

Broken Conductor Fault Detection in Transmission Lines Connected to Renewable Energy-Based Microgrids

Hamid Reza Safa^{1,2}, *M.Sc Student*, Ali Asghar Ghadimi^{1,2}, *Associate Professor*

¹ *Department of Electrical Engineering, Faculty of Engineering, Arak University, Arak, Iran*

² *Research Institute of Renewable Energy, Arak University, Arak, Iran*

Abstract:

The connection of renewable energy-based microgrids in transmission lines has significantly increased recently. The presence of REMs, along with the advantages they provide, also leads to problems from different aspects of operation, control, and protection in transmission lines. The direct connection of REMs in the form of T-off in the transmission lines and without the construction of a substation, causes a severe disturbance in the performance of the protection algorithms of the line protection relays. This paper presents a fault detection method in transmission lines connected to REMs for early detection of Broken Conductor Fault (BCF) based on the information of one side of the line (the sending terminal) and using the teaching-learning artificial neural networks (ANNs). The neural network considered in this study is a combination of convolutional neural network and long short-term memory (CNN-LSTM). The hybrid model includes a Conv1D layer with 64 filters and a kernel size of 3, a MaxPooling1D layer, two LSTM layers with 32 units, a Dropout layer and a Dense layer with one unit and sigmoid activation. The necessary data for training the desired ANN have been extracted from the simulation of the main network and the implementation of various fault scenarios in MATLAB/Simulink software, and finally the considered ANN model has been programmed and modeled in the Python software environment. According to the simulation results, the accuracy of the extracted model in detecting the BCF in this proposed topology is estimated to be about 99.73%. The successful results presented in the test and evaluation results section confirm the optimal performance of the proposed algorithm.

Keywords: Broken conductor fault, Microgrid, Renewable energies, Artificial neural networks.

Received: 11 May 2024

Revised: 10 July 2024

Accepted: 08 August 2024

Corresponding Author: Dr. Ali Asghar Ghadimi, a-ghadimi@araku.ac.ir

DOI: 10.30486/TEEGES.2025.1119513



فناوری‌های نوین مهندسی برق در سیستم انرژی سبز

تشخیص وقوع خطای قطع فاز در خطوط انتقال متصل به ریزشبه‌های مبتنی بر انرژی‌های تجدیدپذیر

حمیدرضا صفا^۱، دانشجوی کارشناسی ارشد، علی اصغر قدیمی^۲، دانشیار

۱- گروه مهندسی برق، دانشکده مهندسی، دانشگاه اراک، اراک، ایران

۲- پژوهشکده انرژی‌های تجدیدپذیر، دانشگاه اراک، اراک، ایران

چکیده: اتصال ریزشبه‌های مبتنی بر انرژی‌های تجدید در خطوط انتقال بیش از پیش افزایش یافته است. حضور این ریزشبه‌ها در کنار مزایای که دارند اما معضلاتی را از مناظر مختلف بهره برداری، کنترل و حفاظت پیش می‌آورند. اتصال مستقیم این ریزشبه‌ها به صورت T-off در خطوط انتقال و بدون احداث پست، باعث اختلال شدید در عملکرد الگوریتم‌های حفاظتی خط می‌شود. در این مقاله یک روش تشخیص خطا در خطوط انتقال متصل به ریزشبه‌های مبتنی بر انرژی‌های تجدیدپذیر جهت تشخیص زود هنگام خطای قطع فاز مبتنی بر اطلاعات یک سمت خط (ترمینال ابتدای خط) و با استفاده از روش آموزش یادگیری شبکه‌های عصبی مصنوعی ارائه شده است. شبکه عصبی در نظر گرفته شده در این مقاله ترکیبی از نوع کانولوشنی و بازگشتی با دروازه‌های فراموشی (CNN_LSTM) می‌باشد. مدل ترکیبی شامل یک لایه Conv1D با ۶۴ فیلتر و سایز کرنل ۳، یک لایه MaxPooling1D، دو لایه LSTM با ۳۲ واحد، یک لایه Dropout و یک لایه Dense با یک واحد و فعال‌سازی سیگموئید است. دیتاهای لازم جهت آموزش شبکه عصبی مورد نظر از شبیه‌سازی شبکه اصلی و پیاده‌سازی سناریوهای مختلف خطا در سیمولینک نرم افزار متلب استخراج شده‌اند و در نهایت مدل شبکه عصبی مورد نظر در محیط نرم افزار پایتون برنامه نویسی و مدلسازی شده است. طبق نتایج شبیه‌سازی، دقت نهایی مدل استخراج شده در تشخیص خطای قطع فاز در این توپولوژی پیشنهادی حدود ۹۹/۷۳٪ ارزیابی شده است. نتایج موفقیت آمیز ارائه شده در قسمت نتایج تست و ارزیابی، موید عملکرد مطلوب الگوریتم پیشنهادی در این مقاله می‌باشد.

واژه‌های کلیدی: خطای قطع فاز، ریزشبه، انرژی‌های تجدیدپذیر، شبکه‌های عصبی مصنوعی.

تاریخ ارسال مقاله: ۱۴۰۳/۰۲/۲۲

تاریخ بازنگری مقاله: ۱۴۰۳/۰۴/۲۰

تاریخ پذیرش مقاله: ۱۴۰۳/۰۵/۱۸

نویسنده‌ی مسئول: دکتر علی اصغر قدیمی، a-ghadimi@araku.ac.ir

DOI: 10.30486/TEEGES.2025.1119513





۱- مقدمه

اتصال ریزشبهک‌ها با اهداف مختلف مطلوب بهره برداری به شبکه سراسری معضلات مختلفی را هم از نظر فنی بوجود می‌آورند. حضور تولیدات پراکنده^۱ مبتنی بر انرژی‌های تجدیدپذیر^۲ بادی و خورشیدی در این ریزشبهک به دلیل عدم قطعیت‌های مختلف در تولید باعث شده است که یک سناریوی واحد جهت بهره برداری ریزشبهک‌ها وجود نداشته باشد [۱]. این مسئله از نظر مسائل حفاظتی چالش‌های مختلفی را بوجود می‌آورد. عملکرد ناشناخته این ریزشبهک‌ها از دید طرح‌های حفاظتی بعنوان یک مسئله چالش بر انگیز همواره مطرح بوده است. زمانی که این ریزشبهک‌ها به صورت انشعاب فرعی وارد مدار می‌شوند، خط انتقال به دو بخش تقسیم بندی می‌شود. یک بخش بین ترمینال ابتدای خط تا ریزشبهک (بخش سمت چپ) و یک بخش دیگر بین ترمینال انتهایی خط و ریزشبهک (بخش سمت راست) می‌باشد. زمانی که اطلاعات نمونه برداری تنها از ترمینال ابتدای خط انجام می‌شود، تشخیص وقوع هر نوع خطا در بخش سمت راست توسط الگوریتم‌های حفاظتی طراحی شده دچار اختلال می‌شوند. به طور کلی خطاهای خطوط انتقال به دو بخش اتصال کوتاه و قطع فاز تقسیم بندی می‌شوند. در این مقاله چالش تشخیص خطای قطع فاز در خطوط انتقال متصل به ریزشبهک مبتنی بر انرژی‌های تجدید پذیر به صورت T-off بررسی شده است و یک روش هوشمند مبتنی بر اندازه گیری‌های جریان و ولتاژ ترمینال ابتدای خط جهت این چالش ارائه شده است. در ادامه به نقد و بررسی انواع پژوهش‌های منتشر شده در این زمینه پرداخته شده است.

