

ارائه یک الگوریتم مبتنی بر یادگیری عمیق برای آشکارسازی خروج از همگامی در ژنراتورهای سنکرون

سجاد نفرخلج^۱، تورج امرایی^۲

^۱ دانشجوی کارشناسی ارشد، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران
S.nafarkhalaj@email.kntu.ac.ir

^۲ دانشیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران
Amraee@kntu.ac.ir

چکیده

ژنراتور سنکرون، به عنوان هسته شبکه قدرت وظیفه مهم تولید توان را ایفا می‌کند. این تجهیزات در معرض اختلالات مختلفی مانند خطاها و تغییرات بار قرار دارند. اگر توازن بین توان مکانیکی ورودی به ژنراتور و توان الکتریکی خروجی از بین برود، ژنراتور ممکن است سرعت خود را افزایش یا کاهش دهد. در نتیجه، توان الکتریکی بین ژنراتور و سیستم قدرت در نوسان خواهد بود، تا زمانی که ژنراتور به یک نقطه کار متعادل جدید برسد. اگر ژنراتور توانایی خود را برای همگام کار کردن با شبکه از دست بدهد، ناپایدار در نظر گرفته می‌شود. این شرایط معمولاً به عنوان وضعیت خروج از همگامی* در نظر گرفته می‌شود. اگر چنین پدیده‌ای در سیستم قدرت رخ دهد، ضروری است تا نواحی ناهمگام قبل از آسیب به ژنراتورهای سنکرون یا قبل از وقوع یک قطع و خاموشی پی‌درپی در نواحی بزرگتر، ایزوله شوند. بنابراین، یک طرح حفاظتی با قابلیت اعتماد بالا برای تشخیص به موقع وضعیت خروج از همگامی در ژنراتورهای سنکرون ضروری است. از این نظر با پرداختن به رویکردهای ریاضی و الگوریتم‌های هوشمند، روش‌های زیادی ارائه شده است که همگی دارای نقاط قوت و ضعف هستند. روش این مقاله نیز پرداختن به چالش تشخیص خطای خروج از همگامی با استفاده از قابلیت‌های یادگیری عمیق است.

کلمات کلیدی

خروج از همگامی، نوسان توان پایدار، پایداری گذرا، یادگیری عمیق، شبکه‌های عصبی کانولوشن، شبکه‌های عصبی بازگشتی.

* Out Of Step

۱- مقدمه

دهند. بنابراین از شبیه‌سازی‌های زمانی برای ارزیابی پایداری و امنیت سیستم‌های قدرت در مقیاس بزرگ استفاده می‌شود [۲].

دسته‌بندی بعدی از روش‌های هوشمند به منظور تشخیص خطا استفاده می‌کند. د [۳] از توان الکتریکی، شتاب و انرژی جنبشی ژنراتور به عنوان ویژگی‌های درخت تصمیم استفاده می‌شود. خروجی پیش‌بینی پایداری ژنراتور به ترتیب یک و صفر برای شرایط پایدار و ناپایدار است. ورودی‌ها از شرایط قبل و بعد از خطا استخراج می‌شوند. پاسخ روش چند میلی‌ثانیه پس از زمان رفع خطا است.

مرجع [۴] از شبکه‌های عصبی پیچشی^۱ پی‌درپی (CNN) برای پیش‌بینی پایداری استفاده می‌کند. این مقاله بر روی یک سیستم برق واقعی لهستانی با ۲۳۸۳ باس تست شده است.

مقاله [۵] از شبکه عصبی بازگشتی (RNN) و شبکه حافظه‌ی بلند کوتاه-مدت (LSTM) برای ارزیابی پایداری در زمان واقعی استفاده می‌کند. این مقاله یک طرح خود انطباقی زمانی را برای ایجاد تعادل بین دقت و زمان پاسخ پیاده‌سازی می‌کند.

