Journal of **N**ovel **R**esearches on **S**mart **P**ower **S**ystems - Vol. 15 - No. 1 – Spring 2026
P-ISSN: 2322-2468, E-ISSN: 2981-0272, https://jeps.dezful.iau.ir/

Research Article

A CNN–LSTM Based Differential Protection Scheme for Early Detection and Classification of Internal Winding Faults in Power Transformers

Ehsan Akbari[1], *Assistant professor*

[1] Department of Electrical Engineering, Mazandaran University of Science and Technology, Babol, Iran.
e.akbari@ustmb.ac.ir

Abstract:
Power transformers are critical assets in transmission and distribution networks, and internal faults can cause substantial equipment damage and compromise power system stability. The rapid detection of winding faults and their accurate discrimination from transient phenomena remain key challenges in transformer differential protection. This paper proposes an intelligent hybrid model based on a convolutional neural network and long short-term memory network (CNN–LSTM) for the early detection and classification of internal transformer faults. Three-phase differential current signals are used as inputs to the proposed model. The CNN layers extract salient local and spatial features from the current waveforms, while the LSTM layer captures the temporal dependencies embedded in the transient signals. Various operating scenarios are simulated, including normal operating conditions, magnetizing inrush current, and different types of internal faults, namely phase-to-ground, phase-to-phase, and three-phase faults. The evaluation results demonstrate that the proposed hybrid architecture achieves an accuracy of 98.8%, outperforming standalone CNN and LSTM models. With its fast response and high accuracy in discriminating internal faults from magnetizing inrush currents, the proposed model shows strong potential for implementation in next-generation intelligent protective relays.

Keywords: CNN–LSTM, differential protection, early fault detection, internal fault, long short-term memory, power transformer.

Received: 1 Feb. 2026
Revised: 9 Apr. 2026
Accepted: 14 Apr. 2026

*** Corresponding Author:** Dr. Ehsan Akbari

Citation: Ehsan Akbari, “A CNN–LSTM Based Differential Protection Scheme for Early Detection and Classification of Internal Winding Faults in Power Transformers”, Journal of Novel Researches on Smart Power Systems, vol. 15, no. 1, pp. 1-14, June 2026 (in Persian).

[Downloaded from jeps.dezful.iau.ir on 2026-10-21]

مقاله پژوهشی

ارائه طرح حفاظتی دیفرانسیلی مبتنی بر مدل ترکیبی *CNN-LSTM* برای تشخیص زودهنگام و طبقه‌بندی خطاهای داخلی سیم‌پیچی در ترانسفورماتورهای قدرت

احسان اکبری[1]، استادیار

۱- دانشکده مهندسی برق، دانشگاه علوم و فنون مازندران، بابل، ایران، e.akbari@ustmb.ac.ir

چکیده: ترانسفورماتورهای قدرت از تجهیزات حیاتی در شبکه‌های انتقال و توزیع هستند که بروز خطاهای داخلی در آن‌ها می‌تواند منجر به خسارت‌های سنگین و کاهش پایداری شبکه شود. تشخیص سریع و تفکیک دقیق خطاهای سیم‌پیچی از پدیده‌های گذرا، چالش اصلی در حفاظت دیفرانسیل است. در این مقاله، یک مدل هوشمند ترکیبی مبتنی بر شبکه‌های عصبی کانولوشنی و حافظه طولانی‌مدت کوتاه‌مدت (CNN-LSTM) جهت تشخیص زودهنگام و طبقه‌بندی خطاهای داخلی ارائه شده است. در روش پیشنهادی، از سیگنال‌های جریان تفاضلی سه‌فاز به‌عنوان ورودی استفاده می‌شود؛ به‌طوری‌که لایه‌های CNN وظیفه استخراج ویژگی‌های مکانی و محلی از شکل‌موج‌ها را بر عهده داشته و لایه LSTM وابستگی‌های زمانی موجود در سیگنال‌های گذرا را فرا می‌گیرد. سناریوهای مختلفی شامل وضعیت عادی، جریان هجومی و انواع خطاهای داخلی (فاز به زمین، فاز به فاز و سه‌فاز) شبیه‌سازی شده است. نتایج حاصل از ارزیابی مدل نشان می‌دهد که ساختار ترکیبی پیشنهادی با دستیابی به دقت ۹۸,۴ درصد، عملکرد بهتری نسبت به مدل‌های تک‌ساختار CNN و LSTM نشان می‌دهد. این مدل با سرعت پاسخ‌دهی بالا و دقت در تفکیک جریان هجومی، پتانسیل بالایی جهت به‌کارگیری در نسل جدید رله‌های حفاظتی هوشمند دارد.

کلمات کلیدی: ترانسفورماتور قدرت، خطای داخلی، حفاظت دیفرانسیل، شبکه عصبی کانولوشنی، LSTM، تشخیص زودهنگام خطا.

تاریخ دریافت: ۱۴۰۴/۱۱/۱۲
تاریخ بازنگری: ۱۴۰۵/۱/۲۰
تاریخ پذیرش: ۱۴۰۵/۱/۲۵

* **نام نویسنده مسئول:** دکتر احسان اکبری
نشانی نویسنده مسئول: بابل، دانشگاه علوم و فنون مازندران، دانشکده مهندسی برق.

[Downloaded from jeps.dezful.iau.ir on 2026-10-21]
Journal of Novel Researches on Smart Power Systems - Vol. 15 - No. 1- Spring 2026

۱- مقدمه

شبکه‌های ترانسفورماتورهای قدرت از مهم‌ترین تجهیزات الکتریکی در شبکه‌های انتقال و توزیع انرژی الکتریکی به شمار می‌روند و نقش اساسی در انتقال مطمئن و پایدار توان بین سطوح مختلف ولتاژ دارند [۱]. با توجه به اهمیت بالای این تجهیز، بروز هرگونه خطا در آن می‌تواند منجر به اختلال در بهره‌برداری، افزایش هزینه‌های تعمیر و نگهداری، کاهش قابلیت اطمینان شبکه و حتی وقوع خاموشی‌های گسترده شود [۲]. در میان انواع خطاهای ترانسفورماتور، خطاهای داخلی سیم‌پیچی از اهمیت ویژه‌ای برخوردارند؛ زیرا این خطاها معمولاً با سرعت بالا پیشرفت کرده و در صورت عدم تشخیص به‌موقع، می‌توانند خسارات جدی و جبران‌ناپذیری به ترانسفورماتور وارد کنند [۳].

در حال حاضر، رله دیفرانسیلیکی از اصلی‌ترین روش‌های حفاظت ترانسفورماتور در برابر خطاهای داخلی محسوب می‌شود. با وجود عملکرد مناسب این رله در شرایط عادی، تشخیص صحیح خطاهای داخلی در برخی وضعیت‌های گذرا همچون جریان هجومی مغناطیس‌کنندگی، اشباع ترانس جریان، تغییرات ناگهانی بار و خطاهای خارجی همراه با اعوجاج سیگنال، همچنان با چالش‌هایی همراه است [۴]. این شرایط می‌توانند موجب عملکرد نادرست رله یا کاهش حساسیت و پایداری آن شوند. ازاین‌رو، استفاده از روش‌های هوشمند و داده‌محور برای افزایش دقت و سرعت تشخیص خطا، به‌عنوان یک رویکرد مکمل در کنار حفاظت‌های سنتی، مورد توجه پژوهشگران قرار گرفته است [۵].

