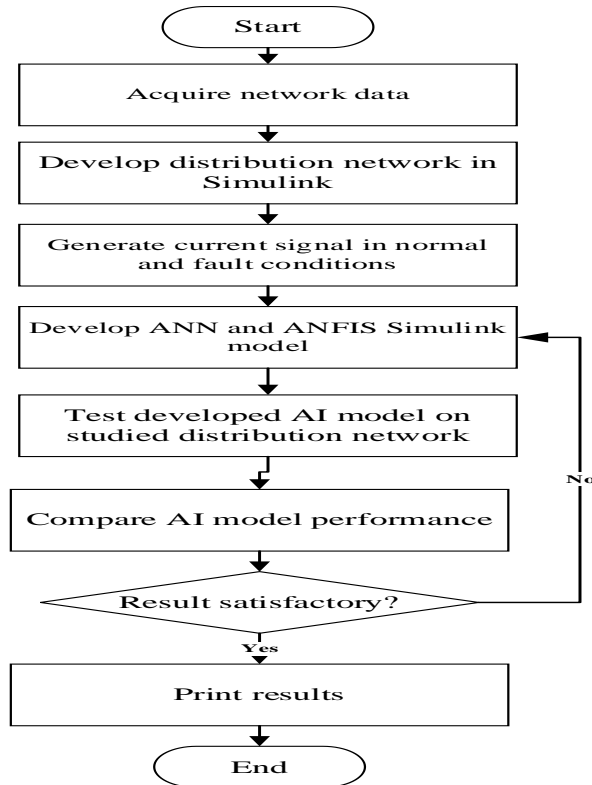
MATLAB/Simulink مدل‌سازی شد که از طریق ترانسفورماتورهای کاهنده از منابع ۳۳/۱۱ کیلوولت تغذیه می‌شد. این شبکه شامل سه بار متعادل بود و از مدارشکن‌ها برای جداسازی خطا استفاده می‌کرد تا از خرابی‌های آبشاری جلوگیری شود. سیگنال‌های ولتاژ و جریان در طول عملیات عادی ثبت شدند و خطاهای سه فاز را شبیه‌سازی کردند. این مجموعه داده‌ها، دو مدل هوش مصنوعی، شامل یک ANN و یک ANFIS، را برای تشخیص، طبقه‌بندی و مکان‌یابی خطا در زمان واقعی آموزش دادند. اعتبارسنجی مدل، قابلیت پیش‌بینی آنها را در شناسایی وقوع خطا و دسته‌بندی انواع خطا در شبکه توزیع تأیید کرد. شکل ۱ نمودار جریانی را نشان می‌دهد که خلاصه‌ای از روش تحقیق را نشان می‌دهد.

دو مجموعه داده در این مطالعه مورد استفاده قرار گرفت. مجموعه داده اول شامل اطلاعات شبکه سیستم قدرت به‌دست‌آمده از فیدر Ayobo شرکت توزیع برق Ikeja بود. مجموعه داده دوم برای توسعه مدل‌های ANN و سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) به کار گرفته شد. این مجموعه داده از شبیه‌سازی‌های شبکه سیستم قدرت انجام شده در MATLAB/Simulink استخراج شده است. سیگنال‌های جریان و ولتاژ در طول شبیه‌سازی برای هر کلاس خطا تولید شده و متعاقباً به عنوان ویژگی‌های ورودی برای آموزش و اعتبارسنجی مدل‌های ANN و ANFIS استفاده شدند. روش شبیه‌سازی در شکل ۲ نشان داده شده است.

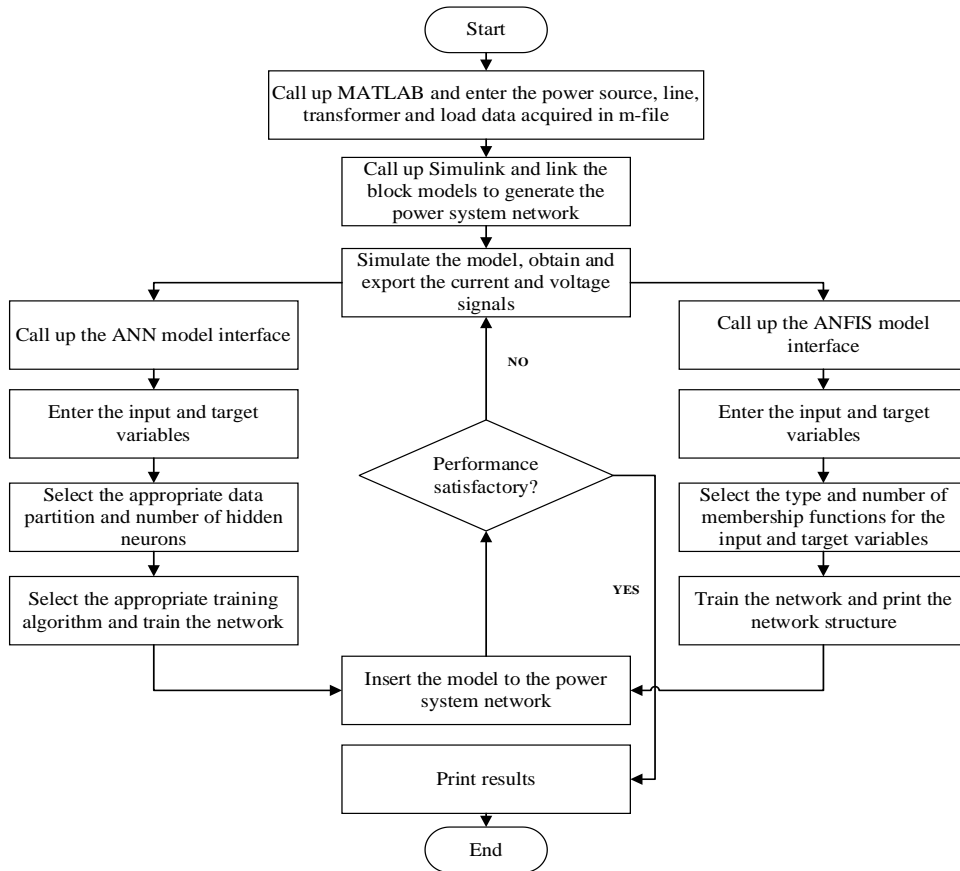
مبتنی بر ANN را با استفاده از داده‌های پست برق نشان داد، اگرچه ادغام حسگر سطح میدان را نادیده گرفت، در حالی که Alayande و همکاران (۲۰۲۰) به دقت آزمایش ۱۰۰٪ برای خطاهای نامتقارن دست یافتند اما فاقد اعتبارسنجی در بارها و فواصل متغیر بودند. برای افزایش قابلیت تفسیر و مدیریت عدم قطعیت، ANFIS قابلیت یادگیری ANN را با استدلال منطقی فازی ترکیب کرد، همانطور که توسط Zhang و همکاران (۲۰۱۳) برای طبقه‌بندی خطای توزیع و Mohamed و همکاران تأیید شد. (۲۰۲۱) برای تشخیص موتور، با این حال این مطالعات محدودیت‌های استقرار در زمان واقعی را نادیده گرفته‌اند. پیشرفت‌های اخیر شامل GNNها برای شناسایی بخش خطا با آگاهی از توپولوژی (دقت ۹۸٫۳٪، Ngo و همکاران، ۲۰۲۱)، هیبریدهای CNN-SVM برای مقاومت در برابر نویز (دقت ۹۷٫۶٪، Thomas و همکاران، ۲۰۲۳) و یادگیری فدرال برای حفظ حریم خصوصی (Wu و همکاران، ۲۰۲۳) است. با این حال، این روش‌ها از شدت محاسبات، تأخیر (< ۴۵ میلی‌ثانیه) یا هزینه‌های سخت‌افزاری بالا رنج می‌برند (Dana و همکاران، ۲۰۲۲). با وجود پیشرفت، شکاف‌هایی در FDLC مقرون‌به‌صرفه و در زمان واقعی برای شبکه‌های توزیع ثانویه تحت شرایط عملیاتی پویا وجود دارد. این شکاف توسط چارچوب یکپارچه ANN-ANFIS این مطالعه، که از حسگرهای سازگار با لبه و اعتبارسنجی بار متغیر استفاده می‌کند، برطرف شده است.