۲- مفاهیم خروج از همگامی

مهم‌ترین عوامل از دست رفتن همگامی ژنراتور سنکرون شامل قطع و وصل خطوط، اتصال کوتاه‌های سه‌فاز مدت‌دار، خروج ناگهانی سایر ژنراتورها، تغییرات ناگهانی بار و یا به علت قطع تحریک ژنراتور می‌باشد. به دنبال این اختلالات، تعادل بین توان مکانیکی ورودی و توان الکتریکی خروجی بر هم خورده و باعث افزایش یا کاهش شتاب روتور ژنراتورها شده، در نتیجه ژنراتور دچار نوسان می‌شود. نوسانات پایدار این‌گونه است که زوایای روتور در محدوده‌ی باریکی تغییر کرده و در نهایت به مقادیر ثابت می‌رسند. اما در نوسانات ناپایدار، زاویه‌ی روتور یک یا چند ژنراتور ممکن است نوسانات شدیدی را تجربه کند و به بیش از ۱۸۰ درجه افزایش یابد که منجر به از دست‌دادن همگامی ژنراتورها می‌شود. این پدیده به‌عنوان لغزش قطب ژنراتور یا شرایط خروج از همگامی شناخته می‌شود [۶].

هنگامی که یک ژنراتور سنکرون، همگامی را از دست می‌دهد، روتور آن با سرعتی پایین‌تر یا بالاتر از سرعت مورد نیاز برای تولید ولتاژ در فرکانس سیستم می‌چرخد. به دنبال این اتفاق، بین میدان چرخشی استاتور و میدان روتور لغزشی ایجاد می‌شود که منجر به نوسانات زیادی در زاویه روتور، توان خروجی، ولتاژ و جریان ماشین می‌شود. این امر باعث واکنش سیستم حفاظت شده و ژنراتور سنکرون ناپایدار از سیستم جدا می‌شود. ناهمگامی می‌تواند مابین گروهی از ژنراتورها و یا مابین یک ژنراتور سنکرون با بقیه‌ی سیستم اتفاق بیفتد. در حالت اول، پس از جدایی و جزیره‌سازی، ممکن است در هر گروه سنکرونیزم حفظ شود [۷].


سیستم‌های قدرت شبکه‌های درهم تنیده‌ای هستند که برای تولید، انتقال و توزیع بهینه انرژی الکتریکی طراحی شده‌اند. عملکرد صحیح و ایمن این سیستم‌ها در گرو حفظ پایداری آن‌ها است. پایداری سیستم قدرت شامل توانایی سیستم برای بازگشت سریع و روان به حالت ثابت پس از اغتشاش است. این ویژگی برای جلوگیری از خروج‌های پی‌درپی که می‌تواند منجر به خاموشی‌های گسترده شود، حیاتی است.

ژنراتور سنکرون، بنیان شبکه قدرت و عهده‌دار تولید انرژی است. بنابراین در حفظ پایداری شبکه و همچنین جلوگیری از خاموشی‌های گسترده نقش قابل ملاحظه‌ای را ایفا می‌کند. وقوع هرگونه حادثه در ژنراتور، علاوه بر خساراتی که برای واحد تولید به همراه خواهد داشت، می‌تواند پایداری شبکه قدرت را نیز به مخاطره اندازد. بنابراین مؤثرترین راه در جلوگیری از ناپایداری شبکه، تشخیص سریع و به‌موقع خطاهای الکتریکی و یا پیش‌بینی آن‌ها می‌باشد.

ناپایداری از جمله دلایل بروز و گسترش خاموشی‌ها در شبکه‌های قدرت هستند. ناپایداری می‌تواند در انواع مختلف مانند ناپایداری گذرای زاویه روتور، ناپایداری سیگنال کوچک، ناپایداری فرکانس و ناپایداری ولتاژ رخ دهد. پایداری گذرا زاویه روتور توانایی سیستم قدرت برای حفظ همگامی خود تحت یک اختلال شدید مانند برون‌رفت خطوط است. پایداری سیستم قدرت تحت اغتشاشات مختلف به تجهیزات کنترلی نصب شده برای تعدیل کردن نوسانات الکترومکانیکی بستگی دارد. لذا، برای به حداقل رساندن گسترش یک اختلال ناخواسته و آسیب به ژنراتورها، وجود طرح‌های حفاظتی مناسب الزامی است.

روش‌های تشخیص خروج از سنکرونیزم در ژنراتور سنکرون را می‌توان به سه دسته کلی تقسیم‌بندی کرد. دسته اول شامل روش‌های سنتی است. این روش‌ها غالباً با محاسبه امپدانس دیده شده از پایانه ژنراتور و بررسی روند تغییرات آن به تشخیص خطا می‌پردازند. شناخته‌شده‌ترین روش از این دسته‌بندی R-Rdot نام دارد. اساس این رله بر اندازه‌گیری مقاومت ظاهری (R) و مشتق آن (Rdot) است و فقط نیاز به اندازه‌گیری‌های محلی و محاسبات ابتدایی دارد [۱].