در سال‌های اخیر، کاربرد روش‌هایادگیری ماشین و یادگیری عمیق در حوزه حفاظت و پایش تجهیزات قدرت رشد قابل توجهی داشته است [۶]. در میان این روش‌ها، شبکه‌های عصبی کانولوشنی [۱](CNN) به دلیل توانایی بالا در استخراج ویژگی‌های موضعی از داده‌های ورودی [۷]، و شبکه‌های حافظه کوتاه‌مدت بلندمدت [۲](LSTM) به دلیل قدرت در مدل‌سازی وابستگی‌های زمانی [۸]، گزینه‌های مناسبی برای تحلیل سیگنال‌های گذرای الکتریکی هستند. ترکیب این دو شبکه در قالب یک ساختار هیبریدی CNN-LSTM می‌تواند هم‌زمان ویژگی‌های مکانی و زمانی سیگنال را یاد گرفته و در نتیجه، دقت تشخیص را نسبت به مدل‌های منفرد افزایش دهد [۹]. این ویژگی به‌ویژه برای تحلیل سیگنال‌های جریان دیفرانسیل ترانسفورماتور که دارای رفتارهای گذرا و غیرخطی هستند، بسیار مفید است. برخلاف برخی پژوهش‌های پیشین که بر تحلیل گازهای محلول در روغن [۱۰] یا داده‌های حرارتی [۱۱] برای تشخیص وضعیت ترانسفورماتور تمرکز داشته‌اند، در این مقاله از سیگنال‌های جریان دیفرانسیل سه‌فاز به‌عنوان ورودی مدل استفاده می‌شود تا تشخیص خطا در بازه زمانی کوتاه و با هدف کاربرد حفاظتی انجام گیرد. به این ترتیب، مسئله از پایش وضعیت عمومی به سمت تشخیص سریع و دقیق خطاهای داخلی سیم‌پیچی برای بهبود عملکرد رله دیفرانسیل سوق داده می‌شود [۱۲]. این رویکرد می‌تواند علاوه بر افزایش سرعت تشخیص، حساسیت سیستم حفاظتی را در برابر خطاهای داخلی افزایش داده و از عملکرد نادرست در شرایط گذرا جلوگیری کند [۱۳]. در این مقاله، یک مدل ترکیبی CNN-LSTM برای تشخیص زودهنگام و طبقه‌بندی خطاهای داخلی ترانسفورماتور قدرت ارائه می‌شود. در این مدل، پس از پیش‌پردازش و نرمال‌سازی داده‌ها، سیگنال‌های جریان در قالب پنجره‌های زمانی کوتاه به شبکه ورودی داده می‌شوند. سپس لایه‌هایCNN ویژگی‌های مهم سیگنال را استخراج کرده و لایه‌های LSTM وابستگی‌های زمانی را برای تصمیم‌گیری نهایی مدل می‌کنند. عملکرد مدل پیشنهادی در سناریوهای مختلف شامل حالت عادی، جریان هجومی و انواع خطاهای داخلی مورد ارزیابی قرار گرفته و با مدل‌های کلاسیک ماشین بردار پشتیبان [۳](SVM) و شبکه پرسپترون چند لایه [۴](MLP) مقایسه می‌شود. نتایج نشان می‌دهد که ساختار هیبریدی پیشنهادی می‌تواند به‌عنوان یک ابزار هوشمند و کارآمد در بهبود عملکرد حفاظت دیفرانسیل ترانسفورماتورهای قدرت مورد استفاده قرار گیرد.

نوآوری های اصلی مقاله به شرح زیر است:

- ارائه یک مدل ترکیبی CNN-LSTM برای تشخیص زودهنگام خطاهای داخلی ترانسفورماتور قدرت.
- استفاده از سیگنال‌های جریان دیفرانسیل به‌عنوان ورودی مدل به‌جای داده‌های تحلیل گازهای محلول [۵](DGA) یا حرارتی.
- طبقه‌بندی چند حالت عملکردی شامل حالت عادی، جریان هجومی و انواع خطاهای داخلی.
- مقایسه عملکرد مدل پیشنهادی با مدل‌های کلاسیک SVM و MLP و نشان‌دادن برتری ساختار ترکیبی.

[Downloaded from jeps.dezful.iau.ir on 2026-10-21]
Journal of Novel Researches on Smart Power Systems - Vol. 15 - No. 1- Spring 2026

ادامه مقاله به صورت زیر سازمان‌دهی شده است: در بخش دوم، مبانی نظری و مفاهیم مرتبط با حفاظت دیفرانسیل ترانسفورماتور و خطاهای داخلی بررسی می‌شود. در بخش سوم، مدل پیشنهادی مبتنی بر شبکه عصبی ترکیبیCNN-LSTM و مراحل پیش‌پردازش داده‌ها ارائه می‌گردد. در بخش چهارم، نتایج شبیه‌سازی و ارزیابی عملکرد روش پیشنهادی ارائه و با روش‌های دیگر مقایسه می‌شود. نهایتاً، در بخش پنجم نتیجه‌گیری و پیشنهادهایی برای تحقیقات آینده بیان می‌شود.

۲- مبانی نظری حفاظت دیفرانسیل و خطاهای داخلی ترانسفورماتور

در این حفاظت دیفرانسیل یکی از رایج‌ترین و مؤثرترین روش‌های حفاظت ترانسفورماتور در برابر خطاهای داخلی است. اساس عملکرد این حفاظت بر مقایسه جریان‌های دو طرف ترانسفورماتور در محدوده حفاظتی استوار است [۱۴]. در شرایط بهره‌برداری عادی، جریان ورودی به ترانسفورماتور و جریان خروجی از آن، پس از اعمال اصلاحات مربوط به نسبت تبدیل،گروه برداری و نسبت ترانسفورماتورهای جریان، تقریباً با یکدیگر برابر هستند. بنابراین اختلاف جریان دو طرف مقدار ناچیزی دارد. اما در صورت وقوع خطای داخلی، بخشی از جریان در محل خطا جاری شده و تعادل بین جریان‌های دو سمت ترانسفورماتور از بین می‌رود. در نتیجه، جریان دیفرانسیل افزایش‌یافته و می‌تواند به‌عنوان شاخصی برای تشخیص خطای داخلی مورد استفاده قرار گیرد.جریان دیفرانسیل هر فاز به‌صورت کلی از رابطه زیر محاسبه می‌شود:

$$I_{diff,k} = \left| I_{p,k} - I'_{s,k} \right| \quad (۱)$$

که در آن، $I_{p,k}$ جریان سمت اولیه، $I'_{s,k}$ جریان سمت ثانویه ارجاع داده شده به سمت اولیه و k نشان‌دهنده فازهای a،b و c است. جریان سمت ثانویه پس از در نظر گرفتن نسبت تبدیل ترانسفورماتور، نسبت ترانسفورماتورهای جریان و سایر ضرایب اصلاحی، به سمت اولیه ارجاع داده می‌شود. این جریان را می‌توان به‌صورت زیر بیان کرد:

$$I'_{s,k} = KI_{s,k} \quad (۲)$$

در این رابطه، K ضریب اصلاحی برای هم مقیاس سازی جریان‌های دو سمت ترانسفورماتور است. در حالت ایده‌آل و در نبود خطای داخلی، مقدار I_{diff} بسیار کوچک خواهد بود. با این حال، در شرایط واقعی، عواملی مانند خطای اندازه‌گیری، اختلاف مشخصات ترانسفورماتورهای جریان و شرایط گذرا می‌توانند باعث ایجاد جریان دیفرانسیل غیرصفر شوند. برای افزایش پایداری حفاظت دیفرانسیل در برابر شرایط غیرخطا، معمولاً از جریان مهارکننده یا جریان بایاس استفاده می‌شود. این جریان معیاری از شدت جریان عبوری از ترانسفورماتور است و به رله کمک می‌کند تا بین خطاهای داخلی و شرایطی مانند خطاهای خارجی یا خطاهای ناشی از اشباع ترانسفورماتور جریان تمایز قائل شود [۱۵]. جریان بایاس برای هر فاز به‌صورت زیر تعریف می‌شود:

$$I_{bias,k} = \frac{\left| I_{p,k} \right| + \left| I'_{s,k} \right|}{2} \quad (۳)$$

در رله‌های دیفرانسیل متداول، تصمیم‌گیری حفاظتی بر اساس مقایسه جریان دیفرانسیل با یک مقدار آستانه وابسته به جریان بایاس انجام می‌شود [۱۶]. به‌طور ساده، شرط عملکرد رله را می‌توان به‌صورت زیر نوشت:

$$I_{\mathrm{diff},k} \succ I_{set} + sI_{bias,k} \quad (۴)$$

که در آن، I_{set} جریان تنظیمی اولیه رله و S شیب مشخصه دیفرانسیل است. در صورتی که جریان دیفرانسیل از مقدار مجاز تعیین‌شده بیشتر شود، رله وقوع خطای داخلی را تشخیص داده و فرمان قطع صادر می‌کند. با وجود سادگی و کارایی این روش، عملکرد آن در برخی شرایط گذرا ممکن است با چالش مواجه شود.

یکی از مهم‌ترین چالش‌های حفاظت دیفرانسیل، جریان هجومی مغناطیس‌کنندگی در زمان برق‌دار شدن ترانسفورماتور است [۱۷]. این جریان می‌تواند دامنه‌ای بزرگ داشته باشد و از نظر مقدار، شبیه جریان خطای داخلی ظاهر شود؛ در حالی که ناشی از خطا نیست و نباید موجب عملکرد رله شود. همچنین، در هنگام وقوع خطاهای خارجی شدید، ترانسفورماتورهای جریان ممکن است وارد ناحیه اشباع شوند. اشباع ترانسفورماتور جریان باعث اعوجاج در سیگنال اندازه‌گیری‌شده شده و ممکن است

[Downloaded from jeps.dezful.iau.ir on 2026-10-21]
Journal of Novel Researches on Smart Power Systems - Vol. 15 - No. 1- Spring 2026

جریان دیفرانسیل کاذب ایجاد کند [۱۸]. علاوه بر این، تغییرات ناگهانی بار، نویز اندازه‌گیری، عدم تطابق کامل ترانسفورماتورهای جریان و تغییرات پارامتری نیز می‌توانند تشخیص دقیق خطا را دشوار سازند [۱۹].