۳. شیوه تحقیق

این تحقیق یک چارچوب مدیریت خطای مبتنی بر هوش مصنوعی برای شبکه‌های توزیع سه فاز توسعه داد. یک سیستم توزیع ۴۱۵ ولت (خط به خط، فاز به نول ۰٫۲۴ کیلوولت) در



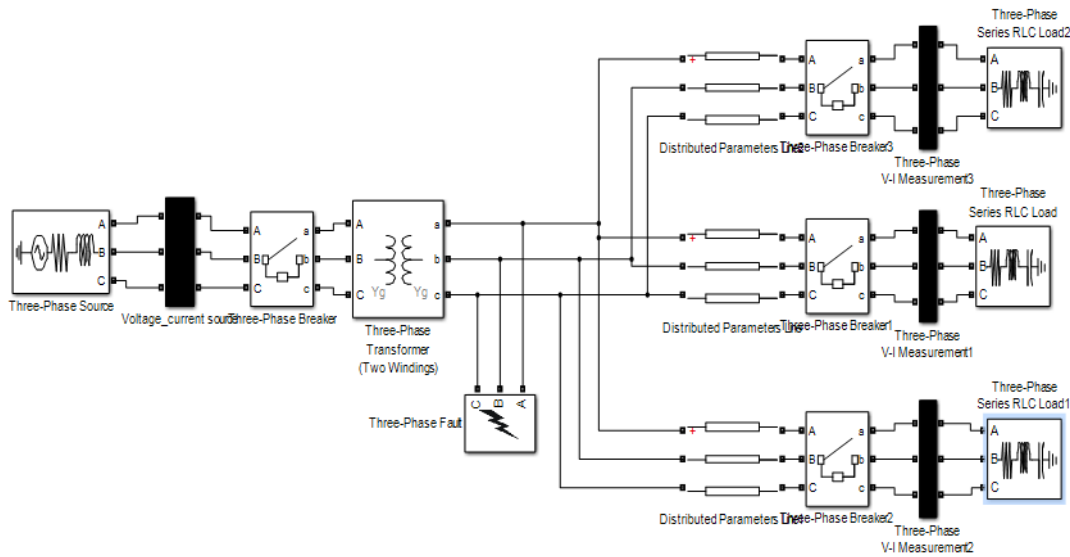
شکل ۱. نمودار جریان روش تحقیق



شکل ۲. روش شبیه سازی

روشی که در شکل ۲ نشان داده شده است، با تصاویری از رابط MATLAB/Simulink در بخش‌های بعدی توضیح داده شده است. اجزای سیستم شامل یک منبع ولتاژ سه فاز (که نشان دهنده منبع تغذیه از منبع الکتریکی کتابخانه است)، یک بار سه فاز، یک خط توزیع، یک ترانسفورماتور سه فاز و یک بریکر سه فاز (که به عنوان سوئیچ نیز عمل می‌کند) بود. یک بلوک خطای

سه فاز نیز برای شبیه‌سازی شرایط خطا گنجانده شد؛ این اجزا از کتابخانه عناصر الکتریکی Simscape انتخاب شدند. اندازه‌گیری‌های ولتاژ و جریان با استفاده از یک بلوک اندازه‌گیری ولتاژ-جریان سه فاز از بخش اندازه‌گیری کتابخانه به دست آمد. مدل شبیه‌سازی، متشکل از تمام اجزای الکتریکی مورد نیاز، در شکل ۳ نشان داده شده است.



شکل ۳. مدل شبیه‌سازی الکتریکی

جریان و داده‌های سیگنال ولتاژ که از مدل Simulink شبکه سیستم قدرت به محیط MATLAB صادر شده بودند، برای تولید مدل‌ها استفاده شدند. داده‌های جدول ۱، داده‌های سیگنال جریان مورد استفاده برای تجزیه و تحلیل هستند.

دو مدل هوش مصنوعی برای تشخیص و طبقه‌بندی خطا مورد استفاده قرار گرفتند. این مدل‌ها، مدل ANN و سیستم ANFIS بودند. سه مدل برای قرار دادن به عنوان حسگر در هر یک از ایستگاه‌های بار توسعه داده شدند. داده‌های سیگنال

جدول ۱. داده‌های سیگنال

Load station	Phases	Current signal for each fault class (A)				
		Normal condition	Single-phase fault	Double phase fault		Double phase fault (line-to-line)
			Ag	Bg		
Load station 1	A-g	59.3	204.6	56.6	55.5	54.5
	B-g	58.2	60.1	206.1	58.7	60.3
	AB-g	57.6	58.7	60.3	211.1	57.9
	AB	58.4	56.4	61.1	51.6	212.8
	Classification Code	0	1	2	3	4
Load station 2	A-g	55.92	211.31	60.09	57.77	61.32
	B-g	58.23	58.88	202.1	59.21	60.41
	AB-g	59.12	62.07	55.67	211.31	59.77
	AB	61.04	54.33	58.24	56.11	231.44
	Classification Code	0	1	2	3	4
Load station 3	A-g	61.31	203.31	59.97	62.92	55.98
	B-g	56.72	62.41	227.97	58.90	62.19

Load station	Phases	Current signal for each fault class (A)				
		Normal condition	Single-phase fault	Double phase fault	Double phase fault (line-to-line)	
			Ag	Bg		
	AB-g	60.11	58.81	57.75	212.31	59.50
	AB	55.79	61.19	60.88	62.21	204.47
	Classification Code	0	1	2	3	4
Source station	A-g	57.13	220.1164.3	56.14	59.31	55.59
	B-g	51.33		232.15	65.51	60.33
	AB-g	54.31	59.41	56.41	226.41	61.31
	AB	61.33	58.13	61.33	62.14	0
	Classification Code	0	1	2	3	4

جدول ۲. سیگنال ولتاژ

Load station	Phases	Voltage signal for each fault class (V)				
		Normal condition	Single-phase fault	Double phase fault	Double phase fault (line-to-line)	
			A-g	B-g		
Load station 1	A-g	218.81	434.28	214.33	224.49	226.54
	B-g	219.37	222.31	421.47	219.97	220.01
	AB-g	220.41	218.17	220.97	424.32	223.32
	AB	221.31	227.39	217.01	216.98	431.97
	Classification Code	0	1	2	3	4
Load station 2	A-g	223.98	434.19	222.21	215.09	220.01
	B-g	214.99	219.21	431.76	220.56	219.25
	AB-g	221.81	225.65	218.73	413.43	221.38
	AB	220.33	219.92	223.33	224.09	217.90
	Classification Code	0	1	2	3	4
Load station 3	A-g	223.98	410.32	216.17	220.22	222.61
	B-g	220.11	221.90	442.34	217.31	216.33
	AB-g	218.33	219.01	221.24	443.39	228.31
	AB	220.18	220.88	216.99	225.34	221.67
	Classification Code	0	1	2	3	4
Source station	A-G	221	421.16	216.3	217.31	221.19
	B-G	217	203.44	433.10	221.33	212.65
	AB-g	215	213.17	215.66	212.47	214.31
	AB	417	415.22	413.45	412.37	0
	Classification Code	0	1	2	3	4

۴. توسعه شبکه عصبی

مدل هوش مصنوعی برای تشخیص و طبقه‌بندی خطا استفاده شد. این مدل‌ها، مدل ANN و سیستم ANFIS بودند. سه مدل از این مدل‌ها برای قرار دادن به عنوان حسگر در هر یک از ایستگاه‌های بار توسعه داده شدند. داده‌های سیگنال جریان و داده‌های سیگنال ولتاژ صادر شده از مدل Simulink شبکه سیستم قدرت به محیط MATLAB برای تولید مدل‌ها

بر اساس کدهای طبقه‌بندی در جداول ۱ و ۲، عدد ۰ نشان‌دهنده عملکرد عادی سیستم است. در مقابل، مقادیر ۱ و ۲ به ترتیب مربوط به خطاهای تک فاز در فازهای قرمز و زرد هستند. مقدار ۳ نشان‌دهنده خطای دو فاز و ۴ نشان‌دهنده خطای خط به خط است. در توسعه مدل‌های هوش مصنوعی، طبقه‌بندی خطاها به عنوان متغیرهای ورودی استفاده شدند، در حالی که کدهای طبقه‌بندی مربوطه به عنوان متغیرهای خروجی عمل کردند.