در مرجع [۲]، روشی مبتنی بر مدت زمان کامل شدن یک سیکل کامل جریان جهت تشخیص خطای قطع فاز^۳ ارائه شده است. زمانی که خطای قطع فاز اتفاق می‌افتد، مدت زمان لازم جهت کامل شدن هر پریود جریان اندازه گیری شده توسط ترمینال ابتدای خط تغییر می‌کند، لذا در این مرجع از این روش جهت تشخیص وقوع خطای قطع فاز به صورت اتصال از یک سمت به زمین استفاده شده است. در همین راستا، در مراجع [۳، ۴]، با بهره گیری از روش‌های هوشمند شبکه عصبی مصنوعی^۴، روشی جهت تشخیص خطای قطع فاز در یک خطوط انتقال دومداره مبتنی بر مولفه‌های اساسی جریان اندازه گیری شده از یک سمت خط بدون نیاز به تنظیمات اولیه ارائه شده است. در یک مطالعه دیگر، با استفاده از ولتاژ پایانه‌های سمت فشار ضعیف ترانسفورماتورهای نصب شده بر روی هر تیر در شبکه توزیع، روشی جهت تشخیص خطای قطع فاز ارائه شده است. روش پیشنهادی در این مرجع به این صورت است که مقدار ولتاژ اندازه گیری شده با یک مقدار آستانه از پیش تعریف شده مقایسه می‌کند و اگر ولتاژ در یک یا چند فاز برای مدت زمان مشخصی از آستانه پایین تر بیاید، سیستم خطای مدار باز را در فاز(های) مربوطه شناسایی و سپس از طریق سیستم SCADA^۵ به مرکز کنترل سیستم هشدار افت ولتاژ را ارسال می‌کند تا اقدامات لازم انجام شود [۵]. در ادامه این مطالعات، در مرجع [۶]، از یک روش هوشمند مبتنی بر تکنولوژی‌های پیشرفته، دستگاه‌های الکترونیکی هوشمند، زیر ساخت‌های شی گرا و عمومی و دستگاه‌های منطقی جهت تشخیص خطاهای قطع فاز و امپدانس بالا در یک شبکه توزیع ۱۱ کیلو ولت ارائه شده است. روش پیشنهادی از نظر اقتصادی و مسائل پیاده سازی بسیار هزینه بر است. در مرجع [۷]، جهت تشخیص خطای قطع فاز و امپدانس بالا از روش ترکیبی آنالیز مولفه توالی منفی جریان خطا یا به عبارت دیگر فاکتور نامتعادلی و جریان و همچنین آنالیز موجک گسسته استفاده شده است. در صورت قطع یک فاز، جریان فازها نامتعادل شده است و باعث تولید مولفه‌های توالی منفی در خط می‌شود و از طرف دیگر از نقطه قوت تبدیل موجک نسبت به فوریه جهت آنالیز قوس ناشی از خطای امپدانس بالا استفاده شده است. ترکیب هر دو روش فوق باعث افزایش دقت و سرعت تشخیص این نوع از خطا شده است. در مرجع [۸]، از یک روش آنالیز تصویر برداری جهت تشخیص خطای قطع فاز استفاده شده است. در این مرجع، با استفاده از روش آستانه‌بندی تطبیقی پس از پیش پردازش با استفاده از روش نرم‌افزاری نرمال سازی واریانس خاکستری، ناحیه هادی از پس‌زمینه تصویر استخراج می‌شود. شکستگی هادی با استفاده از تبدیل موج مربعی از منحنی‌های توزیع مقادیر خاکستری آن که روشی ساده و کارآمد است، تشخیص داده می‌شود. در نهایت، با محاسبه تعداد رشته‌های شکسته و فیلتر کردن عیوب مشکوک، نتایج نهایی تشخیص عیب به دست می‌آید. در مرجع [۹]، یک روشی مبتنی بر آنالیز و مقایسه مقدار جریان اندازه گیری شده توسط ترمینال‌های خط با یک مقدار آستانه جهت تشخیص خطای قطع فاز به صورت زمان واقعی ارائه شده است. روش پیشنهادی در حقیقت بر اساس تفاوت جریان‌های مرجع پیش‌بینی شده و جریان‌های اندازه‌گیری شده عمل می‌کند. با استفاده از عوامل ضرب‌کننده جریان باقیمانده، جریان‌های مرجع پیش‌بینی شده در زمان واقعی محاسبه می‌شوند و سپس با جریان‌های اندازه‌گیری شده مقایسه می‌شوند. اگر تفاوت قابل توجهی بین این دو وجود داشته باشد، الگوریتم به عنوان نشانه‌ای از خطای قطع فاز در شبکه تشخیص می‌دهد. در مرجع [۱۰]، یک روشی مبتنی بر آنالیز دامنه هارمونیک سوم جریان و ولتاژ توالی صفر جهت تشخیص خطای قطع فاز ارائه شده است. در



صورت مقدار توان هارمونیک سوم اندازه گیری شده به طور ناگهانی کاهش یابد الگوریتم طراحی شده، خطای قطع فاز را تشخیص خواهد داد. در مرجع [۱۱]، یک منطق تشخیص خطای قطع فاز برای تقویت سیستم‌های حفاظتی با ترانسفورماتورهای تک فاز پیشنهاد شده است. روش پیشنهادی در این مرجع، جریان‌های اندازه‌گیری شده در شبکه را به سه مؤلفه متقارن مثبت، منفی و صفر تفکیک می‌کند، الگوی هر مؤلفه در شرایط خطا با شرایط عادی متفاوت است، لذا این روش با بررسی الگوی هر مؤلفه، می‌تواند خطا را تشخیص دهد. در مرجع [۱۲]، از مقایسه مؤلفه‌های جریان توالی مثبت، منفی و صفر در یک بازه زمانی مشخص جهت تشخیص خطای قطع فاز استفاده شده است. تغییر در مقدار این اختلاف زمانی برای یک سیکل با سیکل‌های قبل بعنوان معیاری جهت تشخیص خطای قطع فاز در نظر گرفته شده است. در مرجع [۱۳]، روشی مبتنی بر بهره‌گیری از شاخص انتگرال مقدار لحظه‌ای ولتاژهای فاز به فاز، جهت تشخیص خطای قطع فاز ارائه شده است. این شاخص به صورت غیرمستقیم زاویه بین ولتاژهای فاز به فاز را تخمین می‌زند. سپس، با مقایسه مقدار موثر ولتاژهای فاز به فاز، نیز خطاهای قطع فاز تشخیص داده می‌شوند. در این مرجع برای افزایش اطمینان از عملکرد الگوریتم، به جای استفاده از مقادیر مقایسه فاز، مقایسه اندازه ولتاژهای فاز به فاز نیز معرفی شده است. در ادامه در یک مطالعه دیگر، روشی جهت تشخیص خطای قطع فاز در شبکه‌های توزیع مبتنی بر واحد پایانه از راه دور فیدر ارائه شده است. روش ارائه شده در این مرجع، با ارزیابی جریان و ولتاژ در یک بازه زمانی و در نهایت با تشخیص شرایط غیر عادی مانند افت ولتاژ بیش از حد، قطعی جریان، تغییر مقدار امپدانس و ایجاد نامتعادلی جریان آلارم هشدار ایجاد شرایط بحرانی و به احتمال زیاد قطع فاز را صادر می‌کند [۱۴]. در ادامه مطالعه این مسئله، در مرجع [۱۵]، یک روش جدید جهت تشخیص خطای قطع فاز سمت بار با استفاده از اندازه‌گیری‌های یک سمت، بر روی خطوط توزیع هوایی ارائه شده است. روش تشخیص خطا ارائه شده در این مرجع، بدون وابستگی به اتصالات ترانسفورماتورهای سمت بار، بر اساس نسبت ثابت جریان توالی منفی به مثبت اندازه‌گیری شده در سمت تغذیه‌کننده استوار است. در مرجع [۱۶]، روشی جهت تشخیص خطای قطع فاز مبتنی بر افزایش ناگهانی مقدار جریان نول و مقایسه با دو حد آستانه ارائه شده است. عبور نرخ تغییرات جریان نول نسبت به زمان از این دو حد آستانه در یک فاصله زمانی مشخص بعنوان یک معیار ارزیابی جهت تشخیص خطای قطع فاز در این مرجع در نظر گرفته شده است. در ادامه این مطالعات در مرجع [۱۷]، از دو شاخص ترکیبی شامل ارزیابی شاخص افت شدید جریان و افزایش قابل توجه مقاومت فاز تخمینی جهت تشخیص خطای قطع فاز استفاده می‌کند. این روش به دنبال افت شدید مقدار دامنه جریان در یک فاز خاص در طول یک زمان از پیش تعیین شده است.