با توجه به این چالش‌ها، استفاده صرف از دامنه جریان دیفرانسیل همیشه برای تشخیص دقیق خطاهای داخلی کافی نیست. شکل موج جریان، نحوه تغییرات آن در زمان، الگوهای گذرا و ارتباط میان نمونه‌های متوالی سیگنال می‌توانند اطلاعات ارزشمندی درباره وضعیت ترانسفورماتور فراهم کنند. از این رو، روش‌های مبتنی بر یادگیری عمیق می‌توانند به‌عنوان ابزاری مناسب برای استخراج ویژگی‌های پنهان از سیگنال‌های جریان و افزایش دقت تشخیص خطا مورد استفاده قرار گیرند [۲۰]. در این مقاله، از سیگنال‌های جریان دیفرانسیل سه‌فاز به‌عنوان ورودی مدل پیشنهادی استفاده می شود تا شبکه بتواند الگوهای مربوط به حالت عادی، جریان هجومی و خطاهای داخلی را یاد بگیرد. برای تشکیل ورودی شبکه، جریان دیفرانسیل سه فاز در هر لحظه نمونه‌برداری به‌صورت یک بردار داده در نظر گرفته می‌شود:

$$X(n)=\left[I_{diff,a}(n) \quad I_{diff,b}(n) \quad I_{diff,c}(n)\right]^T \tag{۵}$$

با در نظر گرفتن یک پنجره زمانی شامل N نمونه متوالی، ماتریس ورودی شبکه به‌صورت زیر تشکیل می‌شود:

$$X=\begin{bmatrix} x(1) \\ x(2) \\ \vdots \\ x(\mathrm{N}) \end{bmatrix} \in \Re^{N\times 3} \tag{۶}$$

در این ماتریس، هر سطر بیانگر نمونه‌ای از جریان‌های دیفرانسیل سه‌فاز در یک لحظه زمانی و هر ستون مربوط به یکی از فازها است. استفاده از پنجره زمانی این امکان را فراهم می‌کند که مدل پیشنهادی علاوه بر مقدار لحظه‌ای جریان، روند تغییرات آن در بازه‌ای کوتاه را نیز بررسی کند. این ویژگی برای تشخیص زودهنگام خطاهای داخلی اهمیت زیادی دارد، زیرا بسیاری از خطاها در لحظات اولیه دارای الگوهای گذرای مشخصی در شکل موج جریان هستند.پیش از اعمال داده‌ها به شبکه عصبی، سیگنال‌ها نرمال سازی می شوند تا اثر اختلاف مقیاس داده‌ها کاهش یافته و فرآیند آموزش پایدارتر شود. نرمال سازی داده‌ها می‌تواند به‌صورت زیر انجام گیرد:

$$x_{norm}=\frac{x-x_{\min}}{x_{\max}-x_{\min}} \tag{۷}$$

که در آن، x مقدار اصلی سیگنال و x_{min} و x_{max} به‌ترتیب کمینه و بیشینه مقادیر داده هستند. پس از نرمال‌سازی، داده‌ها به دو مجموعه آموزش و آزمون تقسیم شده و برای هر پنجره زمانی، برچسب متناظر با وضعیت ترانسفورماتور اختصاص داده می‌شود. این برچسب‌ها شامل حالت عادی، جریان هجومی مغناطیس‌کنندگی و انواع خطاهای داخلی مورد مطالعه هستند. در بخش بعد، ساختار مدل ترکیبیCNN-LSTM و نحوه استفاده از این داده‌ها برای تشخیص و طبقه‌بندی خطاها ارائه می‌شود.

۳- مدل پیشنهادی CNN-LSTM و روش آموزش آن

۳-۱- ساختار کلی مدل پیشنهادی

به‌منظور تشخیص سریع خطاهای داخلی سیم‌پیچی ترانسفورماتور، در این مقاله یک مدل ترکیبی مبتنی بر شبکه‌های عصبی کانولوشنی و حافظه بلندمدت کوتاه‌مدت پیشنهاد می‌شود. ایده اصلی مدل آن است که ابتدا ویژگی‌های محلی و الگوهای متمایزکننده موجود در شکل موج جریان دیفرانسیل توسط لایه‌هایCNN استخراج شوند و سپس وابستگی زمانی این ویژگی‌ها در پنجره نمونه‌برداری شده تو سط لایه LSTM تحلیل گردد. ترکیب این دو ساختار باعث می شود مدل پیشنهادی بتواند هم اعوجاج‌ها و تغییرات موضعی شکل موج و هم روند زمانی وقوع خطا را مورد بررسی قرار دهد.

ورودی مدل پیشنهادی، ماتریس جریان‌های دیفرانسیل سه‌فاز با ابعاد $N\times 3$ است که در آن N تعداد نمونه‌های موجود در پنجره زمانی و سه ستون ماتریس مربوط به فازهای a، b و c هستند. این ساختار به شبکه اجازه می‌دهد اطلاعات سه فاز را

[Downloaded from jeps.dezful.iau.ir on 2026-10-21]
Journal of Novel Researches on Smart Power Systems - Vol. 15 - No. 1- Spring 2026

به‌صورت هم‌زمان دریافت کند و ارتباط میان تغییرات جریان در فازهای مختلف را نیز در فرآیند تشخیص در نظر بگیرد. پس از دریافت داده ورودی، نمونه‌ها از مراحل استخراج ویژگی، تحلیل زمانی و طبقه‌بندی عبور می‌کنند. خروجی نهایی مدل، کلاس متناظر با وضعیت بهره‌برداری ترانسفورماتور است. شکل (۱) ساختار کلی مدل چندلایه پیشنهادی CNN-LSTM را نشان می‌دهد. در این ساختار، ماتریس جریان‌های دیفرانسیل سه‌فاز پس از پیش‌پردازش و نرمال‌سازی به لایه‌های کانولوشنییک‌بعدی اعمال می‌شود. لایه‌های CNN ویژگی‌های محلی و الگوهای متمایزکننده موجود در شکل موج جریان را استخراج می‌کنند. سپس ویژگی‌های به‌دست‌آمده به لایه‌های LSTM منتقل می‌شوند تا وابستگی‌های زمانی موجود در پنجره نمونه‌برداری تحلیل شوند. در پایان، ویژگی‌های استخراج‌شده توسط لایه کاملاً متصل پردازش شده و لایه Softmax وضعیت ترانسفورماتور را در یکی از کلاس‌های تعریف‌شده طبقه‌بندی می‌کند.

۲-۳- استخراج ویژگی با شبکه کانولوشنی

لایه کانولوشنییک‌بعدی برای استخراج ویژگی از سیگنال‌های ترتیبی مناسب است، زیرا می‌تواند الگوهای محلی موجود در نمونه‌های متوالی را شناسایی کند. در این مقاله، کانولوشن در راستای محور زمان انجام می شود و هر فیلتر، بخشی از شکل موج جریان را در یک بازه کوتاه بررسی می‌کند. خروجی فیلتر j در موقعیت زمانی n از رابطه زیر به‌دست می‌آید:

$$Z_j(n)=\sum_{r=0}^{K-1}\sum_{c=1}^{3} w_j(r,c)\,x(n+r,c)+b_j \tag{۸}$$

که در آن، $x(n,c)$ مقدار جریان مربوط به نمونه n در کانال c، K طول فیلتر، $w_j(r,c)$ وزن فیلتر، و b_j بایاس مربوط به فیلتر j است. در این رابطه، تعداد کانال‌های ورودی برابر با سه بوده و متناظر با سه جریان دیفرانسیل فازهای ترانسفورماتور است.
پس از انجام عملیات کانولوشن، تابع فعال‌سازی غیرخطی ReLU به‌کار گرفته می‌شود. این تابع به‌صورت زیر تعریف می‌شود:

$$f(z)=\max(0,z) \tag{۹}$$

استفاده از تابع ReLU موجب می‌شود شبکه بتواند روابط غیرخطی میان ویژگی‌های جریان را یاد بگیرد و در عین حال، از پیچیدگی محاسباتی بالای توابع فعال‌سازی اشباع‌شونده جلوگیری شود. خروجی لایه فعال‌سازی را می‌توان به‌صورت زیر نمایش داد:

$$h_{CNN}(n)=\mathrm{Re}LU\left(W_{CNN} * X(n)+b_{CNN}\right) \tag{۱۰}$$

که در آن، $x(n)$ بیانگر داده‌های ورودی شامل نمونه‌های جریان تفاضلی در گام زمانی n، $\mathbf{W}_{\mathrm{CNN}}$ مجموعه کرنل‌های قابل‌آموزش لایه کانولوشنی و $\mathbf{b}_{\mathrm{CNN}}$ بردار بایاس متناظر است. همچنین، نماد *عملیات کانولوشن را نشان می‌دهد و $\mathbf{h}_{\mathrm{CNN}}(n)$ نگاشت ویژگی استخراج شده پس از اعمال تابع فعال سازی ReLU است. تابع ReLU به صورت $\mathrm{ReLU}(z)=\max(0,z)$ تعریف شده و به‌صورت درایه‌به‌درایه اعمال می‌شود.فیلترهای ابتدایی معمولاً تغییرات سریع، قله‌های جریان، اعوجاج‌ها و ناپیوستگی‌های موجود در شکل موج را شناسایی می‌کنند. در لایه‌های عمیق‌تر، این ویژگی‌های اولیه با یکدیگر ترکیب شده و الگوهای پیچیده‌تری مانند تفاوت میان جریان هجومی و جریان خطای داخلی استخراج می‌شوند. برای کاهش ابعاد داده و افزایش مقاومت مدل در برابر تغییرات جزئی، پس از لایه‌های کانولوشنی از عملیات Max-Pooling استفاده می‌گردد. در این عملیات، بیشترین مقدار موجود در یک ناحیه مشخص از ویژگی‌ها انتخاب می‌شود:

$$p_j(m)=\max_{n\in R_m} h_j(n) \tag{۱۱}$$

[Downloaded from jeps.dezful.iau.ir on 2026-10-21]
Journal of Novel Researches on Smart Power Systems - Vol. 15 - No. 1- Spring 2026

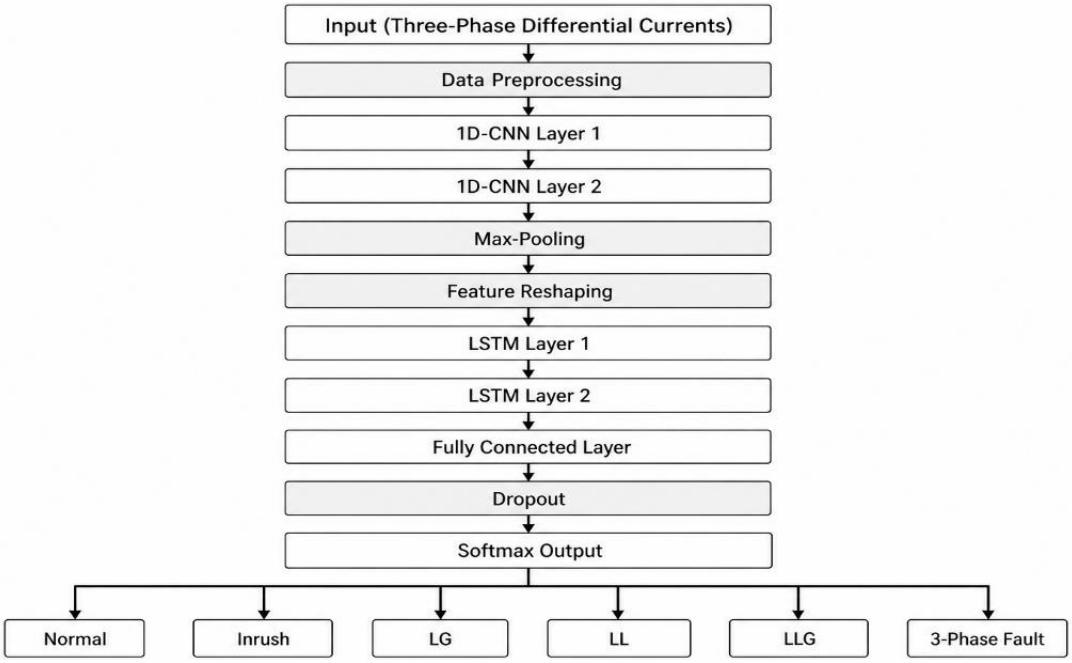

شکل (۱): ساختار کلی مدل چند لایه CNN-LSTM برای تشخیص خطاهای داخلی ترانسفورماتور

Figure (1): General structure of CNN-LSTM multilayer model for transformer internal fault detection

که در آن، $\mathcal{R}_m$ ناحیه مربوط به پنجره pooling و$p_j(m)$ خروجی کاهش‌یافته ویژگیjاست. این عملیات ضمن کاهش حجم محاسبات، ویژگی‌های مهم‌تر را حفظ کرده و حساسیت شبکه را نسبت به جابه‌جایی‌های جزئی در محل وقوع الگو کاهش می‌دهد.

۳-۳- تحلیل وابستگی‌های زمانی با لایه LSTM

اگرچه لایه‌هایCNN در استخراج ویژگی‌های محلی شکل موج عملکرد مناسبی دارند، اما به‌تنهایی نمی‌توانند وابستگی‌های زمانی بلندمدت میان نمونه‌های متوالی را به‌طور کامل مدل‌سازی کنند [۲۱]. برای رفع این محدودیت، خروجی توالی لایه‌های کانولوشنی به یک لایه LSTM داده می‌شود. شبکه LSTM نوعی شبکه عصبی بازگشتی است که با استفاده از ساختار حافظه داخلی خود می‌تواند اطلاعات مهم مربوط به نمونه‌های قبلی را حفظ کرده و اثر اطلاعات کم اهمیت یا نامرتبط را کاهش دهد [۲۲]. در گام زمانیn، روابط اصلی لایه LSTM به‌صورت زیر تعریف می‌شوند:

$$i_n = \sigma\left(W_i u_n + U_i h_{n-1} + b_i\right) \quad (۱۲)$$

$$f_n = \sigma\left(W_f u_n + U_f h_{n-1} + b_f\right) \quad (۱۳)$$

$$o_n = \sigma\left(W_o u_n + U_o h_{n-1} + b_o\right) \quad (۱۴)$$

$$\tilde{c}_n = \tanh\left(W_c u_n + U_c h_{n-1} + b_c\right) \quad (۱۵)$$

$$\mathbf{c}_n = \mathbf{f}_n \odot \mathbf{c}_{n-1} + \mathbf{i}_n \odot \tilde{\mathbf{c}}_n \quad (۱۶)$$

$$\mathbf{h}_n = \mathbf{o}_n \odot \tanh(\mathbf{c}_n) \quad (۱۷)$$

در این روابط، u_n ورودی لایه LSTM در گام زمانیn، h_n بردار حالت پنهان، c_n بردار وضعیت سلول و i_n، f_n و o_n به‌ترتیب درگاه ورودی،درگاه فراموشی و درگاه خروجی هستند. همچنین، σ تابع سیگموید، tanh تابع تانژانت هایپربولیک و $\odot$ عملگر ضرب عضو به عضو است.

[Downloaded from jeps.dezful.iau.ir on 2026-10-21]
Journal of Novel Researches on Smart Power Systems - Vol. 15 - No. 1- Spring 2026

درگاه فراموشی تعیین می‌کند که چه مقدار از اطلاعات مربوط به وضعیت قبلی حفظ شود. درگاه ورودی اطلاعات جدید و مهم را به حافظه ا ضافه می‌کند و درگاه خروجی نیز م شخص می سازد که چه بخ شی از و ضعیت داخلی سلول در خروجی هر گام زمانی ظاهر شود. این ویژگی باعث می شود شبکه LSTM بتواند تفاوت میان تغییرات گذرای جریان هجومی و روند تغییرات جریان ناشی از خطای داخلی را بهتر شناسایی کند.