ویژگی ورودی (مربوط به کلاس های خطا) و یک گره خروجی واحد بود که نشان دهنده برچسب طبقه بندی است.

مرحله ۳: آموزش شبکه

مدل ANN با استفاده از الگوریتم پس انتشار -Levenberg-Marquardt آموزش داده شد که به دلیل ویژگی های همگرایی سریع و مناسب بودن آن برای مسائل تقریب تابع انتخاب شده بود. آموزش در یک محیط یادگیری تحت نظارت استاندارد انجام شد، جایی که مدل به صورت تکراری وزن ها را بر اساس کمینه سازی میانگین مربعات خطا (MSE) بین خروجی های پیش بینی شده و واقعی تنظیم می کرد.

مرحله ۴: یکپارچه سازی در سیمولینک

پس از آموزش، مدل ANN به عنوان یک بلوک برای سازگاری شبیه سازی در زمان واقعی، صادر و در سیمولینک ادغام شد. این امر امکان ادغام یکپارچه ANN آموزش دیده در مدل سطح سیستم شبکه توزیع برق را فراهم کرد.

مرحله ۵: پیاده سازی مدل در شبکه توزیع

بلوک ANN آموزش دیده در سیمولینک در مدل شبیه سازی شبکه توزیع برق ثانویه تعبیه شد. این پیاده سازی به ANN آموزش دیده اجازه داد تا با استفاده از ورودی های سیگنال ولتاژ و جریان ورودی از سیستم، خطاها را در زمان واقعی طبقه بندی کند. این چارچوب، تشخیص و طبقه بندی سریع خطا را در طول شبیه سازی تسهیل کرد و با الزامات عملیاتی دنیای واقعی که در شکل ۴ نشان داده شده است، همسو شد.

استفاده شدند. داده های نشان داده شده در جدول ۱، داده های سیگنال جریان مورد استفاده برای تجزیه و تحلیل هستند. مراحل مورد استفاده برای تولید مدل ANN در این بخش شرح داده شده است.

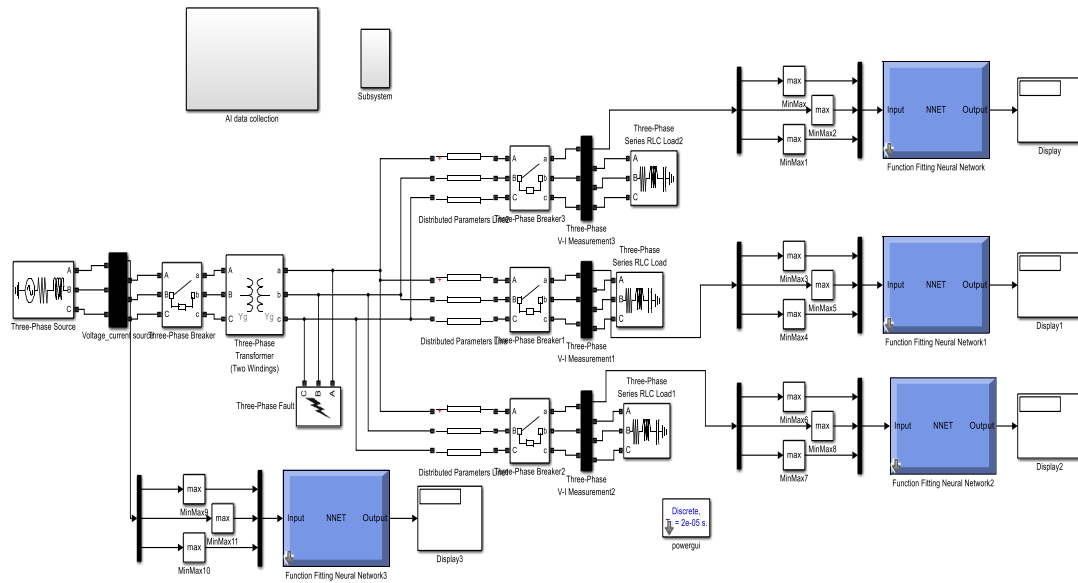
مرحله ۱: فراخوانی رابط کاربری گرافیکی (ANN GUI) و انتخاب داده های ورودی و خروجی

این کار با وارد کردن و اجرای 'nftool' در پنجره فرمان MATLAB انجام شد. تصویر کلی از رابط ANN.

داده های ورودی شامل مقادیر سیگنال جریان برای یک مدل و مقادیر سیگنال ولتاژ برای یک مدل جداگانه بود که هر کدام مربوط به کلاس های مختلف خطا بودند. داده های خروجی که در هر دو مدل مشترک بودند، شامل کدهای طبقه بندی بودند که شرایط خطا را نشان می دادند.

مرحله ۲: تقسیم بندی مجموعه داده ها و انتخاب نوروں های پنهان

مجموعه داده های مورد استفاده در این مطالعه به ۷۰٪ برای آموزش، ۱۵٪ برای اعتبارسنجی و ۱۵٪ برای آزمایش تقسیم شد. این استراتژی تقسیم بندی به طور یکنواخت در هر دو مجموعه داده های سیگنال جریان و ولتاژ اعمال شد و اطمینان حاصل شد که شبکه عصبی مصنوعی (ANN) داده های کافی برای تعمیم و بهینه سازی عملکرد دارد. معماری مدل شامل چهار نوروں پنهان بود که پس از ارزیابی تجربی برای متعادل کردن پیچیدگی و دقت انتخاب شدند. پیکربندی ANN شامل سه



شکل ۴. الزامات عملیاتی در واقعیت

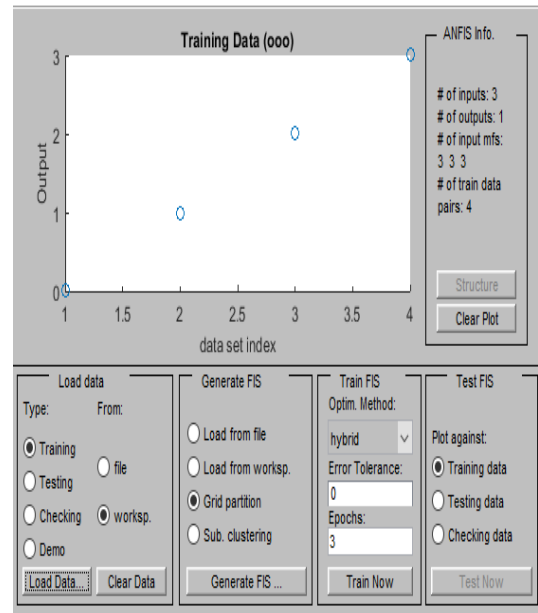
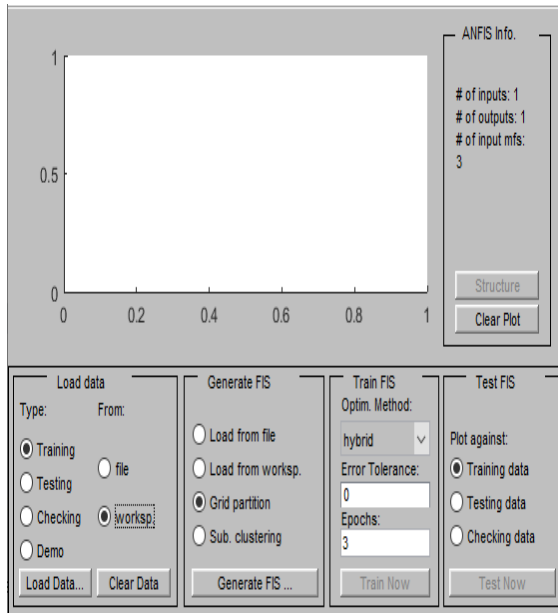
مرحله ۱: فراخوانی رابط کاربری گرافیکی ANFIS (GUI) و انتخاب داده‌های ورودی و خروجی

این کار با وارد کردن و اجرای 'anfisedit' در پنجره فرمان MATLAB انجام شد. تصویر رابط ANN در شکل ۵ نشان داده شده است. داده‌های ورودی از طریق آیکون 'worksp' وارد می‌شوند و نتیجه نیز نشان داده شده است.