اگر بزرگی جریان در یک فاز به طور قابل توجهی در یک دوره زمانی مشخص کاهش یابد، این روش شکستگی هادی را در آن فاز تشخیص می‌دهد و در روش دوم، اگر مقاومت تخمینی یک فاز در طول یک دوره زمانی مشخص به طور قابل توجهی افزایش یابد، این روش هم همچنین شکستگی هادی را در آن فاز تشخیص می‌دهد. در مرجع [۱۸]، یک روشی جهت تشخیص خطای قطع فاز مبتنی بر شبکه‌های عصبی عمیق و با استفاده از سیگنال‌های جریان و ولتاژ یک ترمینال ارائه شده است. در این مرجع، روش پیشنهادی جهت افزایش دقت نتایج از تبدیل موجک جهت استخراج ویژگی‌های مفید سینگال‌های اندازه‌گیری بهره می‌برد. در مرجع [۱۹]، یک روش تشخیص خطای قطع فاز و امپدانس بالا در خطوط انتقال فشار قوی مبتنی بر تجزیه و تحلیل تبدیل موجک گسسته سینگال‌های جریان و ولتاژ ارائه شده است. عملکرد الگوریتم پیشنهادی در این مرجع، به طور قابل توجهی به انتخاب مقادیر آستانه مناسب برای شاخص‌های M و H بستگی دارد. شاخص M اطلاعات مربوط به حداکثر نوسان جریان را در هر فاز یا جریان زمین ارائه می‌دهد، در حالی که شاخص H اطلاعات مربوط به تفاوت بین نوسانات فرکانس بالای جریان در فازهای مختلف را ارائه می‌دهد. در نهایت با استفاده از شاخص‌های بیان شده، خطای قطع فاز و امپدانس توسط الگوریتم پیشنهادی در مرجع قابل تشخیص می‌باشند.

با توجه به مرور و بررسی پیشینه تحقیقات پیرامون خطای قطع فاز، شکاف تحقیقاتی مراجع پیشین و موضوع در نظر گرفته شده در این مقاله کاملاً مشخص است. روش‌های ارائه شده در مراجع پیشین تنها در خطوط انتقال ساده قابل پیاده سازی می‌باشند و در زمان حضور یک ریزش شبکه به صورت T-off و یا جبران‌ساز توان راکتیو و یا ادوات فکتس^۲ ناکارآمد می‌باشند. یکی از دلایلی که در این روش‌های می‌توان به طور عمده بیان کرد این است که روش‌های پیشنهادی اکثراً چالش قطع فاز را معادل با افت جریان شین در نظر می‌گیرند [۲۰] که این نکته تنها در خطوط انتقال ساده صادق است و در خطوط انتقالی که شامل یک ریزش شبکه به صورت T-off می‌باشند قابل پیاده سازی نمی‌باشند. از طرف دیگر به دلیل عدم قطعیت در تولیدات تجدید پذیر و عدم تعریف یک سناریوی واحد جهت شارش توان اکتیو و راکتیو، مسئله مطرح شده در این مقاله قابل فرمول بندی و تنظیم بندی به صورت یک راه حل کلی است، لذا این مسئله باعث ایجاد تمایز و شکاف تحقیقاتی بین روش پیشنهادی این مقاله و مراجع پیشین است.



سهم نوآوری و مشارکت این مقاله، ارائه یک روش هوشمند، جهت تشخیص خطای قطع فاز در خطوط انتقال متصل به ریزشبهک‌های مبتنی بر انرژی‌های تجدید پذیر با استفاده از دامنه و زاویه فاز نمونه‌های فازوری جریان و ولتاژ سه فاز ترمینال ابتدای خط (مجموعاً ۱۲ نمونه) و بدون نیاز به اطلاعات پارامترهای خط انتقال ارائه شده است. به طور کلی خطاهای قطع فاز در خطوط انتقال در حالت تعریف می شوند. یک حالت این است که هادی از دو طرف بریده و در هوا معلق می شود، یک حالت دیگر این است که از یک طرف در هوا معلق و از یک طرف به زمین برخورد می کند و در یک حالت دیگر اینکه از دو طرف فاز به زمین متصل می گردد. روش پیشنهادی مبتنی بر یک شبکه عصبی ترکیبی شامل دو ساختار عمده یادگیری عمیق، یعنی شبکه‌های عصبی پیچشی^۷ و شبکه‌های عصبی بازگشتی با دروازه‌های فراموشی^۸ تشکیل شده است. استفاده از این دو ساختار اصلی در یک مدل ترکیبی، امکان بهره‌گیری از ویژگی‌های مکانی و زمانی موجود در داده‌ها را فراهم می کند و باعث بهبود عملکرد و افزایش دقت مدل در تشخیص خطا می شود. این مدل ترکیبی جهت استخراج یک مدل دقیق به این صورت سازمان دهی شده است که در ابتدا از یک لایه Conv1D با اندازه هسته ۳ استفاده می شود که عملیات کانولوشن را جهت شناسایی الگوهای مختلف بر روی داده‌های ورودی پیاده سازی می کند. در این مدل از تابع فعال سازی ReLU و عملیات MaxPooling1D به ترتیب جهت اعمال تاثیر غیرخطی و کاهش ابعاد خروجی لایه قبل استفاده شده است. در ادامه از یک لایه LSTM با ۳۲ نورون جهت یادگیری، نگهداری اطلاعات زمانی و شناسایی الگوهای زمانی پیچیده با هدف نهایی پیش بینی خروجی استفاده شده است، سپس از یک لایه Dropout جهت جلوگیری از بیش پردازش مبتنی بر خاموش سازی تصادفی ۲۰ درصد از واحدهای خروجی استفاده شده است. در ادامه این مرحله از یک لایه LSTM دیگر با ۳۲ نورون بدون بازگشت به دنباله‌ها جهت تولید خروجی نهایی استفاده شده است، سپس از یک لایه Dense با یک واحد و تابع فعال سازی sigmoid برای تولید خروجی نهایی مدل استفاده شده است. این لایه اطمینان حاصل می کند که خروجی مدل بین مقادیر ۰ و ۱ قرار می گیرد، که برای مسائل طبقه بندی دودویی مناسب است. در این مرحله، مدل با استفاده از تابع هزینه آنتروپی متقاطع باینری و بهینه ساز Adam کامپایل می شود تا دقت نهایی نتایج افزایش یابد. در نهایت از یک معیار دقت جهت ارزیابی مدل با تعداد تکرار ۵ و اندازه دسته ۷۰ آموزش استفاده شده است. دقت نهایی مدل استخراج شده جهت تشخیص خطای قطع فاز در این روش پیشنهادی حدود ۹۹/۷۳٪ است. این درصد بالا از دقت نشان می دهد که مدل بسیار مناسب برای مسئله مورد نظر است و عملکرد مناسبی را ارائه می دهد. نوآوری های این مقاله به ترتیب به شرح ذیل است:


- ارائه یک الگوریتم تشخیص خطا قطع فاز در خطوط متصل به ریزشبهک به صورت T-off
- الگوریتم ارائه شده وابسته به پارامترهای خط انتقال شامل امپدانس و ادمیتانس نمی باشد.
- جهت تشخیص خطای قطع فاز از اطلاعات تنها یک ترمینال استفاده شده است.
- روش حل پیشنهادی ترکیبی از دو شبکه عصبی CNN و LSTM بوده است.
- روش پیشنهادی نسبت به دینامیک و مود عملکرد ریزشبهک مقاوم می باشد.

این مقاله به این گونه سازمان دهی شده است که در بخش دوم شبکه قدرت تحت مطالعه معرفی شده است، در ادامه در بخش سوم، روش پیشنهادی به طور کامل تشریح شده است. سپس در بخش چهارم نتایج تست و ارزیابی مدل استخراج شده برای سناریوهای مختلف انجام شده است و در بخش پنجم، نتیجه گیری و پیشنهاداتی جهت ادامه کار آینده این مسئله پژوهشی آورده شده است. در نهایت در بخش پایانی این مقاله یک پیوست مبتنی بر اطلاعات شبکه قدرت جهت مدلسازی نرم افزاری آورده شده است.

۲- معرفی مدل شبکه تحت مطالعه

شبکه قدرت در نظر گرفته شده در این مقاله در شکل (۱) نشان داده شده است. همان طور که در این شکل مشخص است، در نقطه T-off یک ریزشبهک به صورت مستقیم به خط انتقال بین شین‌های S و R متصل شده است و الگوریتم حفاظتی تنها از دیتاهای اندازه گیری شده از شین S با فرکانس ۲۴۰۰ هرتز جهت حفاظت خط استفاده می کند. از مدار معادل تونن، جهت نمایش شبکه‌های قدرت متصل به شین‌های R و S استفاده شده است. ریزشبهک در نظر گرفته شده در این طرح، مبتنی بر مزرعه بادی، مزرعه خورشیدی و مصرف مسکونی است. تمام المان‌های پیاده سازی شده در ریزشبهک به صورت دینامیکی مدلسازی شده‌اند. تمام اطلاعات شبکه تحت مطالعه در پیوست این مقاله آورده شده است.