۳-۴- طبقه‌بندی وضعیت ترانسفورماتور

پس از پردازش توالی ویژگی‌ها توسط لایه LSTM، آخرین بردار حالت پنهان یا خروجی تجمیع‌شده آن به یک لایه کاملاً متصل منتقل می شود. این لایه، ویژگی‌های ا ستخراج شده را ترکیب کرده و نمایش منا سبی برای ت صمیم‌گیری نهایی ایجاد می‌کند. برای جلوگیری از بیش‌برازش، در این بخش از روش Dropout استفاده می‌گردد. در روش Dropout، بخشی از نورون‌ها به صورت ت صادفی در طول فرآیند آموزش غیرفعال می شوند و شبکه به‌جای وابستگی به تعداد محدودی از ویژگی‌ها، نمایش عمومی‌تری از داده‌ها یاد می‌گیرد. به فرض تعداد کلاس‌های مورد بررسی برابر با C باشد. خروجی لایه Softmax برای کلاس q از رابطه زیر محاسبه می‌شود:

$$\hat{y}_q = \frac{\exp(s_q)}{\sum_{\tau=1}^{C} \exp(s_r)} \tag{۱۸}$$

که در آن، s_q مقدار خام خروجی مربوط به کلاس q و $\hat{y}_q$ احتمال پیش‌بینی‌شده برای آن کلاس است. مجموع احتمال‌های خروجی برابر با یک خواهد بود و کلاس نهایی با بیشترین احتمال به‌عنوان وضعیت تشخیص‌داده‌شده انتخاب می‌شود:

$$\hat{C} = \arg \max \ \hat{y}_q \quad q \in \{1,...,C\} \tag{۱۹}$$

در این مقاله، کلاس‌های خروجی شامل و ضعیت عادی، جریان هجومی، خطای فاز به زمین، خطای فاز به فاز، خطای دو فاز به زمین و خطای سه‌فاز هستند.

۳-۵- فرآیند آموزش مدل

آموزش مدل پیشنهادی با ا ستفاده از پنجره‌های زمانی برچسب‌گذاری شده انجام می شود. هر نمونه آموز شی شامل ماتریس جریان‌های دیفرانسیل سه‌فاز و برچسب وضعیت متناظر با آن است. پس از نرمال‌سازی، داده‌ها به مجموعه‌های آموزش و اعتبارسنجی تقسیم می‌شوند. مجموعه آموزش برای تنظیم وزن‌ها، و مجموعه اعتبارسنجی برای بررسی عملکرد مدل در طول آموزش، انتخاب پارامترهای مناسب، و ارزیابی نهایی مدل مورد استفاده قرار می‌گیرد.برایبک مسئله چندکلاسه، تابع هزینه آنتروپی متقاطع به‌صورت زیر تعریف می‌شود:

$$\Im = -\frac{1}{M} \sum_{m=1}^{M} \sum_{q=1}^{C} y_{m,q} \log\left(\hat{y}_{m,q}\right) \tag{۲۰}$$

که در آن، M تعداد نمونه‌های آموز شی، C تعداد کلاس‌ها، $y_{m,q}$ مقدار واقعی برچسب نمونه m برای کلاس q، و $\hat{y}_{m,q}$ احتمال پیش‌بینی‌شده توسط مدل است. اگر نمونه m به کلاس q تعلق داشته باشد، مقدار $y_{m,q}$ برابر یک و در غیر این صورت برابر صفر خواهد بود.

وزن‌های شبکه با ا ستفاده از الگوریتم بهینه سازیAdam به‌روزر سانی می شوند [۲۳]. این الگوریتم با ا ستفاده از گرادیان تابع هزینه، نرخ یادگیری تطبیقی برای پارامترهای مختلف شبکه تعیین می‌کند. به‌روزرسانی کلی پارامترهای مدل را می‌توان به‌صورت زیر نمایش داد:

$$\theta_{t+1} = \theta_t - \eta \nabla_\theta \Im(\theta_t) \tag{۲۱}$$

[Downloaded from jeps.dezful.iau.ir on 2026-10-21]
Journal of Novel Researches on Smart Power Systems - Vol. 15 - No. 1- Spring 2026

که در آن، مجموعه پارامترهای قابل آموزش شـــبکه، η نرخ یادگیری و $\nabla_\theta \mathfrak{J}$ گرادیان تابع هزینه نســـبت به پارامترهای مدل ا ست. در فرآیند آموزش، داده‌ها در د سته‌های کوچک به شبکه ارائه می شوند و در پایان هر دوره، عملکرد مدل با ا ستفاده از داده‌های اعتبارسنجی بررسی می‌گردد[۲۵].

به‌منظور جلوگیری از بیش‌برازش، آموزش شـــبکه تا زمانی ادامه می‌یابد که خطای اعتبارســـنجی کاهش یابد. در صـــورتی که خطای اعتبارســـنجی در چند دوره متوالی افزایش پیدا کند، فرآیند آموزش متوقف شـــده و وزن‌های مربوط به بهترین عملکرد اعتبارسنجی انتخاب می‌شوند. همچنین، استفاده از Dropout، نرمال‌سازی داده‌ها و انتخاب مناسب طول پنجره زمانی می‌تواند به افزایش قابلیت تعمیم مدل کمک کند.

در نهایت، مدل آموزش‌دیده با ا ستفاده از داده‌های آزمون ارزیابی می شود. برای سنجش عملکرد مدل، معیارهایدقت، صحت، فراخوانی، امتیازF_1 و ماتریس درهم‌ریختگی مورد استفاده قرار می‌گیرند. دقت مدل از رابطه زیر محاسبه می‌شود:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \tag{۲۲}$$

که در آن، TP تعداد تشـخیص‌های صـحیح برای کلاس مثبت، TN تعداد تشـخیص‌های صـحیح برای کلاس منفی،FP تعداد موارد مثبت کاذب و FN تعداد موارد منفی کاذب اسـت. همچنین، صـحت و فراخوانی به‌ترتیب از روابط (۲۳) و (۲۴) به‌دسـت می‌آیند:

$$\mathrm{Pr}ecision = \frac{TP}{TP + FP} \tag{۲۳}$$

$$\mathrm{Re}call = \frac{TP}{TP + FN} \tag{۲۴}$$

امتیازF_1 نیز به‌صورت زیر تعریف می‌شود:

$$F_1 = \frac{2 \times \mathrm{Pr}ecision \times \mathrm{Re}call}{\mathrm{Pr}ecision + \mathrm{Re}call} \tag{۲۵}$$

این شاخص‌ها امکان ارزیابی جامع عملکرد مدل را فراهم می‌کنند، زیرا در مسئله تشخیص خطا، صرفاً دقت کلی کافی نیست و باید توانایی مدل در شناسایی صحیح کلاس‌های مختلف نیز مورد توجه قرار گیرد. به‌ویژه در مواردی که داده‌ها نامتوازن باشند یا برخی خطاها فراوانی کمتریداشته باشند، استفاده از شاخص‌های صحت و فراخوانی اهمیت بیشتری پیدا می‌کند.

۴- شبیه‌سازی و نتایج عددی

سیستم تحت مطالعه در محیط نرم‌افزاری PSCADTM/EMTDC مدل‌سازی شده تا داده‌های جریان دیفرانسیل با دقت بالا ا ستخراج گردند. همچنین به منظور پیاده سازی الگوی تشخیص خطای پیشنهادی، از نرم افزار MATLAB 2020b ا ستفاده شده ا ست. ترانسفورماتور قدرت مورد مطالعه دارای ظرفیت و ولتاژ نامیمطابق جدول (۱) بوده و مدل سازی آن شامل جزئیات دقیق سیم‌پیچی، هسته مغناطیسی و ترانسفورماتورهای جریان (CT)[۶] جهت در نظر گرفتن پدیده‌های غیرخطی نظیر ا شباع ا ست[۲۴]. سناریوهای مختلف شامل شرایط عادی بهره‌برداری، وقوع انواع خطاهای داخلی (فاز به زمین، فاز به فاز و سه‌فاز) و شـرایط گذرای ناشـی از جریان هجومی مغناطیس‌کنندگی تولید شـده‌اند. فرکانس نمونه‌برداریسـیگنال‌ها برابر با ۱۶ کیلوهرتز انتخاب شده و پنجره‌های زمانی به طول یک سیکل از جریان دیفرانسیل به‌عنوان ورودی مدل ا ستخراج گردید. داده‌های تولید شده پس از نرمال‌سازی در بازه [۰،۱]، به سه دو داده‌های آموزش و اعتبارسنجی تقسیم شدند تا از بیش برازش مدل جلوگیری شود. معماری CNN-LSTM با هدف ا ستخراج ویژگی‌های سلسله‌مراتبی از سیگنال جریان طراحی شده ا ست. بخش CNN

[Downloaded from jeps.dezful.iau.ir on 2026-10-21]
Journal of Novel Researches on Smart Power Systems - Vol. 15 - No. 1- Spring 2026

شامل لایه‌های کانولو شن یک‌بعدی ا ست که م سئولیت شنا سایی الگوهای محلی شکل موج را بر عهده دارند. پس از لایه‌های کانولوشـــن و لایه‌های تجمیع (Pooling)، داده‌ها به لایه‌های LSTM منتقل می‌شـــوند تا روابط زمانی میان نمونه‌های متوالی تحلیل گردد. نرخ یادگیری برابر با $\alpha=10^{-3}$، تعداد دوره‌های آموزش (Epochs) و اندازه دســته (Batch Size) به‌گونه‌ای بهینه شدند که تابع هزینه (Categorical Cross-Entropy) به حداقل مقدار خود بر سد. تنظیمات دقیق هایپر پارامترها در جدول (۲) ارائه شده است.