اساس بلوک ANN تشخیص و طبقه‌بندی خطا طبق کد طبقه‌بندی جداول ۱ و ۲ و ارسال نتیجه به بلوک نمایش است.

تولید مدل ANFIS

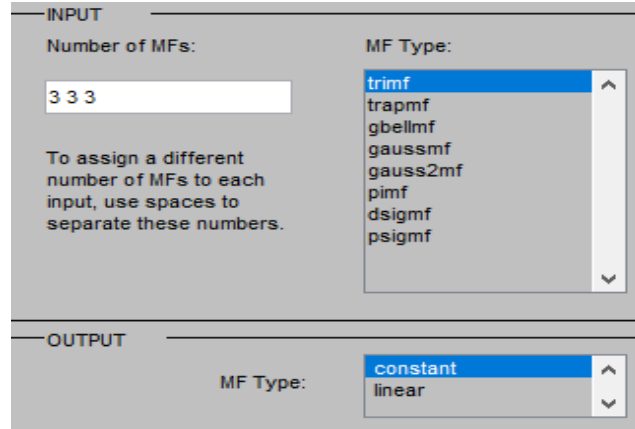
مراحل مورد استفاده برای تولید مدل ANFIS با داده‌های سیگنال جریان و ولتاژ در این بخش شرح داده شده است.



شکل ۵. رابط ANN

از گزارش شکل ۵، تعداد ورودی‌ها ۳ (کلاس خطای سیگنال جریان) و خروجی یکی (کد طبقه‌بندی) بود.

مرحله ۲: تولید سیستم استنتاج فازی (FIS) تصویر FIS در مدل ANFIS در شکل ۶ نشان داده شده.

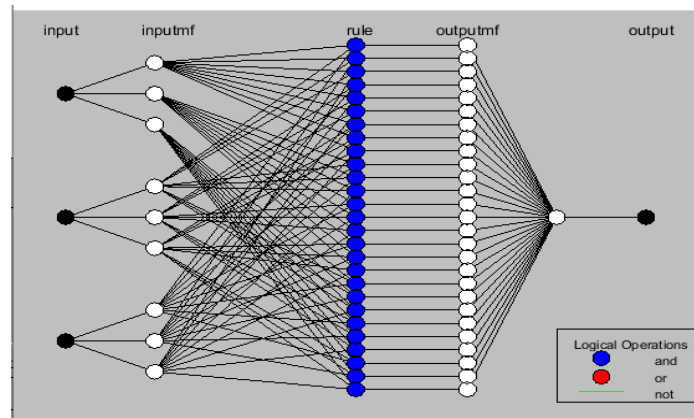


شکل ۶. تصویر FIS

شکل ۶ نشان می‌دهد که نوع تابع عضویت (MF) انتخاب شده برای متغیرهای ورودی، تابع عضویت مثلثی (trimf) بوده است. تابع عضویت انتخاب شده برای متغیر خروجی، MF خطی بوده است.

مرحله ۳: آموزش مدل

مدل ANFIS از طریق دکمه «آموزش اکنون» که در شکل ۵ نشان داده شده است، آموزش داده شد. ساختار ANFIS حاصل از آموزش در شکل ۷ نشان داده شده است.



شکل ۷. ساختار ANFIS

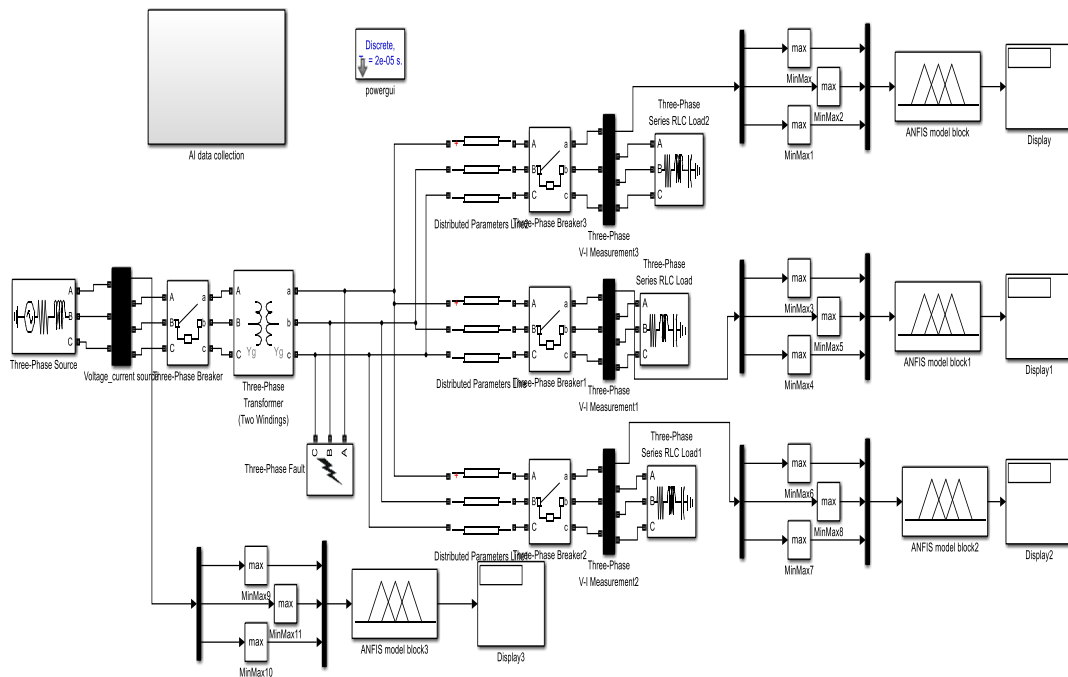
ساختار ANFIS در شکل ۷ نشان می‌دهد که سه ورودی وجود داشته است که هر کدام دارای سه تابع فازی (MF) هستند و هر تابع فازی نه قانون استنتاج مرتبط با هشتاد و یک تابع فازی از متغیر خروجی تولید می‌کند.

مرحله ۴: پیاده‌سازی مدل ANFIS در شبکه سیستم توزیع برق

برای دستیابی به این هدف، اولین فرآیند ذخیره مدل ANFIS بود (مدل با عنوان «بار ۱» ذخیره شد). مدل‌های ANFIS بار ۲ و بار ۳ تولید شدند، سه مدل ANFIS به بلوک سیمولینک فازی وارد شدند و بلوک مدل در مدل سیستم قدرت قرار داده

شد. مدل سیمولینک سیستم قدرت با مدل ANFIS در شکل

۸ نشان داده شده است.



شکل ۸. مدل سیمولینک

مرحله ۱: فاصله خطوط توزیع از منبع تا بار را بدست آورید و فاصله را به صورت تجمعی به چهار نقطه مساوی تقسیم کنید.

مرحله ۲: سیگنال جریان را با وارد کردن هر فاصله در یک خطای تک فاز تولید کنید.

فاصله خط توزیع و محل تقسیم در جدول ۳ نشان داده شده.