شکل (۱): شماتیک خط انتقال متصل به ریزشبکه مبتنی بر انرژی‌های تجدید پذیر به صورت T-off.

۳- روش پیشنهادی حل مسئله

روش پیشنهادی جهت تشخیص خطای قطع فاز در این توپولوژی از سه قسمت اصلی یا سه بلوک تشکیل شده است. بلوک اول، شامل اطلاعات اندازه و زاویه جریان‌ها و ولتاژهای هر سه فاز اندازه‌گیری شده از ترمینال یک سمت خط در دوره خطا می‌باشند. بلوک دوم، شامل قسمت‌های مختلف آموزش، یادگیری و تست توسط ابزار ترکیبی CNN_LSTM است. در این بلوک مدل شبکه عصبی ترکیبی به طور کامل استخراج می‌گردد. بلوک سوم، مربوط به ماتریس درهم ریختگی است که کلاس بندی نتایج تشخیص و دسته بندی خطای قطع فاز را از حالت غیر قطع فاز نشان می‌دهد.

۳-۱- بلوک اول (پردازش اولیه)

در این بلوک داده‌های ورودی شامل اندازه و زاویه ولتاژ و جریان سه فاز در حوزه فازور با نرخ نمونه برداری ۲۴۰۰ هرتز می‌باشند. این داده‌ها توسط ترانسفورماتورهای جریان و ولتاژ اندازه‌گیری و بعنوان ورودی الگوریتم در نظر گرفته می‌شوند. ماتریس ترتیب داده‌های ورودی در فرمول (۱) آورده شده است. فرض در این مسئله بر این است که این داده‌ها به صورت دقیق و بدون خطا در اختیار الگوریتم قرار گرفته باشند. لازم به ذکر است که دامنه ولتاژها و جریان‌ها بر حسب ولتاژ و آمپر می‌باشند و زاویه آنها بر حسب درجه در نظر گرفته شده است. این داده‌ها به طور رندم حدود ۸۰ درصد آنها برای آموزش و حدود ۲۰ درصد برای تست در نظر گرفته شده‌اند.

$$Input = [abs(V_a), abs(V_b), abs(V_c), abs(I_a), abs(I_b), abs(I_c), angle(V_a), angle(V_b), angle(V_c), angle(I_a), angle(I_b), angle(I_c)] \quad (1)$$

۳-۲- بلوک دوم (CNN_LSTM)

توپولوژی در نظر گرفته شده در این مقاله به عنوان شبکه عصبی، ترکیبی از دو شبکه CNN و LSTM است. مدل ترکیبی CNN-LSTM از ویژگی‌های مکانی با CNN و ارتباطات زمانی با LSTM بهره می‌برد. این ترکیب امکان تشخیص الگوهای پیچیده‌تر و اطلاعات مکانی و زمانی مرتبط با خطا را فراهم می‌کند. CNN به عنوان یک شبکه عصبی کانولوشنال، قادر است الگوهای مهم و معنادار در داده‌ها را استخراج کند، به خصوص اطلاعات مکانی که برای شناسایی الگوها و ویژگی‌های داده مهم است. از طرف دیگر، LSTM به عنوان یک شبکه بازگشتی، می‌تواند وابستگی‌های زمانی بین داده‌ها را مدل کند و الگوهای زمانی را به خوبی تشخیص دهد. این ترکیب امکان تشخیص الگوهای پیچیده‌تر و اطلاعات مکانی و زمانی مرتبط با خطا را فراهم می‌کند. بدین ترتیب، مدل ترکیبی CNN-LSTM معمولاً دقت و عملکرد بهتری در تشخیص و طبقه‌بندی خطا نسبت به مدل‌های ساده‌تر مانند SVM، LSTM و GaussianNB ارائه می‌دهد.




۱-۲-۳- شبکه CNN

شبکه CNN، بعنوان یک شبکه قدرتمند جهت تشخیص و دسته بندی بسیار کارآمد است. این نوع شبکه‌های عصبی با ساختار عمیق و استفاده از عملیات کانولوشن، توانایی برتری در استخراج ویژگی‌ها و سپس انجام عملیات تشخیص را دارند. این شبکه شامل دو لایه، Con1D و MaxPooling1D می‌شود [۲۴-۲۱].

الف) لایه Con1D: این لایه در شبکه‌های CNN برای استخراج ویژگی‌های مهم از داده‌های ورودی استفاده می‌شود. در این مقاله، از یک لایه Con1D یک بعدی با ۶۴ فیلتر و اندازه کرنل ۳ استفاده شده است. در هر مرحله از اعمال فیلترها، عملیات کانولوشن انجام می‌شود. این به این معناست که هر فیلتر با یک قسمت از ورودی (با طول کرنل) راه می‌رود و یک عملیات محاسبه انجام می‌دهد. نتیجه این عملیات، یک مقدار (یا ویژگی) جدید است که به عنوان قسمتی از نتیجه خروجی این لایه استفاده می‌شود. همچنین در این مقاله، با استفاده از Padding، صفرهای مشخصی به ورودی اضافه شده است تا ابعاد خروجی برابر با ابعاد ورودی شود. این کار معمولاً برای حفظ اطلاعات مرزی در ورودی و جلوگیری از کاهش ابعاد در طول عملیات پیچشی استفاده شده است. برای درک بهتر مطلب یک عملکرد ساده از کرنل در لایه کانولوشن در شکل (۲) نشان داده شده است. در انتها، نتایج پیچش‌ها از طریق تابع فعال‌سازی (ReLU) می‌گذرند. تابع ReLU به صورت غیرخطی عمل می‌کند و از ایجاد همگرایی سریعتر شبکه عصبی بهره می‌برد. با اعمال این تابع، ویژگی‌های مهم از داده‌های ورودی استخراج می‌شوند و به لایه‌های بعدی ارسال می‌شوند. فرم کلی ریاضی این تابع در معادله (۲) آورده شده است. در ادامه در معادله (۳)، خروجی y_i برای هر ورودی x_i با استفاده از عملیات کانولوشن به هسته‌های k_{ij} و اضافه کردن بایاس b_j به نتایج، و سپس اعمال تابع فعال‌سازی f بر روی نتایج حاصل محاسبه می‌شود [۲۵] در فرمول‌های (۲) و (۳)، تعاریف پارمترهای x_i, y_i, f, k_{ij} و b_j به ترتیب، نقشه ورودی به لایه کانولوشن به صورت یک بردار، لایه خروجی، تابع فعال‌سازی، هسته کانولوشن (وزن‌های مربوط به فیلتر j برای ماتریس ورودی i) و بایاس ورودی j ام می‌باشند.

$$f(x) = \begin{cases} x, & \text{if } x > 0 \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

$$y_i = f(b_j + \sum_i k_{ij} * x_i) \quad (3)$$



شکل (۲): عملکرد کرنل در لایه کانولوشن.

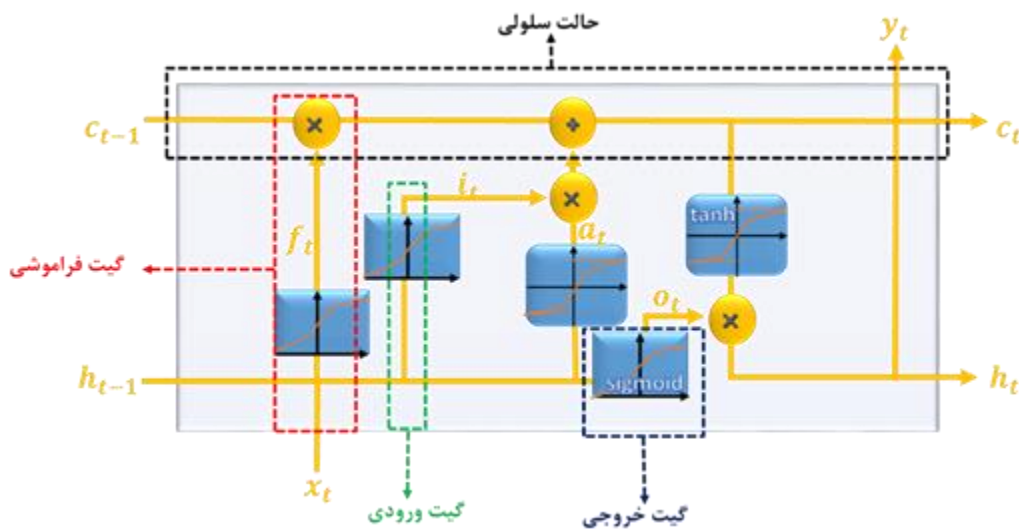
ب) لایه (MaxPooling1D): این لایه در شبکه‌های عصبی کانولوشنال عمیق برای کاهش ابعاد داده‌ها استفاده می‌شود. این لایه با استفاده از یک پنجره انتخابی با اندازه pool size روی ویژگی‌های ورودی حرکت می‌کند و بین این ویژگی‌ها، مقدار بزرگتر را انتخاب کرده و به عنوان ویژگی برجسته در ویژگی‌های خروجی اعمال می‌کند. در این فرآیند، هر واحد در نقشه خروجی y_i بر روی یک ناحیه $S \times S$ بدون همپوشانی در نقشه ورودی x_i جمع می‌شود. این عملیات به عنوان یک عملیات غیرپارامتریک شناخته می‌شود، زیرا در این لایه هیچ وزن قابل آموزشی وجود ندارد و تنها مقدار بزرگترین عنصر در هر پنجره انتخاب می‌شود و به عنوان خروجی تولید می‌شود. جهت محاسبه MaxPooling1D از معادله (۴) می‌توان استفاده کرد.