Table (1): Power transformer technical specifications and simulation settings

جدول (۱): مشخصات فنی ترانسفورماتور قدرت و تنظیمات شبیه‌سازی

پارامتر	مقدار
توان نامی (MVA)	۱۰۰
ولتاژ نامی (فشارقوی / فشارضعیف) (kV)	۶۳ / ۲۳۰
فرکانس شبکه (Hz)	۵۰
گروه برداری	YNd11
نسبت تبدیل ترانسفورماتور جریان (CT)	۵ / ۴۰۰
فرکانس نمونه‌برداری (kHz)	۱۶
طول پنجره زمانی (ms)	۲۰

Table (2): Hyperparametric parameters of the proposed model

جدول (۲): پارامترهای هایپرپارامتریک مدل پیشنهادی

پارامتر	مقدار
تعداد لایه‌های CNN	۲ لایه (۳۲ و ۶۴ فیلتر)
تعداد نورون‌های LSTM	۶۴ نورون
نرخ یادگیری (Learning Rate)	۱۰^-۳
تعداد دوره‌های آموزش (Epochs)	۵۰
اندازه دسته (Batch Size)	۳۲
طول پنجره زمانی	۲۰ میلی‌ثانیه

در این مطالعه، برای هر حالت بهره‌برداری،یک پنجره زمانی کوتاه از سیگنال‌های جریان انتخاب شد تا امکان تشخیص سریع خطا فراهم شود. ا ستفاده از پنجره‌های کوتاه زمانی از این جهت اهمیت دارد که در کاربردهای حفاظتی، تصمیم‌گیری باید در کمترین زمان ممکن انجام شـود و هرگونه تأخیر می‌تواند منجر به آســیب بیشــتر به تجهیزات شــود. بنابراین، ســاختار داده به‌گونه‌ای طراحی شــد که مدل بتواند تنها بر اســاس چند ســیکل ابتدایی پس از وقوع رویداد، نوع وضــعیت ترانســفورماتور را شناسایی کند.

نتایج عددی حا صل از ارزیابی مدل در جدول (۳) خلا صه شده ا ست. شاخص‌های ا صلی ارزیابی شامل دقت (Accuracy)، صــحت (Precision)، فراخوانی (Recall) و امتیاز F_1 هســتند. طبق نتایج به‌دســت‌آمده، مدل پیشــنهادی موفق شــده اســت خطاهای داخلی را با دقت بسیار بالایی از سایر شرایط متمایز نماید.

برای مقایسه عملکرد مدل، نتایج آن با روش‌های مرسوم مبتنی بر آستانه‌گذاری جریان دیفرانسیل و همچنین روش‌هایادگیری ماشین کلاسیک مانند شبکه عصبی پرسپترون چندلایهو ماشین بردار پشتیبان مقایسه شده است. مقایسه‌ها نشان می‌دهند که مدل پیشنهادی نه‌تنها از نظر دقت کلی برتری دارد، بلکه به دلیل ساختار ترکیبی خود، نسبت به نویز و اعوجاج‌های نا شی از اشباع CT نیز مقاوم‌تر عمل می‌کند.

شکل (۲)، نمونه‌ای از سیگنال‌های جریان تفا ضلی ورودی به مدل پیشنهادی را در دو حالت خطای داخلی و جریان هجومی نشان می‌دهد. همان‌طور که ملاحظه می‌شود، جریان خطای داخلی (a) با افزایش ناگهانی دامنه و رفتار سینوسی متقارن همراه است، در حالی که جریان هجومی (b) دارای ماهیت غیر سینوسی، مؤلفه DC و میراشوندگی نمایی است. این تفاوت‌های ظریف

[Downloaded from jeps.dezful.iau.ir on 2026-10-21]
Journal of Novel Researches on Smart Power Systems - Vol. 15 - No. 1- Spring 2026

در الگوهای زمانی، زیربنای استخراج ویژگی توسط لایه‌های کانولوشن CNN و تحلیل وابستگی‌های زمانی توسط لایه‌های LSTM را تشکیل می‌دهند تا تمایز دقیق بین این دو پدیده میسر شود.

شکل (۳) ماتریس درهم‌ریختگی مدل پیشنهادی CNN-LSTM را در طبقه‌بندی پنج وضعیت عملیاتی مختلف ترانسفورماتور نشان می‌دهد. همان‌گونه که در این ماتریس مشاهده می‌شود، مدل به دقت کلی ۹۸٫۴٪ برروی داده‌های آزمون دست یافته است که نشان‌دهنده توانمندی بالای ساختار ترکیبیدر استخراج ویژگی‌های فضایی و تحلیل وابستگی‌های زمانی سیگنال‌های جریان تفاضلی است. بیشترین دقت تفکیک (۹۹٪) درکلاس‌های «عادی» و «خطای سه‌فاز» مشاهده می‌شود. در کلاس «جریان هجومی»، نرخ تشخیص صحیح ۹۷٪ ثبت شده است؛ تحلیل خطاها نشان می‌دهد که تعداد اندکی از نمونه‌های هجومی به دلیل شباهت شکلی در لحظات اولیه با خطاهای داخلی اشتباه شده‌اند، با این حال، میزان این خطا در مقایسه با کل نمونه‌ها بسیار ناچیز بوده و تأثیری بر پایداری سیستم حفاظت ترانسفورماتور نخواهد داشت.

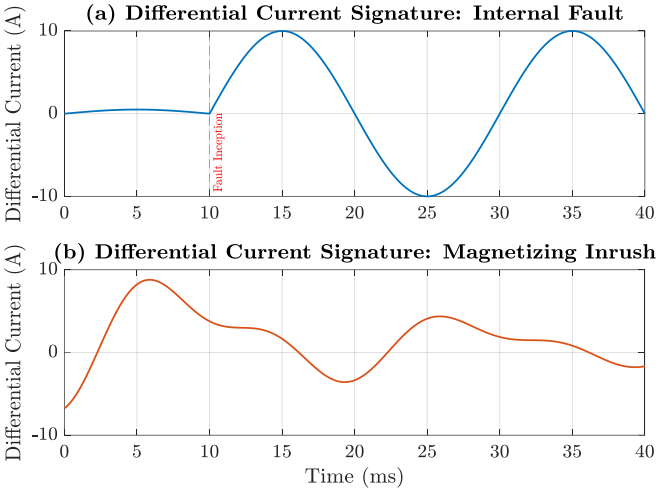

شکل (۲): نمونه‌ای از سیگنال‌های جریان تفاضلی ورودی به مدل پیشنهادی در دو حالت (a) خطای داخلی و (b) جریان هجومی

Figure (2): Example of differential current signals input to the proposed model in two cases (a) internal fault and (b) inrush current

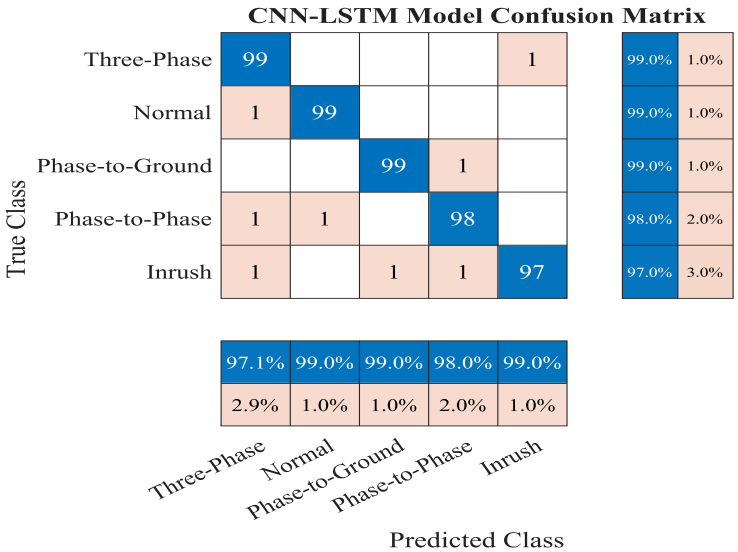

شکل (۳): ماتریس درهم‌ریختگی حاصل از پیاده‌سازی مدل بر روی داده‌های آزمون

Figure (3): Confusion matrix resulting from implementing the model on the test data

شکل (۴) روند همگرایی مدل پیشنهادی CNN-LSTM را در طول فرآیند آموزش نشان می‌دهد. همان‌گونه که مشاهده می‌شود، مقدار تابع هزینه در ابتدای آموزش در سطح بالاتری قرار داشته و با افزایش تعداد دوره‌ها به‌تدریج کاهش یافته است.