جدول ۳. فاصله خط توزیع

Distribution line distance	Load 1 (m)	Load 2 (m)	Load 3 (m)
Point 1	200	180	220
Point 2	400	360	440
Point 3	600	540	660
Point 4	800	720	880
Cumulative sum (actual distance of the distribution line)	800	720	880

نتیجه سیگنال جریان به دست آمده برای هر فاصله تجمعی در یک خطای تک فاز در جدول ۴ نشان داده شده است.

۵. مکان‌یابی خطا با مدل‌های هوش مصنوعی

مکان‌یابی خطا با هر دو مدل ANN و ANFIS روی خطوط توزیع انجام شد تا مدل‌های هوش مصنوعی جداگانه‌ای برای مکان‌های خطا تولید شود. مراحل تولید مدل‌ها برای مکان‌های خطا در مراحل زیر شرح داده شده است:

جدول ۴. نتیجه سیگنال جریان

Class of single-phase fault	Load 1			Load 2			Load 3		
	Distance (m)	Current (amps)	signal	Distance (m)	Current (amps)	signal	Distance (m)	Current (amps)	signal
Ag	200	401.09		180	449.15		220	390.87	
	400	389.77		360	440.13		440	383.93	
	600	385.22		540	433.32		660	381.29	
	800	380.17		720	431.56		880	380.97	
Bg	200	450.19		180	399.61		220	420.32	
	400	430.33		360	397.19		440	412.19	
	600	428.28		540	392.17		660	441.90	
	800	423.32		720	420.23		880	440.17	
Cg	200	410.33		180	421.37		220	398.71	
	400	398.819		360	403.4		440	389.43	
	600	400.12		540	400.31		660	387.33	
	800	387.19		720	420.23		880	381.41	

می‌کند. نتایج از طریق نمودارها و نمودارهایی که رفتارهای کلیدی سیستم، از جمله الگوهای سیگنال ولتاژ/جریان، دقت طبقه‌بندی خطا و پاسخ‌های مقایسه‌ای خطا را نشان می‌دهند، تجسم می‌شوند. این تجسم‌ها اثربخشی مدل‌ها را در شناسایی و طبقه‌بندی خطاها نشان می‌دهند، در حالی که تفسیرها نقاط قوت و محدودیت‌های عملی آنها را برای کاربردهای نظارت بر سیستم برق و تشخیص خطا برجسته می‌کنند.

نتیجه سیستم قدرت در شرایط عادی

شکل‌های ۹ و ۱۰ سیگنال جریان و ولتاژ شبکه سیستم قدرت را در شرایط عملیاتی عادی (بدون خطا) نشان می‌دهند. این شکل موج یک مبنای مرجع برای ارزیابی رفتار سیستم و تشخیص موارد غیرعادی هنگام بروز خطا است. تجزیه و تحلیل ویژگی‌های سیگنال جریان در طول عملکرد حالت پایدار، شناسایی انحرافات ناشی از سناریوهای مختلف خطا را در شبیه‌سازی‌های بعدی آسان‌تر می‌کند.

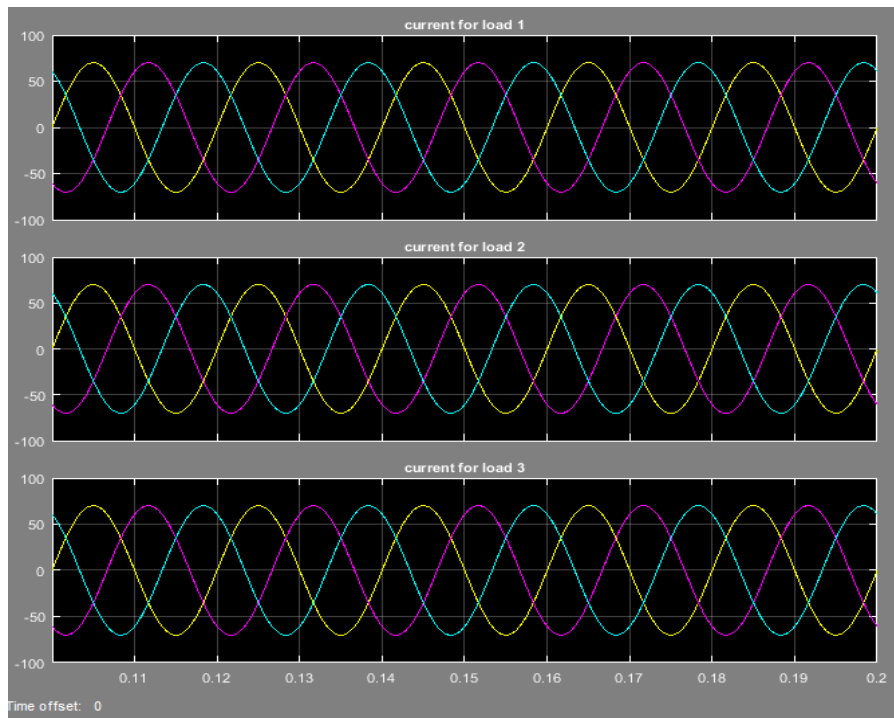
تک فاز به ترتیب برای Ag، Bg و Cg برابر با ۱، ۲ و ۳ بود.

مرحله ۳: داده‌های ورودی و هدف را برای مدل‌های هوش مصنوعی وارد کنید و شبکه را آموزش دهید.

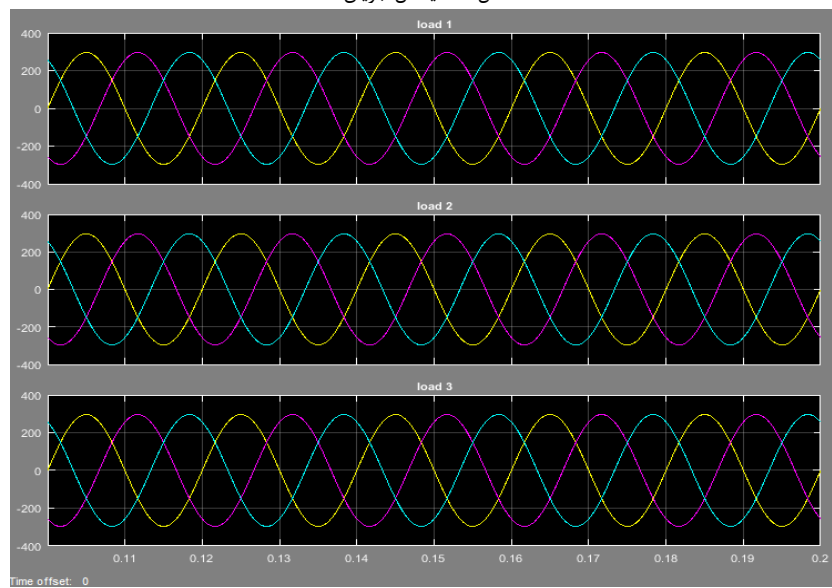
ورودی‌های مدل‌های هوش مصنوعی سیگنال‌های جریان بودند، در حالی که متغیر هدف مقادیر فاصله بودند. شرایط یکسانی برای طبقه‌بندی خطا در محل انتخاب شد و سیستم آموزش دید. مدل‌های هوش مصنوعی تولید شده در شبکه سیمولینک سیستم قدرت قرار داده شدند، همانطور که برای طبقه‌بندی خطا نشان داده شده در شکل ۴ برای ANN و شکل ۸ برای ANFIS انجام شد.