دسته دوم شامل روش‌های تحلیلی می‌شود، که با توجه به روابط الکتریکی حاکم بر عملکرد ماشین و بررسی تأثیر خطای خروج از همگامی بر این روابط، شرایط خروج از همگامی را شناسایی می‌کنند. پرکاربردترین روش از این دسته‌بندی روش معیار سطوح برابر است. این تکنیک برای سیستم تک ماشین متصل به شین بی‌نیاز است. برای سیستم‌های قدرت در مقیاس بزرگ با ژنراتورها و خطوط انتقال زیاد، روش‌های تحلیلی مانند معیار مساحت مساوی نمی‌توانند نتایج کارآمدی را ارائه




شکل (۳): دیاگرام فازوری جهت معرفی وابستگی مابین ولتاژهای ژنراتور و موتور سنکرون موجود در شکل (۲) [7].

شکل (۳) نمودار فازوری ارتباط بین ولتاژها را نشان می‌دهد. توان انتقالی از ژنراتور به موتور برابر است با:

$$P = \frac{E_G E_M}{X_T} \sin \delta \quad (1)$$


$$X_T = X_G + X_L + X_M \quad (2)$$

مطابق با شکل (۴)، رابطه‌ی توان انتقالی متناسب با موقعیت زاویه‌ای روتور است. اگر اختلاف زاویه برابر صفر باشد، انتقال توان صورت نمی‌گیرد. همچنان که اندازه زاویه افزایش پیدا می‌کند، توان انتقالی نیز افزایش می‌یابد. با اختلاف زاویه‌ای معادل ۹۰ درجه انتقال توان به حداکثر می‌رسد. بعد از ۹۰ درجه، زاویه به سمت مقدار ۱۸۰ درجه نزدیک می‌گردد. نقاط کاری قبل از ۹۰ درجه نقاط تعادل پایدار ماندگار و نقاط کاری بعد از ۹۰ درجه نقاط تعادل ناپایدار هستند. در عمل، اختلاف زاویه در حالت پایدار بسیار کمتر از ۹۰ درجه (حداکثر ۱۰ تا ۱۵ درجه) است. با توجه به منحنی توان-زاویه و بر مبنای معیار سطوح برابر می‌توان پدیده پایداری گذرا را شرح داد [7].




شکل (۴): نمودار (P-δ) مشخصه توان انتقالی سیستم دو ماشین [7].

یک مشخصه مهم در مقوله‌ی پایداری سیستم قدرت، رابطه‌ی غیرخطی بین موقعیت زاویه‌ای روتور ژنراتور سنکرون و توان اکتیو انتقالی است. سیستم ساده شکل (۱) این موضوع را به نمایش می‌گذارد. این نمودار تک‌خطی از دو ماشین سنکرون تشکیل شده است که از طریق یک خط انتقال با راکتانس X_L به یکدیگر متصل شده‌اند. از مقاومت و ظرفیت خازنی خط صرف نظر شده است. ماشین شماره ۱، یک ژنراتور سنکرون و ماشین شماره ۲، یک موتور سنکرون است. توان انتقال یافته از ژنراتور به موتور تابعی از اختلاف زاویه بین روتورهای دو ماشین است. این اختلاف زاویه از سه قسمت شامل زاویه داخلی موتور، تفاضل زاویه مابین ولتاژهای پایانه ژنراتور و موتور سنکرون و زاویه داخلی ژنراتور است. با کمک شکل (۲) که مدل ایده‌آل سیستم را نشان می‌دهد می‌توان رابطه توان-زاویه را به دست آورد. مدار معادل هر ماشین شامل یک منبع ولتاژ داخلی و یک راکتانس در نظر گرفته شده است. مقدار راکتانس ماشین، بستگی به موضوع مورد مطالعه دارد. برای مطالعات حالت ماندگار، استفاده از راکتانس سنکرون ماشین به همراه ولتاژ تحریک به عنوان منبع داخلی ولتاژ کافی است [7].



شکل (۱): دیاگرام تک‌خطی اتصال ژنراتور سنکرون به موتور سنکرون توسط خط انتقال [7].



شکل (۲): مدل ایده‌آل اتصال ژنراتور سنکرون به موتور سنکرون توسط خط انتقال [7].