$$y_{ij} = \max_{0 \leq m \leq s} \{x_{i(j.s+m)}\} \quad (4)$$



LSTM یک نوع معماری قدرتمند از شبکه‌های عصبی بازگشتی است که برای مدل‌سازی و پیش‌بینی سری‌های زمانی مورد استفاده قرار می‌گیرد. در این مقاله از دو لایه LSTM به جای یک لایه استفاده شده است، که امکان مدل کردن ویژگی‌ها و الگوهای پیچیده‌تری را فراهم می‌کند و از یک لایه Dropout با نرخ $dropout=0.2$ که به عنوان یک لایه منظم‌سازی بین دو لایه LSTM استفاده شده است. این لایه با حذف تصادفی بخشی از ورودی‌ها، از بیش‌برازش جلوگیری می‌کند. با داشتن دو لایه LSTM، مدل توانایی بیشتری برای یادگیری و نگهداری اطلاعات از حالت‌های قبلی دارد. لایه اول LSTM می‌تواند الگوهای زمانی را در داده‌های ورودی تا حدی کشف کند و ویژگی‌های مهم را استخراج کند، در حالی که لایه دوم LSTM می‌تواند به عنوان یک متخصص در تجزیه و تحلیل ویژگی‌های بیشتر و بهتر از داده‌ها عمل کند. این کار باعث می‌شود که مدل توانایی بهبود پیش‌بینی‌ها و یادگیری الگوهای پیچیده‌تری را داشته باشد، به خصوص زمانی که داده‌ها دارای ساختار و ارتباطات پیچیده‌تری هستند.

در همین راستا استفاده از دو لایه LSTM می‌تواند بهبود عملکرد مدل و دقت تشخیص خطا را ارتقاء دهد. با توجه به شکل (۳) این معماری شامل چهار متغیر اصلی در هر واحد خود است: حالت سلولی، گیت ورودی، گیت خروجی، گیت فراموشی در واقع، از طریق این متغیرها، LSTM قادر است جریان سیگنال را مدیریت کند و میزان اطلاعاتی که از حالت قبلی نگه‌داشته شود را تعیین کند، این کار به این صورت است که، تابع فعال‌ساز تانژانت هایپربولیک (Tanh) به مقادیر در طول شبکه کمک می‌کند تا تنظیم شوند و همه مقادیر را به بازه‌ی -1 تا 1 می‌برد. این انتقال باعث می‌شود که عملیات ریاضی مختلف در طول شبکه بر روی بردارها انجام شود. تابع فعال‌ساز سیگموئید^۱ نیز در شبکه‌های عصبی LSTM وجود دارد و مقادیر را در بازه‌ی صفر تا ۱ قرار می‌دهد. این کار باعث می‌شود که بتوانیم در زمان به‌روزرسانی یا فراموش کردن داده از آن استفاده کنیم. گیت‌های فراموشی و ورودی نیز در فرآیند تصمیم‌گیری برای حفظ یا فراموش کردن اطلاعات موثر هستند. در نهایت، با آپدیت حالت سلول، مقادیر جدیدی برای استفاده در گام‌های بعدی تولید می‌شوند.



شکل (۳): معماری شبکه LSTM.

با توجه به شکل (۳) معادلات ساختار ریاضی LSTM به صورت معادلات (۵) الی (۱۰) قابل توصیف است.

$$f_t = \sigma(w_f(h_{t-1}, x_t) + b_f) \quad (۵)$$

$$i_t = \sigma(w_i(h_{t-1}, x_t) + b_i) \quad (۶)$$

$$a_t = \tanh(w_a(h_{t-1}, x_t) + b_a) \quad (۷)$$

$$c_t = f_t c_{t-1} + i_t a_t \quad (۸)$$

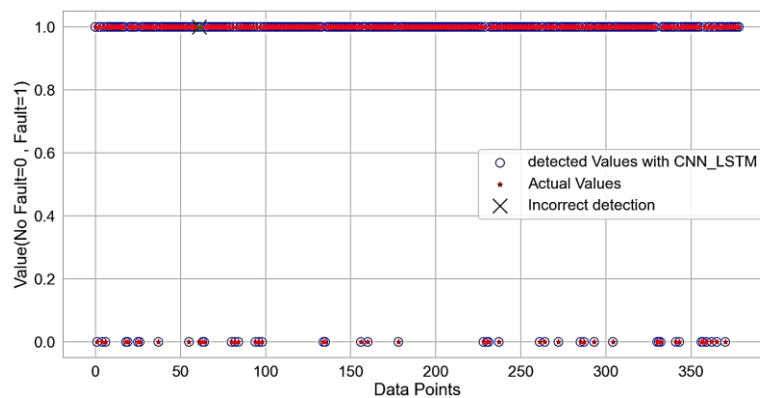
$$o_t = \sigma(w_o(h_{t-1}, x_t) + b_o) \quad (۹)$$

$$h_t = o_t \tanh(c_t) \quad (۱۰)$$



۳-۳- بلوک خروجی

در مرحله پایانی از لایه Dense با یک واحد و تابع فعال‌سازی سیگموئید، در مدل CNN_LSTM استفاده شده است که مسئول تولید خروجی نهایی مدل است. این لایه یک تابع فعال‌سازی سیگموئید استفاده می‌کند که خروجی را به بازه [۰، ۱] تغییر می‌دهد [۲۶، ۲۷]. در این مقاله برای حالت دو کلاسه که برای تشخیص داده‌های در حالت خطا و بدون خطا استفاده شده است. در ادامه در شکل (۴)، نتایج حاصل از پیاده‌سازی الگوریتم نهایی در قالب عملکرد تشخیص و عدم تشخیص آورده شده است. همان‌طور که در این شکل مشاهده می‌شود، تنها در یک مورد قادر به شناسایی دقیق وقوع خطای فاز نبوده است و بجز آن یک مورد، در تمام موارد به درستی خطای قطع فاز را تشخیص داده است. در شکل (۵) نتایج ماتریس درهم‌ریختگی نشان داده شده است. این ماتریس، تعداد نمونه‌هایی که به درستی یا به اشتباه تشخیص و دسته‌بندی شده‌اند، را به صورت ماتریسی نمایش می‌دهد. این ماتریس شامل چهار خانه اصلی است که عملکرد مدل در تشخیص خطا را در این کار نمایش می‌دهد. پارامترهای TP، FP، TN و TP به ترتیب برابر با، تعداد نمونه‌های که به درستی به عنوان خطا تشخیص و طبقه‌بندی شده، تعداد نمونه‌های که به عنوان خطا به اشتباه تشخیص و طبقه‌بندی شده، تعداد نمونه‌های که به درستی به عنوان بدون خطا تشخیص و طبقه‌بندی شده‌اند و تعداد نمونه‌های که به اشتباه به عنوان عدم خطا تشخیص و طبقه‌بندی شده‌اند را نشان می‌دهند. در شکل (۶)، فلوجارت نهایی طرح تشخیص خطای قطع فاز به صورت یک الگوریتم ترکیبی پیشنهادی آورده شده است. در ماتریس درهم‌ریختگی شکل (۵)، مدل پیشنهادی تعداد ۴۴ نمونه "بدون خطا" را به درستی (TN) و ۳۳۴ نمونه "خطا" را به درستی (TP) تشخیص داده است. همچنین، تنها یک نمونه "بدون خطا" را به اشتباه به عنوان "خطا" (FP) و هیچ نمونه "خطا" را به اشتباه به عنوان "بدون خطا" (FN) تشخیص نداده است. این نتایج نشان‌دهنده عملکرد بسیار خوب مدل با نرخ خطای بسیار پایین است. تنها نقطه ضعف جزئی مدل، یک مورد FP است که نشان‌دهنده تعداد بسیار کمی از خطاهای مثبت کاذب است.