۶. نتایج و بحث

این بخش نتایج شبیه‌سازی را ارائه می‌دهد که عملکرد مدل‌های پیشنهادی (ANN و ANFIS) را تحت شرایط عملیاتی مختلف و سناریوهای خطا در یک شبکه توزیع برق ارزیابی

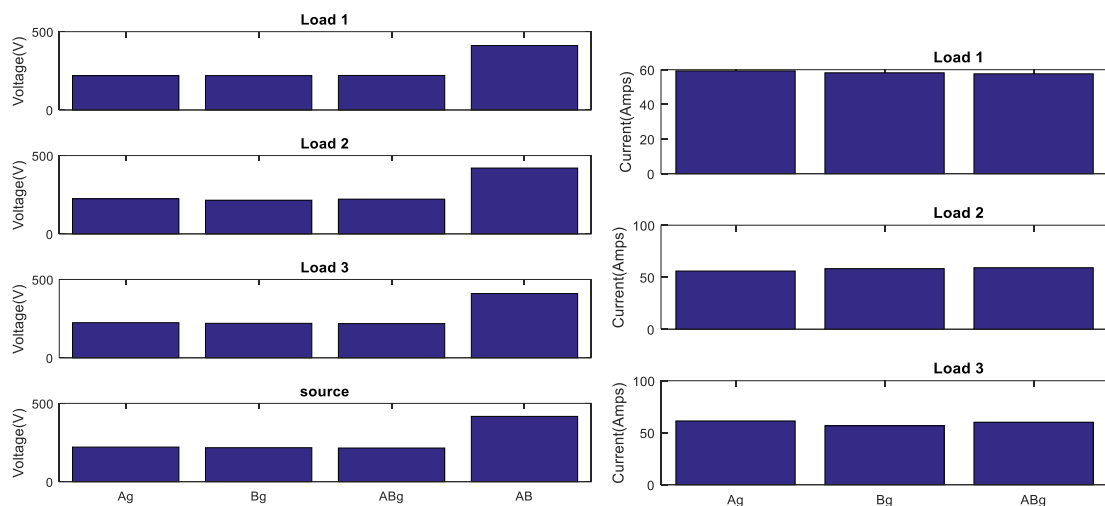


شکل ۹. سیگنال جریان



شکل ۱۰. سیگنال ولتاژ

سیگنال‌های جریان و ولتاژ در شرایط عادی که به MATLAB منتقل شده‌اند، در نمودار میله‌ای شکل ۱۱ نشان داده شده‌اند.




شکل ۱۱. نمودار میله ای سیگنالهای جریان و ولتاژ

سیگنال جریان برای هر بار بین ۲۳ آمپر و ۳۲ آمپر اندازه گیری شد، در حالی که سطح ولتاژ در هر بار بین ۲۱۰ ولت و ۲۳۰ ولت اندازه گیری شد.

آن را از سیگنال عملیاتی عادی قابل تشخیص می سازد. انحرافات مشاهده شده در الگوی جریان به عنوان ویژگی های ورودی حیاتی برای آموزش و اعتبارسنجی مدل های هوش مصنوعی توسعه یافته برای تشخیص و طبقه بندی خطا عمل می کنند.


نتایج سیستم قدرت در کلاس های مختلف خطا

شکل های ۱۲ و ۱۳ سیگنال های جریان و ولتاژ شبکه سیستم قدرت را در طول یک شرایط خطای تک فاز نشان می دهند. این شکل موج، اختلال ایجاد شده توسط خطا را برجسته می کند و




شکل ۱۲. سیگنال جریان در خطای تک فاز

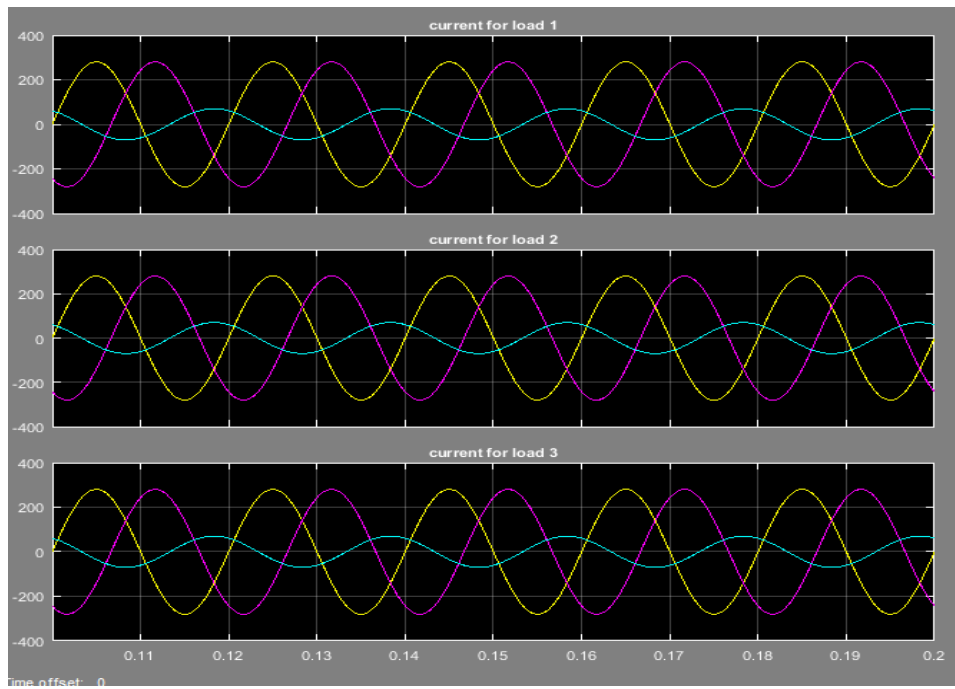
از شکل ۱۳ مشاهده می شود که یک خطای تک فاز در سیستم توزیع رخ داده است، زیرا افزایش سطح ولتاژ بالاتر از ۲۲۰ ولت معمولی در شبیه سازی ثبت شده است.




شکل ۱۳. سیگنال ولتاژ در خطای تک فاز
 سیگنال جریان در خطای تک فاز Ag به MATLAB منتقل و رسم شد و در شکل ۱۴ به صورت نمودار میله‌ای نشان داده شده است.



شکل ۱۴. نمودار میله ای سیگنال جریان در خطای تک فاز
 شکل‌های ۱۵ و ۱۶ سیگنال جریان و ولتاژ به دست آمده از شبکه سیستم قدرت را در طول شرایط خطای دو فاز نشان می‌دهند. شکل موج، اختلال ناشی از خطاهای همزمان در دو فاز را با انحرافات قابل توجه از الگوی سیگنال عادی منعکس می‌کند. این نوع خطا، اعوجاج پیچیده‌تری را در پروفایل جریان ایجاد می‌کند که برای آموزش و ارزیابی مدل‌های طبقه‌بندی خطای مبتنی بر هوش مصنوعی در تشخیص دقیق سناریوهای خطای چند فاز بسیار مهم است.




شکل ۱۵. سیگنال جریان در خطای دو فاز



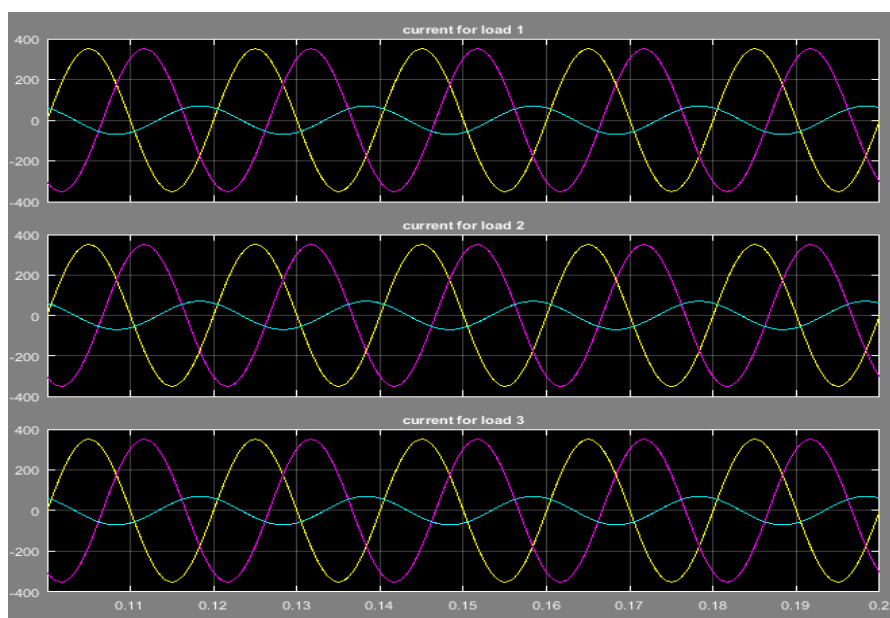
شکل ۱۶. سیگنال ولتاژ در خطای دو فاز

شکل ۱۷. نمودار میله ای سیگنال جریان در خطای دو فاز




تغییرات خطاهای تک فاز یا دو فاز متفاوت است و ویژگی‌های ارزشمندی را برای طبقه‌بندی خطا ارائه می‌دهد. این شکل موج در آموزش مدل‌های هوش مصنوعی برای شناسایی و تمایز دقیق خطاهای خط به خط از سایر انواع خطا، نقش مهمی دارد.