[Downloaded from jeps.dezful.iau.ir on 2026-10-21]
Journal of Novel Researches on Smart Power Systems - Vol. 15 - No. 1- Spring 2026

Table (3): Comparison of performance indicators of the proposed model with conventional methods

جدول (۳): مقایسه شاخص‌های عملکردی مدل پیشنهادی با روش‌های مرسوم

روش	دقت (Accuracy ٪)	صحت (Precision ٪)	فراخوانی (Recall ٪)	امتیاز (F_1 ٪)
آستانه‌گذاری سنتی	۸۷٫۵	۸۶٫۲	۸۵٫۰	۸۵٫۶
ماشین بردار پشتیبان (SVM)	۹۲٫۸	۹۱٫۵	۹۲٫۰	۹۱٫۷
پرسپترون چندلایه (MLP)	۹۴٫۲	۹۳٫۰	۹۳٫۵	۹۳٫۲
روش پیشنهادی (CNN-LSTM)	**۹۸.۸**	**۹۸٫۵**	**۹۸٫۹**	**۹۸٫۷**

هم‌زمان، دقت مدل نیز روندی صعودی داشته و پس از چند دوره ابتدایی به مقادیر بالاتری رسیده است. این رفتار نشان می‌دهد که شبکه توانسته الگوهای مؤثر موجود در سیگنال‌های جریان تفاضلی را به‌خوبی فراگرفته و در مسیر آموزش به یک پاسخ پایدار و همگرا دست یابد.

شکل ۵ عملکرد مدل را بر روی داده‌های اعتبارسنجی نمایش می‌دهد و برای بررسی قابلیت تعمیم آن به‌کار می‌رود. مطابق نتایج این شکل، کاهش تابع هزینه و افزایش دقت در مجموعه اعتبارسنجی نیز با روندی مطلوب و نزدیک به نتایج آموزش مشاهده می شود. نزدیکی منحنی‌های آموزش و اعتبار سنجی بیانگر آن است که مدل پیشنهادی دچار بیش‌برازش قابل‌توجه نشده و توانایی مناسبی در تعمیم‌پذیری به داده‌های دیده‌نشده دارد. این موضوع، کارایی ساختار ترکیبی CNN-LSTM را در یادگیری ویژگی‌های متمایزکننده سیگنال‌های جریان تفاضلی تأیید می‌کند.

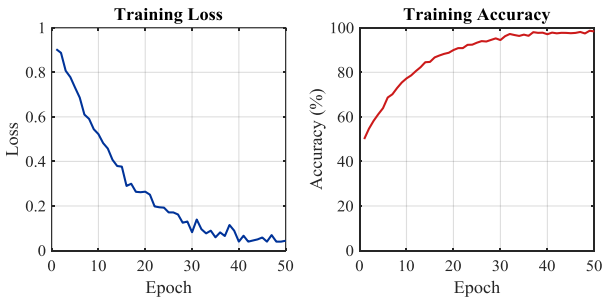

شکل (۴): روند تغییرات تابع هزینه و دقت مدل پیشنهادی CNN-LSTM در طول فرآیند آموزش

Figure (4): Trend of changes in the cost function and accuracy of the proposed CNN-LSTM model during the training process

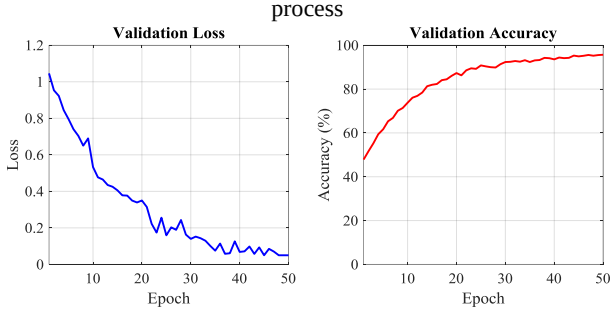

شکل (۵): روند تغییرات تابع هزینه و دقت مدل پیشنهادی CNN-LSTM در طول فرآیند اعتبارسنجی

Figure (5): Trend of changes in the cost function and accuracy of the proposed CNN-LSTM model during the validation process

نتایج به‌دست‌آمده نشان می‌دهند که مدل پیشنهادی قادر است الگوهای گذرای مربوط به خطاهای داخلی را با دقت مناسبی از جریان هجومی و حالت عادی تفکیک کند. این موضوع ناشی از آن است که لایه‌های CNN ویژگی‌های محلی و ساختارهای لحظه‌ای موجود در شکل موج را استخراج می‌کنند و لایه LSTM نیز وابستگی زمانی بین این ویژگی‌ها را در طول پنجره نمونه‌برداری تحلیل می‌کند. به همین دلیل، مدل پیشنهادی تنها به مقدار لحظه‌ای جریان متکی نیست، بلکه روند تغییرات آن

[Downloaded from jeps.dezful.iau.ir on 2026-10-21]
Journal of Novel Researches on Smart Power Systems - Vol. 15 - No. 1- Spring 2026

در زمان را نیز در تصمیم‌گیری لحاظ می‌کند. این ویژگی موجب افزایش قابلیت تشخیص در شرایطی می‌شود که شکل موج خطا شباهت زیادی به سایر وضعیت‌های گذرا دارد.

۵- نتیجه‌گیری

در این پژوهش، یک مدل ترکیبی مبتنی بر شبکه‌های عصبی کانولوشنی یک‌بعدی و حافظه کوتاه مدت بلند مدت (CNN-LSTM) به‌منظور تشخیص زودهنگام خطاهای داخلی سیم‌پیچ ترانسفورماتور قدرت ارائه شد. در ساختار پیشنهادی، لایه‌هایCNN با استخراج ویژگی‌های محلی و متمایزکننده از سیگنال جریان تفاضلی، اطلاعات مؤثر مربوط به شکل موج را شناسایی کردند و سپس لایه‌های LSTM با مدل‌سازی وابستگی‌های زمانی، امکان تفکیک دقیق‌تر حالت‌های مختلف بهره‌برداری و خطا را فراهم نمودند.

نتایج شبیه‌سازی نشان داد که مدل پیشنهادی در طول فرآیند آموزش از روند همگرایی مناسبی برخوردار بوده و با کاهش تابع هزینه و افزایش دقت، الگوهای مربوط به جریان‌های تفاضلی را به‌خوبی فراگرفته است. همچنین، عملکرد مطلوب مدل در داده‌های اعتبار سنجی نشان‌دهنده قابلیت تعمیم مناسب آن و نبود بیش‌برازش قابل‌توجه است. بر اساس نتایج به‌دست‌آمده، مدل CNN-LSTM توانست با دقتی در حدود ۹۸٫۸درصدوزمانپاسخ‌دهی تقریباً ۱۰ میلی‌ثانیه، خطاهای داخلی سیم‌پیچی را از جریان‌های هجومی و آثار ناشی از اشباع ترانسفورماتور جریان تفکیک کند. مقایسه با روش‌های SVM و MLP نیز بیانگر عملکرد بهتر مدل پیشنهادی از نظر دقت تشخیص و سرعت تصمیم‌گیری بود.

در مجموع، استفاده هم‌زمان از قابلیت استخراج ویژگی مکانیCNN و توانایی تحلیل توالی زمانی LSTM، موجب افزایش قابلیت اطمینان سامانه تشخیص خطا شده است. بااین‌حال، ارزیابی مدل در برابر تغییرات گسترده‌تر پارامترهای شبکه، نویزهای اندازه‌گیری، خطاهای ترکیبی و داده‌های واقعی آزمایشگاهی می‌تواند در پژوهش‌های آینده مورد توجه قرار گیرد. همچنین، ترکیب سیگنال‌های جریان تفاضلی با اطلاعات تکمیلی، مانند داده‌های تحلیل گازهای محلول در روغن، و بررسی معماری‌های پیشرفته‌تری نظیرTransformer (برخلاف LSTM که نمونه‌های سیگنال را عمدتاً به‌صورت متوالی پردازش می‌کند،Transformer می‌تواند وابستگی بین نمونه‌های دور از یکدیگر را مستقیم‌تر شناسایی کند و پردازش موازی‌تری داشته باشد.) می‌تواند به بهبود دقت تشخیص و افزایش قابلیت استفاده عملی از مدل در سامانه‌های حفاظتی ترانسفورماتور منجر شود.