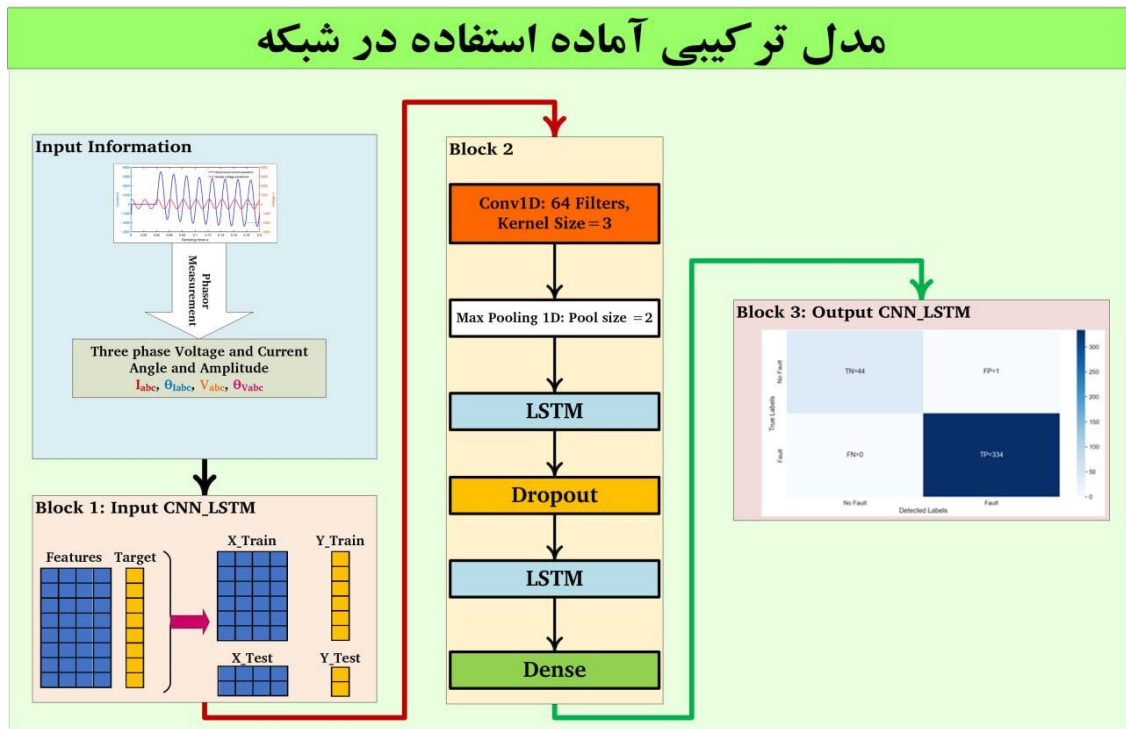


شکل (۴): عملکرد مدل در تشخیص خطا.



شکل (۵): نتایج ماتریس درهم‌ریختگی.





شکل (۶): فلوچارت عملکرد مدل ترکیبی پیشنهادی.

۴- نتایج تست و مقایسه

در این مقاله جهت ارزیابی مدل‌ها از مفاهیم آماری شناخته‌شده‌ای مانند Accuracy, Precision, Recall, F1-Score استفاده شده است. این معیارهای ارزیابی ریاضیاتی می‌توانند به صورت زیر بیان شوند [۲۸, ۲۹].

Accuracy: این معیار نشان می‌دهد که مدل در کل چه درصدی از داده‌ها را به درستی تشخیص داده است.

Precision: این معیار نشان می‌دهد که از تمام خطاهایی که مدل تشخیص داده است، چه تعدادی از آن‌ها واقعاً خطا بوده‌اند.

Recall: این معیار نشان دهنده توانایی مدل در تشخیص است.

F1-Score: میانگین هندسی از دقت و بازیابی است (این معیار ترکیبی از دقت و بازیابی است و جهت ایجاد تعادل استفاده می‌گردد). در معادلات (۱۱) الی (۱۴) فرمولاسیون توصیف کننده شاخص‌های فوق آورده شده است.

$$\text{Accuracy} = \frac{(TP+TN)}{(TP+TN+FP+FN)} \times 100 \quad (11)$$

$$\text{Precision} = \frac{TP}{(TP + FP)} \quad (12)$$

$$\text{Precision} = \frac{TP}{(TP + FN)} \quad (13)$$

$$F1 - \text{score} = \frac{2 \times (\text{Precision} \times \text{Recall})}{(\text{Precision} + \text{Recall})} \quad (14)$$

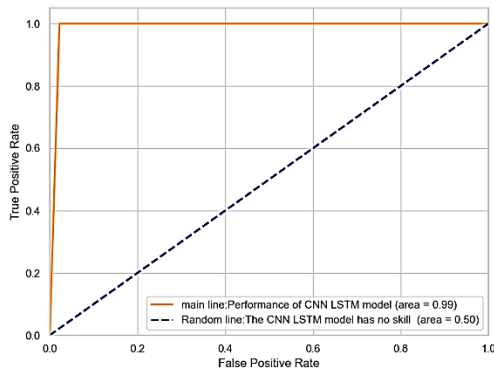
مدل CNN_LSTM با دقت کلی ۰/۹۹۷۳ دارای بهترین عملکرد است و در تمامی معیارها از جمله دقت، بازخوانی و امتیاز F1 برای هر دو کلاس ۰ و ۱ نتایج عالی نشان می‌دهد. مدل‌های SVM و LSTM نیز با دقت‌های کلی ۰/۹۸۹ و ۰/۹۹۲ و امتیازهای F1 بالا عملکرد قوی دارند و دقت و بازخوانی بالایی برای هر دو کلاس ارائه می‌دهند. مدل GaussianNB با دقت کلی ۰/۹۷۸ و امتیاز F1 نسبتاً پایین‌تر، ضعیف‌ترین عملکرد را دارد. با وجود عملکرد خوب مدل‌های SVM و LSTM، نقطه ضعف آن‌ها نسبت به CNN_LSTM این است که قادر به تطبیق بهتر با پیچیدگی‌های داده‌ها نیستند. برای دستیابی به بالاترین دقت، بازخوانی و امتیاز F1 در هر دو کلاس، مدل CNN_LSTM توصیه می‌شود، زیرا با حفظ تعادل بین این معیارها، نتایج بهتری نسبت به سایر مدل‌ها ارائه می‌دهد.



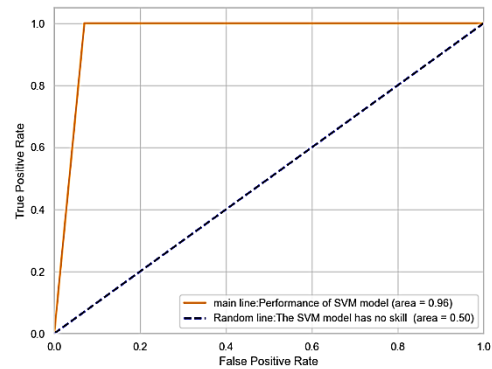
جدول (۱): نتایج حاصل از تست و مقایسه الگوریتم‌های پیشین و الگوریتم پیشنهادی.