شکل‌های ۱۸ و ۱۹ سیگنال جریان و ولتاژ شبکه سیستم قدرت را در شرایط خطای خط به خط نشان می‌دهند. این نوع خطا، که شامل تماس مستقیم بین دو فاز است، منجر به اختلال در شکل موج جریان می‌شود. تغییرات مشاهده شده در سیگنال با



شکل ۱۸. سیگنال جریان در خطای خط به خط



شکل ۱۹. سیگنال ولتاژ در خطای خط به خط

آموزش داده شدند و در نتیجه قابلیت اطمینان سیستم را افزایش داده و زمان پاسخ را کاهش دادند.

پایاده سازی مدل های هوش مصنوعی در شبکه سیستم قدرت

جدول ۵ مقادیر تشخیص و طبقه بندی تعیین شده را در کنار پیش بینی های تولید شده توسط مدل های ANN و ANFIS ارائه می دهد. جدول نشان می دهد که چگونه هر مدل با شناسایی دقیق نوع خطا و اختصاص مقدار طبقه بندی مناسب، به سناریوهای مختلف خطا پاسخ می دهد. این مقایسه، اثربخشی و دقت هر دو مدل هوش مصنوعی را در تشخیص خودکار خطا در شبکه سیستم قدرت برجسته می کند.

سیگنال ولتاژ در شکل ۱۴، بزرگی بیشتری نسبت به خطای دو فاز به زمین در شکل ۱۷ نشان می دهد. وقوع خطا در شبکه سیستم قدرت منجر به افزایش ناگهانی در بزرگی سیگنال می شود که معمولاً به صورت یک جهش شدید در شکل موج جریان منعکس می شود. این وضعیت غیرطبیعی تا زمانی که مدارشکن عمل کند، ادامه می یابد و در آن نقطه سیگنال به صفر می رسد که نشان دهنده جداسازی بخش خطا دار است. مدل های هوش مصنوعی برای تقلید از رفتار رله های حفاظتی برای خودکار سازی فرآیند تشخیص و جداسازی خطا توسعه داده شدند. در این مطالعه، دو مدل هوشمند، ANN و ANFIS، برای تشخیص، طبقه بندی و پاسخ به شرایط مختلف خطا در زمان واقعی استفاده شدند. این مدل ها برای تشخیص علائم خطا و شروع اقدامات کنترلی مناسب، مانند باز یا بسته کردن بریکرها،

جدول ۵. طبقه بندی خطا

Fault class	Fault class code	ANN predicted code	ANFIS predicted code
Normal condition	0	0.014	0
Single-phase fault	1	0.9923	1
Double phase fault	2	2	2
Triple phase fault	3	3.001	3

جدول ۵ نشان می دهد که مدل ANFIS پیش بینی کاملی داشته است، که نشان می دهد ANFIS به طور مؤثر وقوع خطا را شناسایی و طبقه بندی کرده است.

نتایج برای مکان‌یابی خطا


ارزیابی دقت و قابلیت اطمینان هر مدل در تعیین دقیق محل خطا را فراهم می‌کند. این مقایسه برای ارزیابی اثربخشی تکنیک‌های هوشمند پیشنهادی در تسهیل مکان‌یابی سریع و دقیق خطا در شبکه توزیع ضروری است.

جدول ۶ مکان‌های پیش‌بینی شده خطای مقایسه‌ای به‌دست‌آمده پس از شبیه‌سازی سیستم قدرت تحت شرایط خطای تک فاز را نشان می‌دهد. نتایج، موقعیت‌های خطای تخمینی شناسایی شده توسط مدل‌های ANN و ANFIS را نشان می‌دهد و امکان

جدول ۶. مکان پیش‌بینی خطا

Loads	Standard	ANN	ANFIS
Load 1	200	155	201
	400	384	400
	600	647	602
	800	735	803
Load 2	180	153	201
	360	348	400
	540	588	602
	720	703	803
Load 3	220	207	220
	440	422	442
	660	631	658
	880	888	880

نمودارهای مربوط به محل خطا در بارهای ۱، ۲ و ۳ در شکل ۲۰ نشان داده شده است.



شکل ۲۰. محل خطا

نزدیکی بیشتر به نقاط خطای واقعی ارائه می‌دهد. با توجه به دقت و استحکام بهبود یافته آن در مدیریت الگوهای داده غیرخطی، مدل ANFIS به عنوان حسگر هوشمند ترجیحی برای تشخیص محل خطا در سیستم قدرت توصیه می‌شود.

بر اساس نتایج پیش‌بینی محل خطا که در شکل ۲۰ نشان داده شده و در جدول ۶ خلاصه شده است، مدل ANFIS دقت پیش‌بینی بالاتری را در مقایسه با مدل ANN نشان داد. مدل ANFIS تخمین‌های محل خطا را با حاشیه خطای کمتر و

ارزیابی دقت و قابلیت اطمینان مدل‌های محل خطای مبتنی بر هوش مصنوعی عمل می‌کند و امکان مقایسه روشنی از میزان نزدیکی هر مدل به محل خطای واقعی را فراهم می‌کند.

جدول ۷ مقادیر درصد انحراف مرتبط با نتایج محلی‌سازی خطا را نشان می‌دهد. این مقادیر، تفاوت بین محل‌های خطای پیش‌بینی شده و نقاط خطای واقعی در شبکه توزیع برق را کمی می‌کنند. درصد انحراف به عنوان یک معیار عملکرد کلیدی در

جدول ۷. مقادیر درصد انحراف خطا

Load 1 (%)		Load 2 (%)		Load 3 (%)	
ANN	ANFIS	ANN	ANFIS	ANN	ANFIS
22.5000	0.5000	15.0000	0.5556	5.9091	0
4.0000	0	3.3333	0.5556	4.0909	0.4545
7.8333	0.3333	8.8889	0.5556	4.3939	0.3030
8.1250	0.3750	2.3611	0	0.9091	0

منابع:

- [1] Vidya Venkatesh (2018). Fault Classification and Location Identification on Electrical Transmission Network Based on Machine Learning Methods. 2022; Virginia Commonwealth University
- [2] Stefanidou Voziki, Paschalia & Sapountzoglou, Nikolaos & Raison, Bertrand & Dominguez-Garcia, José Luis. (2022). A review of fault location and classification methods in distribution grids. *Electric Power Systems Research*. 209. 108031. [10.1016/j.epsr.2022.108031](https://doi.org/10.1016/j.epsr.2022.108031).
- [3] De La Cruz, J., Gómez-Luna, E., Ali, M., Vasquez, J. C., & Guerrero, J. M. (2023). Fault Location for Distribution Smart Grids: Literature Overview, Challenges, Solutions, and Future Trends. *Energies*, 16(5), 2280. <https://doi.org/10.3390/en16052280>
- [4] Alayande, Akintunde. S., Okakwu, I. K., Olabode, O. E. and Nwankwoh, O. K. (2021). Analysis of unsymmetrical faults based on artificial neural network using 11 kV distribution network of University of Lagos as case study. *Journal of Advances in Science and Engineering*. 4(1); 53-64
- [5] Özdemir, Ö., Köker, R., & Pamuk, N. (2025). Fault Classification and Precise Fault Location Detection in 400 kV High-Voltage Power Transmission Lines Using Machine Learning Algorithms. *Processes*, 13(2), 527. <https://doi.org/10.3390/pr13020527>
- [6] Almasoudi, F. M. (2023). Enhancing Power Grid Resilience through Real-Time Fault Detection and Remediation Using Advanced Hybrid Machine Learning Models. *Sustainability*, 15(10), 8348. <https://doi.org/10.3390/su15108348>

شبکه توزیع روی خطوط بار در این مطالعه بهبود یافته و طبقه‌بندی‌کننده‌های یادگیری و مکان‌یاب‌ها را قادر ساخته تا نوع خطا را به طور دقیق طبقه‌بندی کرده و مکانی را که خطا در آن رخ داده است، پیدا کنند. دقت 99.7% ANFIS بود و در مقایسه با ANN، عملکرد بهتری در تجزیه و تحلیل خود داشت.