References

[1] S. T. Zahra, S. K. Imdad, S. Khan, S. Khalid, and N. A. Baig, “Power transformer health index and life span assessment: A comprehensive review of conventional and machine learning based approaches,” *Engineering Applications of Artificial Intelligence*, vol. 139, pt. A, Art. no. 109474, Jan. 2025, doi: 10.1016/j.engappai.2024.109474.

[2] J. Amjad, A. Siddique, and W. Aslam, “Machine learning-based health index evaluation of power transformers using novel parameterization for predictive maintenance: Data-driven research on Pakistan’s national grid regarding maintenance cost optimization,” *Energies*, vol. 19, no. 15, Art. no. 3653, 2026, doi: 10.3390/en19153653.

[3] A.-M. Aciu, C.-I. Nicola, M.-C. Nițu, and M. Nicola, “Machine learning-based fault diagnosis of power transformers using a Duval pentagon combined complex and a weighted probabilistic ensemble,” *Machines*, vol. 14, no. 6, Art. no. 634, 2026, doi: 10.3390/machines14060634.

[4] A. A. Nazari, S. A. Hosseini, and B. Taheri, “Improving the performance of differential relays in distinguishing between high second harmonic faults and inrush current,” *Electric Power Systems Research*, vol. 223, Art. no. 109675, Oct. 2023, doi:10.1016/j.jestch.2025.102144.

[Downloaded from jeps.dezful.iau.ir on 2026-10-21]
Journal of Novel Researches on Smart Power Systems - Vol. 15 - No. 1- Spring 2026

[5] M. Oztekin, S. Karagol, and O. Ozgonenel, “Low-level inter-turn fault detection algorithm for transformer differential protection,” *Applied Sciences*, vol. 16, no. 14, Art. no. 7073, 2026, doi: 10.3390/app16147073.

[6] O. Surucu, S. A. Gadsden, and J. Yawney, “Condition monitoring using machine learning: A review of theory, applications, and recent advances,” *Expert Systems with Applications*, vol. 221, Art. no. 119738, Jul. 2023, doi:10.1016/j.eswa.2023.119738.

[7] M. H. Reza, M. N. B. Sibly, S. G. Rabbani, S. H. Sadi, M. F. Ahamed, F. B. Shafi, R. Sarmun, and M. E. H. Chowdhury, “A comprehensive review of convolutional neural networks: Foundations, enhancements and applications,” *Neural Computing and Applications*, vol. 38, Art. no. 56, 2026, doi:10.1007/s00521-025-11827-w.

[8] M. Krichen and A. Mihoub, “Long short-term memory networks: A comprehensive survey,” *AI*, vol. 6, no. 9, Art. no. 215, 2025, doi: 10.3390/ai6090215.

[9] F. Hafeez, Z. A. Arfeen, T. A. Jumani, M. I. Masud, N. Alkhaldi, A. Azhar, M. Aman, and M. K. Azam, “Hybrid LSTM-CNN model with temporal feature engineering and genetic algorithm optimization for temperature forecasting,” *Eng*, vol. 7, no. 5, Art. no. 224, 2026, doi: 10.3390/eng7050224.

[10] L. L. Mogotsi, A. Rasool, E. Matlotse, S. Ali, and A. Ali, “Intelligent fault detection of MV/HV transformers using fuzzy logic based on DGA,” *Eng*, vol. 6, no. 9, Art. no. 228, 2025, doi: 10.3390/eng6090228.

[11] H. Al Issa, M. Z. Qawaqzeh, S. Kurashkin, and O. Miroshnyk, “Monitoring of power transformers using thermal model and permission time of overload,” *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 12, no. 3, pp. 2323–2334, Jun. 2022, doi: 10.11591/ijece.v12i3.pp2323-2334.

[12] S. M. Ngong, F. M. Guy-de-patience, and N. N. Stephane, “A comparative study of power transformers windings diagnostic techniques: Part I,” *Discover Electronics*, vol. 2, Art. no. 14, 2025, doi:10.1016/j.meaene.2026.100112.

[13] O. Abdusalam, A. Ibrahim, F. Anayi, and M. Packianather, “New hybrid machine learning method for detecting faults in three-phase power transformers,” *Energies*, vol. 15, no. 11, Art. no. 3905, 2022, doi: 10.3390/en15113905.

[14] D. Bejmert, M. Kereit, F. Mieske, W. Rebizant, K. Solak, and A. Wiszniewski, “Power transformer differential protection with integral approach,” *International Journal of Electrical Power & Energy Systems*, vol. 118, Art. no. 105859, Jun. 2020, doi: 10.1016/j.ijepes.2020.105859.

[15] C.-W. Huang, C.-C. Fang, W.-T. Hsu, C.-C. Yang, and L.-T. Zhou, “Improving the protection of step-down transformers by utilizing percentage differential protection and scale-dependent intrinsic entropy,” *Entropy*, vol. 27, no. 4, Art. no. 444, 2025, doi: 10.3390/e27040444.

[16] C. Mo, T. Y. Ji, L. L. Zhang, and Q. H. Wu, “Equivalent statistics based inrush identification method for differential protection of power transformer,” *Electric Power Systems Research*, vol. 203, Art. no. 107664, Feb. 2022, doi: 10.1016/j.epsr.2021.107664.

[Downloaded from jeps.dezful.iau.ir on 2026-10-21]
Journal of Novel Researches on Smart Power Systems - Vol. 15 - No. 1- Spring 2026

[17] E. Ali, A. Helal, H. Desouki, K. Shebl, S. Abdelkader, and O. P. Malik, “Power transformer differential protection using current and voltage ratios,” *Electric Power Systems Research*, vol. 154, pp. 140–150, Jan. 2018, doi: 10.1016/j.epsr.2017.08.026.

[18] A. Feizbakhsh, H. Meyar-Naimi, and M. Vakilian, “An accurate method for detection and compensation of current transformer saturation using unscented Kalman filter,” *Electric Power Systems Research*, vol. 249, Art. no. 112015, Dec. 2025, doi: 10.1016/j.epsr.2025.112015.

[19] T. Liu, X. Zeng, H. Xie, W. Wu, and J. Xiao, “Method for identifying error states of distribution network current transformers based on current imbalance weights,” *Sustainable Energy Research*, vol. 12, Art. no. 42, 2025, doi:10.1186/s40807-025-00185-9.

[20] H. Cao, C. Zhou, Y. Meng, J. Shen, and X. Xie, “Advancement in transformer fault diagnosis technology,” *Frontiers in Energy Research*, vol. 12, 2024, Art. no. 1437614, Jul. 22, 2024, doi: 10.3389/fenrg.2024.1437614.

[21] B. Zhao, H. Lu, S. Chen, and D. Wu, “Convolutional neural networks for time series classification,” *Journal of Systems Engineering and Electronics*, vol. 28, no. 1, pp. 162–169, Feb. 2017, doi: 10.21629/JSEE.2017.01.18.

[22] J.-W. Kim, J.-H. Lee, D.-H. Son, S.-H. Choi, and K.-S. Park, “Comparative analysis of CNN and LSTM for bearing fault mode classification and causality through representation analysis,” *Lubricants*, vol. 14, no. 1, Art. no. 12, 2026, doi: 10.3390/lubricants14010012.

[23] Y. Wang, Z. Xiao, and G. Cao, “A convolutional neural network method based on Adam optimizer with power-exponential learning rate for bearing fault diagnosis,” *Journal of Vibroengineering*, vol. 24, no. 4, Jun. 2022, doi: 10.21595/jve.2022.22271.

[24] E. Akbari, “A Frequency-Domain Differential Protection Scheme Based on Discrete Laplace Transform Considering the Effects of Voltageand Current Transformers in Transmission Lines,” *Journal of Novel Researches on Smart Power Systems*, vol. 14, no. 2, pp. 35-59, Summer 2025 (in Persian).

[25] E. Akbari, “Fault Detection, Classification and Location in Compensated Transmission System Using Gabor Wavelet Transform and Traveling Wave Theory,” *Journal of Novel Researches on Smart Power Systems*, vol. 13, no. 2, pp. 1-17, Summer 2024 (in Persian).

زیرنویس‌ها:

[1] Convolutional Neural Network
[2] Long Short-Term Memory
[3] Support Vector Machines
[4] Multi Layer Perceptron
[5] Dissolved Gas Analysis
[6] Current Transformer

[Downloaded from jeps.dezful.iau.ir on 2026-10-21]
Journal of Novel Researches on Smart Power Systems - Vol. 15 - No. 1- Spring 2026