Method	Class	Precision	Recall	F1-Score	Accuracy
SVM	۰	۱/۰	۰/۹۳	۰/۹۶	۰/۹۸۹
	۱	۰/۹۹	۱/۰	۰/۹۹	
GaussianNB	۰	۱/۰	۰/۸۶	۰/۹۲	۰/۹۷۸
	۱	۰/۹۸	۱/۰	۰/۹۹	
LSTM	۰	۱/۰	۰/۹۵	۰/۹۷	۰/۹۹۲
	۱	۰/۹۹	۱/۰	۱/۰	
CNN_LSTM	۰	۱/۰	۰/۹۸	۰/۹۹	۰/۹۹۷۳
	۱	۱/۰	۱/۰	۱/۰	


در شکل (۷)، نمودار خط مشخصه ویژگی‌های عملکرد گیرنده^{۱۰}، نشان داده شده است. این خط نمایانگر عملکرد مدل در تشخیص درست خطا است. با مقایسه عملکرد مدل با خط تصادفی، می‌توان ارزیابی کرد که مدل در چه وضعیتی قرار دارد. زمانی که مدل در خط تصادفی قرار می‌گیرد، به این معناست که عملکرد آن به صورت تصادفی است و هیچ توانایی یا نقشی در تشخیص خطا ندارد؛ به عبارت دیگر، در بدترین وضعیت ممکن قرار دارد. در این مقاله مقدار مساحت زیر منحنی ROC برای مدل ترکیبی، برابر با ۰/۹۹ است، نشان می‌دهد که مدل به خوبی قادر به تفکیک و تشخیص درست خطای قطع فاز در خط انتقال نسبت به بقیه مدل‌ها بوده است.



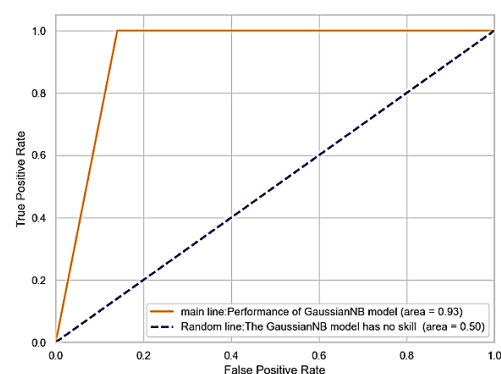
(ب)



(الف)



(د)



(ج)

شکل (۷): منحنی‌های ویژگی‌های عملکرد گیرنده برای تشخیص خطای قطع فاز برای مقایسه مدل پیشنهادی با مدل‌های مختلف

الف) SVM، ب) CNN_LSTM، ج) Gaussian NB، د) LSTM.



۵- نتیجه گیری

این مقاله به حل چالش خطای قطع فاز در خطوط انتقال متصل به ریزش شبکه مبتنی بر انرژی‌های تجدید پذیر به صورت T-off پرداخته است. روش ارائه شده در این مقاله، مبتنی بر آموزش و یادگیری شبکه‌های عصبی ترکیبی CNN_LSTM طرح ریزی شده است. داده‌های لازم جهت پیاده سازی این روش مبتنی بر اندازه و زاویه فازورهای جریان و ولتاژ سه فاز یک ترمینال در نظر گرفته شده است. یکی از چالش‌های قطع فاز در این توپولوژی‌های وجود تزریق از طریق ریزش شبکه به صورت T-off است، که افت جریان در محل ترمینال اندازه گیری قابل اندازه گیری ناست، که در این مقاله این چالش حل شده است. شبکه عصبی در نظر گرفته شده در این مقاله از سه زیر بلوک اساسی تشکیل شده است. این سه زیر بلوک شامل، بلوک پردازش اولیه، بلوک CNN_LSTM (شبکه CNN شامل دو زیر لایه، Con1D و MaxPooling1D) و بلوک خروجی و نتایج است. در بلوک اول، داده‌ها به نسبت ۸۰ درصد برای آموزش و ۲۰ درصد برای آزمون به صورت تصادفی تقسیم شده‌اند، در ادامه در بلوک دوم، مدل ترکیبی با داده‌های آموزش دیده و با ۲۰ درصد داده‌های آزمون ارزیابی شده است و در بلوک سوم خروجی به صورت یک ماتریس درهم ریختگی تولید شده است. در این روش پیشنهادی برای نمایش وضعیت مدل، که در چه میزان در حالت نرمال عمل می‌کند و از حالت تصادفی دور است، و همچنین بررسی عملکرد آن نسبت به سایر مدل‌ها، از نمودار ROC استفاده شده است. مقدار مساحت زیر منحنی ROC برای مدل ترکیبی برابر با ۰/۹۹ است که نشان دهنده‌ی عملکرد مطلوب مدل پیشنهادی است. طبق نتایج خروجی، مدل پیشنهادی با دقت ۹۹/۷۳ درصد در تشخیص خطا، از سایر مدل‌های مانند SVM، Gaussian-NB و LSTM عملکرد بهتری داشته است. همچنین، در هر دو کلاس (۰ و ۱)، معیارهای Recall، Precision و شاخص امتیاز F1 بالایی را به دست آورده است که نشان از قدرت و کارایی بالای مدل CNN_LSTM در تشخیص خطا قطع فاز است.





پیوست

جدول (الف): اطلاعات پارامترهای خطوط انتقال.

پارامترهای خط	مقادیر پارامترها
L_T	۳۰۰
F	۶۰
r_1	۰/۰۲۵۴۶
l_1	۰/۹۳۳۷ e-۳
c_1	۱۲/۷۴ e-۹
r_0	۰/۳۸۶۴
l_0	۴/۱۲۶۴ e-۳
c_0	۷/۷۵۱ e-۹
r_{m0}	۰/۱۷۳۲
l_{m0}	۲/۰۱۲۶۴ e-۳
c_{m0}	-۰/۵۷۵۱ e-۹

جدول (ج): اطلاعات فنی CT و CVT.

پارامترها	مقادیر
V_n	۲۳۰
f	۶۰
R_{s_CT}	۰/۵
L_{s_CT}	۰/۸
N_{CT}	۱۰۰۰:۱
A_{CT}	۶/۵
L_{CT}	۰/۶
R_{p_CT}	۱/۴
L_{L_CT}	۱/۲
R_{p_CVT}	۰/۱۲۵
L_{L_CVT}	۰/۱۲۵
N_{CVT}	۲۰۰:۱
C_{CVT}	۰/۵ و ۲/۲
L_{CVT}	۲۵۳/۴

جدول (ب): اطلاعات ترانسفورماتور متصل به ریزشبه.

پارامترها	ترانسفورماتور متصل به نقطه
V_{1n}	۲۳
V_{2n}	۲۳۰
S_n	۱۰ e۶
F	۶۰
R_{LV}	۰/۰۰۲
L_{LV}	۰/۰۸
R_{HV}	۰/۰۰۲
L_{HV}	۰/۰۰۲
R_m	۵۰۰
L_m	۵۰۰
اتصال سیم پیچ فشار ضعیف	مثلث
اتصال سیم پیچ فشار قوی	ستاره

جدول (د): اطلاعات کامل لازم جهت مدلسازی مزرعه خورشیدی.

پارامترها	مقادیر
Model	SunPower SPR-415E-WHT-D
N_{S_SF}	۱۵۰
N_{P_SF}	۲۰۰۰
B_{SF}	۵۰۰۰ e-۹
T_w	۴۵
K_n	۱۰۰۰
Q_n	۲۰
Type	لیتومی
V_n	۷۰۰۰
S_n	۸۰۰
Ch_s	۱۰۰
t_a	۱
R_{SF_d}	۰/۰۰۳
L_{SF_d}	۵/۷۶ e-۴
C_{SF_d}	۱ e-۳

جدول (ه): مشخصات مزرعه بادی.

پارامترها	مقادیر	پارامترها	مقادیر
توان نامی	۵/۱ مگاوات	مقاومت رتور	۰/۰۱۶
ولتاژ نامی	۵۷۵ ولت	اندوکتانس رتور	۰/۱۶
فرکانس	۶۰ هرتز	ثابت اینرسی	۰/۶۸
مقاومت استاتور	۰/۰۲۳	ضریب اصطکاک	۰/۱
اندوکتانس استاتور	۰/۱۸	تعداد قطبها	۶