۷. نتیجه‌گیری

روش‌های روند هوش مصنوعی (AITM) برای تجزیه و تحلیل سیستم‌های قدرت، دقیق‌تر، سریع‌تر و مقرون‌به‌صرفه‌تر بوده‌اند. در میان این روش‌ها، الگوریتم ANN به دلیل موفقیت‌های اخیر خود، به‌طور گسترده‌ای مورد استفاده قرار گرفته است. اگرچه تکنیک‌های خوشه‌بندی فازی در تشخیص مشکلات مختلف سیستم قدرت، اثربخشی خود را نشان داده‌اند، اما کاربرد آنها همچنان محدود است - احتمالاً به دلیل چالش‌های موجود در همبستگی داده‌ها. این مطالعه نشان داد که مدل سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) با دستیابی به نرخ دقت ۹۹.۷٪، دقیق‌ترین نتایج طبقه‌بندی و مکان‌یابی خطا را ارائه می‌دهد. این یافته‌ها نشان می‌دهد که رویکرد پیشنهادی می‌تواند با بهبود قابل توجه سرعت و دقت تشخیص خطا در طول اختلالات عمده، از اپراتورهای سیستم پشتیبانی کند و در نتیجه زمان از کارافتادگی را کاهش داده و خطر خاموشی‌های طولانی‌مدت را کاهش دهد.

- [17] Dana F. Doghramachi, Siddeeq Y. Ameen. (2023). Internet of Things (IoT) Security Enhancement Using XGboost Machine Learning Techniques. *Computers, Materials and Continua*, 77(1): 717-732.
- [18] Djaballah, Said & Meftah, Kamel & Khelil, Khaled & Sayadi, Mounir. (2023). Deep Transfer Learning for Bearing Fault Diagnosis using CWT Time-Frequency Images and Convolutional Neural Networks. *Journal of Failure Analysis and Prevention*. 10.1007/s11668-023-01645-4.
- [19] Liang, Lingyu & Zhang, Huanming & Cao, Shang & Zhao, Xiangyu & Li, Hanju & Chen, Zhiwei. (2024). Fault location method for distribution networks based on multi-head graph attention networks. *Frontiers in Energy Research*. 12. 10.3389/fenrg.2024.1395737.
- [20] Ngo, Quang-Ha & Nguyen, Bang & Zhang, Jianhua & Schoder, Karl & Ginn, Herbert & Vu, Tuyen. (2024). Deep Graph Neural Network for Fault Detection and Identification in Distribution Systems. 10.36227/techrxiv.172555531.16904989/v1.
- [21] B Thomas, Jibin & Chaudhari, Saurabh & Shihabudheen, K. & Verma, Nishchal. (2023). CNN-Based Transformer Model for Fault Detection in Power System Networks. *IEEE Transactions on Instrumentation and Measurement*. PP. 1-1. 10.1109/TIM.2023.3238059.
- [22] Zhang, J. & He, Zhengyou & Lin, Sheng & Zhang, Y.B. & Qian, Q.Q.. (2013). An ANFIS-based fault classification approach in power distribution system. *International Journal of Electrical Power & Energy Systems*. 49. 243-252. 10.1016/j.ijepes.2012.12.005 .
- [23] Kanwal, S, and Jiriwibhakorn, S. (2024). Advanced Fault Detection, Classification, and Localization in Transmission Lines: A Comparative Study of ANFIS, Neural Networks, and Hybrid Methods. *IEEE Access*. 12. 49017-49033. 10.1109/ACCESS.2024.3384761 .
- [24] Goutam Kumar Yadav*, Mukesh Kumar Kirar, S.C. Gupta and Jatoth Rajender. Integrating ANN and ANFIS for effective fault detection and location in modern power grid. *Science and Technology for Energy Transition* 80, 34.
- [25] Mohamed, M. A., Hassan, M. A. M., Albalawi, F., Ghoneim, S. S. M., Ali, Z. M., & Dardeer, M. (2021). Diagnostic Modelling for Induction Motor Faults via ANFIS Algorithm and DWT-Based Feature Extraction. *Applied Sciences*, 11(19), 9115. <https://doi.org/10.3390/app11199115>
- [7] Liang, Lingyu & Zhang, Huanming & Cao, Shang & Zhao, Xiangyu & Li, Hanju & Chen, Zhiwei. (2024). Fault location method for distribution networks based on multi-head graph attention networks. *Frontiers in Energy Research*. 12. 10.3389/fenrg.2024.1395737.
- [8] D. Chanda and N. Y. Soltani, "Graph-Based Multi-Task Learning For Fault Detection In Smart Grid," 2023 IEEE 33rd International Workshop on Machine Learning for Signal Processing (MLSP), Rome, Italy, 2023, pp. 1-6, doi: 10.1109/MLSP55844.2023.10285865.
- [9] Bang, N., Vu, T., Nguyen, T., Panwar, M., & Hovsapian, R. (2022). Spatial-Temporal Recurrent Graph Neural Networks for Fault Diagnostics in Power Distribution Systems. *IEEE Access*, 11, 46039-46050 frontiersin.org+4arxiv.org+4etasr.com+4sciencedirect.com
- [10] Baskar. D. and Dr. Selvam. (2020). Machine Learning Framework for Power System Fault Detection and Classification. *International Journal of Scientific & Technology Research*. ۸۶۱۶-۲۷۷۷;(۲)۹
- [11] Rahaman Dashti, Mohammad Daisy, Hamid Mirshekali, Hamid Reza Shaker, Mahmood Hosseini Aliabadi. (2021). A survey of fault prediction and location methods in electrical energy distribution networks. *Measurement*, 184, 109947. mdpi.com+3sciencedirect.com+3mdpi.com+3
- [12] Mirshekali, H., Dashti, R., Keshavarz, A., & Shaker, H. R. (2022). Machine Learning-Based Fault Location for Smart Distribution Networks Equipped with Micro-PMU. *Sensors*, 22(3), 945. <https://doi.org/10.3390/s22030945>
- [13] Thukaram (2004). Detection of fault in Distribution systems using artificial neural network. *National power system conference (NPSC)*, IEEE, 9p
- [14] Muhammad M.A.S. Mahmoud (2013). 3-Phase Fault Finding in Oil Field MV Distribution Network Using Fuzzy Clustering Techniques. *Journal of Energy and Power Engineering*, 7: 155-161.
- [15] Avagaddi Prasad and J. Belwin Edward (2016). Application of Wavelet Technique for Fault Classification in Transmission Systems. *School of Electrical Engineering, VIT University, Vellore, Tamil Nadu, 632014, India*
- [16] Q. Wu, C. Dong, F. Guo, L. Wang, X. Wu and C. Wen, "Privacy-Preserving Federated Learning for Power Transformer Fault Diagnosis With Unbalanced Data," in *IEEE Transactions on Industrial Informatics*, vol. 20, no. 4, pp. 5383-5394, April 2024, doi: 10.1109/TII.2023.3333914.