- [1] M. Abasi, A. Rohani, F. Hatami, M. Joorabian, and G. B. Gharehpetian, "Fault location determination in three-terminal transmission lines connected to industrial microgrids without requiring fault classification data and independent of line parameters," *International Journal of Electrical Power and Energy Systems*, vol. 131, 2021, doi: 10.1016/j.ijepes.2021.107044.
- [2] A. Pongthavornsawad and W. Rungseevijitprapa, "Broken conductor detection for overhead line distribution system," in *Asia-Pacific Power and Energy Engineering Conference, APPEEC*, 2011. doi: 10.1109/APPEEC.2011.5749066.
- [3] E. Koley, A. Yadav, and A. S. Thoke, "Artificial Neural Network based Protection Scheme for One Conductor Open Faults in Six Phase Transmission Line," *Int J Comput Appl*, vol. 101, no. 4, 2014, doi: 10.5120/17678-8522.
- [4] A. Narayan and R. Sharma, "ANN based Open Conductor Fault Detector for Protection of Two Parallel Circuit Transmission Line," *International Research Journal of Engineering and Technology*, vol. 6, no. 1, pp. 87–92, 2019.
- [5] S. K. Lau and S. K. Ho, "Open-circuit fault detection in distribution overhead power supply network," *Journal of International Council on Electrical Engineering*, vol. 7, no. 1, 2017, doi: 10.1080/22348972.2017.1385440.
- [6] V. Mariappan and A. B. S. M. Rayees, "Optimal solution to isolate the high impedance/ broken conductor fault in 11 kv overhead line in distribution network," in *IET Conference Publications*, 2017. doi: 10.1049/cp.2017.0328.
- [7] D. K. J. S. Jayamaha, I. H. N. Madhushani, R. S. S. J. Gamage, P. P. B. Tennakoon, J. R. Lucas, and U. Jayatunga, "Open conductor fault detection," in *3rd International Moratuwa Engineering Research Conference, MERCon 2017*, 2017. doi: 10.1109/MERCon.2017.7980511.
- [8] Y. Zhang, X. Huang, J. Jia, and X. Liu, "A Recognition Technology of Transmission Lines Conductor Break and Surface Damage Based on Aerial Image," *IEEE Access*, vol. 7, 2019, doi: 10.1109/ACCESS.2019.2914766.
- [9] A. C. Adewole, A. Rajapakse, D. Ouellette, and P. Forsyth, "Residual current-based method for open phase detection in radial and multi-source power systems," *International Journal of Electrical Power and Energy Systems*, vol. 117, 2020, doi: 10.1016/j.ijepes.2019.105610.
- [10] X. Wang and W. Xu, "A 3rd harmonic power based open conductor detection scheme," *IEEE Transactions on Power Delivery*, vol. 36, no. 2, 2021, doi: 10.1109/TPWRD.2020.3001075.
- [11] D. V. Joao, H. G. B. Souza, and M. A. I. Martins, "Broken conductor fault detection using symmetrical components in distribution power systems - An implementation case," in *2021 IEEE PES Innovative Smart Grid Technologies Conference - Latin America, ISGT Latin America 2021*, 2021. doi: 10.1109/ISGTLatinAmerica52371.2021.9543045.
- [12] S. V. Fernandes, D. V. Joao, M. A. I. Martins, H. G. B. Souza, A. F. MacEdo, and K. A. Martins, "A Symmetrical Component Evaluation for Broken Conductor Fault Detection," in *2021 6th International Conference for Convergence in Technology, I2CT 2021*, 2021. doi: 10.1109/I2CT51068.2021.9417933.
- [13] M. M. Ostojić and Z. N. Stojanović, "An algorithm with voltage inputs for detecting conductor breaks in radial distribution networks," *International Transactions on Electrical Energy Systems*, vol. 31, no. 12, 2021, doi: 10.1002/2050-7038.13195.
- [14] J. S. Hong, S. Y. Hyun, Y. W. Lee, J. H. Choi, S. J. Ahn, and S. Y. Yun, "Detection of Open Conductor Fault Using Multiple Measurement Factors of Feeder RTUs in Power Distribution Networks with DGs," *IEEE Access*, vol. 9, 2021, doi: 10.1109/ACCESS.2021.3121880.
- [15] A. G. Al-Baghdadi, M. K. Abd, and F. M. F. Flaih, "A New Detection Method for Load Side Broken Conductor Fault Based on Negative to Positive Current Sequence," *Electronics (Switzerland)*, vol. 11, no. 6, 2022, doi: 10.3390/electronics11060836.
- [16] D. V. Joao, H. G. B. Souza, M. A. I. Martins, and K. A. Martins, "Pick-ups Counter Methodology for Broken Conductor Fault Detection," in *Proceedings of the IEEE Power Engineering Society Transmission and Distribution Conference*, 2022. doi: 10.1109/TD43745.2022.9816972.
- [17] K. Dase, J. Colwell, and S. Pai, "Novel Methods for Detecting Conductor Breaks in Power Lines," in *76th Annual Conference for Protective Relay Engineers*, College Station, Texas, Mar. 2023, pp. 1–13.





- [18] J. Che, T. Kim, S. Pyo, J. Park, B. An, and T. Park, "Prevention of Wildfires Using an AI-Based Open Conductor Fault Detection Method on Overhead Line," *Energies (Basel)*, vol. 16, no. 5, 2023, doi: 10.3390/en16052366.
- [19] B. A. E. Rashad, D. K. Ibrahim, M. I. Gilany, A. S. Abdelhamid, and W. Abdelfattah, "Identification of broken conductor faults in interconnected transmission systems based on discrete wavelet transform," *PLoS One*, vol. 19, no. 1 January, 2024, doi: 10.1371/journal.pone.0296773.
- [20] M. Abasi, N. Heydarzadeh, and A. Rohani, "Broken Conductor Fault Location in Power Transmission Lines Using GMDH Function and Single-Terminal Data Independent of Line Parameters," *Journal of Applied Research in Electrical Engineering*, vol. 1, no. 1, pp. 22–32, 2021.
- [21] A. Shrestha and A. Mahmood, "Review of deep learning algorithms and architectures," *IEEE Access*, vol. 7. 2019. doi: 10.1109/ACCESS.2019.2912200.
- [22] P. K. Shukla and K. Deepa, "Deep learning techniques for transmission line fault classification – A comparative study," *Ain Shams Engineering Journal*, vol. 15, no. 2, 2024, doi: 10.1016/j.asej.2023.102427.
- [23] J. Hu, Z. Liu, J. Chen, W. Hu, Z. Zhang, and Z. Chen, "A novel deep learning-based fault diagnosis algorithm for preventing protection malfunction," *International Journal of Electrical Power and Energy Systems*, vol. 144, 2023, doi: 10.1016/j.ijepes.2022.108622.
- [24] A. Moradzadeh, B. Mohammadi-Ivatloo, M. Abapour, A. Anvari-Moghaddam, S. Gholami Farkoush, and S. B. Rhee, "A practical solution based on convolutional neural network for non-intrusive load monitoring," *J Ambient Intell Humaniz Comput*, vol. 12, no. 10, 2021, doi: 10.1007/s12652-020-02720-6.
- [25] J. Liu, M. Osadchy, L. Ashton, M. Foster, C. J. Solomon, and S. J. Gibson, "Deep convolutional neural networks for Raman spectrum recognition: A unified solution," *Analyst*, vol. 142, no. 21, 2017, doi: 10.1039/c7an01371j.
- [26] A. Moradzadeh, S. Zakeri, M. Shoran, B. Mohammadi-Ivatloo, and F. Mohammadi, "Short-term load forecasting of microgrid via hybrid support vector regression and long short-term memory algorithms," *Sustainability (Switzerland)*, vol. 12, no. 17, 2020, doi: 10.3390/su12177076.
- [27] M. Abedini, R. Eskandari, J. Ebrahimi, M. H. Zeinali, and A. Alahyari, "Optimal Placement of Power Switches on Malayer Practical Feeder to Improve System Reliability Using Hybrid Particle Swarm Optimization with Sinusoidal and Cosine Acceleration Coefficients," *Scientific Journal of Computational Intelligence in Electrical Engineering*, vol. 11, no. 2, pp. 73–86, 2020, doi: 10.22108/isee.2020.119480.1286.
- [28] M. O. F. Goni *et al.*, "Fast and Accurate Fault Detection and Classification in Transmission Lines using Extreme Learning Machine," *e-Prime - Advances in Electrical Engineering, Electronics and Energy*, vol. 3, 2023, doi: 10.1016/j.prime.2023.100107.
- [29] J. Ebrahimi and M. Abasi, "Design of a Power Management Strategy in Smart Distribution Networks with Wind Turbines and EV Charging Stations to Reduce Loss, Improve Voltage Profile, and Increase Hosting Capacity of the Network," *Journal of Green Energy Research and Innovation*, vol. 1, no. 1, pp. 1–15, Mar. 2024, doi: 10.61186/jgeri.1.1.1.

زیر نویس ها

-
- ¹ Distributed Generation (DG)
² Renewable
³ Broken conductor fault (BCF)
⁴ ANN
⁵ Supervisory Control and Data Acquisition
⁶ FACTS
⁷ CNN
⁸ LSTM
⁹ Sigmoid
¹⁰ ROC