۳- یادگیری عمیق


یادگیری یک شاخه مهم از فناوری اطلاعات بوده که روی ساخت سیستم‌های هوشمند تمرکز دارد. ارتباط تنگاتنگی با یادگیری ماشین^۲ و هوش مصنوعی دارد تا در نهایت مبتنی بر شبکه‌های عصبی مصنوعی^۳، یادگیری ماشین را جلو ببرد. مدل‌های یادگیری عمیق از نورون‌های مصنوعی تشکیل شده و در لایه‌هایی مرتب شده‌اند. این نورون‌ها از لایه‌های قبلی ورودی دریافت می‌کنند و خروجی‌هایی تولید کرده و به لایه بعدی منتقل خواهند کرد. اولین لایه، لایه ورودی است که داده‌ها را دریافت می‌کند و آخرین لایه، لایه خروجی است که پیش‌بینی‌ها را تولید می‌کند. لایه‌های بین، لایه‌های پنهان نامیده می‌شوند و به مدل اجازه می‌دهند تا نمایش‌های پیچیده داده‌ها را یاد بگیرد.

توابع فعال‌سازی در یادگیری عمیق برای معرفی غیرخطی به مدل استفاده می‌شود. آن‌ها به نورون‌ها اجازه می‌دهند بر اساس ورودی‌هایی که دریافت می‌کنند، کار کنند. توابع فعال‌سازی رایج عبارتند از sigmoid و ReLU و tanh. پس‌انتشار یا انتشار معکوس^۴، یک الگوریتم کلیدی در یادگیری عمیق است که به مدل اجازه می‌دهد تا وزن‌ها و جهت‌گیری‌های خود را در طول آموزش تنظیم کند. این کار با انتشار خطا از لایه خروجی به داخل شبکه، تنظیم وزن و بایاس^۵ در هر لایه، برای به حداقل رساندن خطا انجام می‌شود. این فرآیند بارها تکرار می‌شود تا زمانی که مدل روی وزن‌ها و بایاس‌های بهینه همگرا شود و نتیجه به سمت درست‌تر شدن پیش برود. الگوریتم‌های بهینه‌سازی نیز برای سرعت بخشیدن به فرآیند آموزش و بهبود دقت مدل وارد عمل می‌شوند. این الگوریتم‌ها، مانند نزول گرادیان تصادفی^۶، به مدل اجازه می‌دهد تا وزن‌ها و سوگیری‌ها را در مراحل کوچک‌تر تنظیم و فرآیند آموزش را کارآمدتر کند.

یادگیری عمیق به عنوان زیرشاخه‌ای از هوش مصنوعی، شاهد پیشرفت‌های قابل توجه‌ای بوده که با توسعه معماری‌های متنوع شبکه‌های عصبی تقویت شده است. در ادامه به برخی از این معماری‌ها پرداخته خواهد شد.


۳-۱- شبکه RNN

هنگامی که داده‌ها به صورت ترتیبی^۷ یا مبتنی بر سری زمانی^۸ باشند، شبکه‌های عصبی ساده کارایی بالایی نخواهند داشت. از این رو بهتر است از معماری‌هایی بهره گرفت که توانایی پردازش داده‌های مبتنی بر ترتیب را داشته باشند. شبکه‌های عصبی بازگشتی^۹ که به اختصار به آن‌ها RNN نیز گفته می‌شود، توانایی شناسایی الگو و یادگیری را از مجموعه داده‌های ترتیبی دارند.



شکل (۵): نمودار رفتار زاویه‌ی روتور تحت شرایط ناپایداری گذرا [۷].
شکل (۵) رفتار یک ژنراتور سنکرون در مواجهه با یک خطای الکتریکی فرضی را نشان می‌دهد که برای دو حالت منجر به نوسان توان ناپایدار شده و حالت دیگر پایدار مانده است. در مورد حالت پایدار (حالت ۱)، زاویه روتور به سمت یک مقدار بیشینه‌ای افزایش می‌یابد، سپس به صورت نوسانی و با کاهش دامنه به حالت پایدار بازمی‌گردد. در حالت ۲، شدت خطا به حدی بوده است که اختلاف زاویه در همان نوسان اول نه تنها میرا نشده بلکه افزایش یافته است. این حالت همان ناپایداری گذرای زاویه روتور است که با توجه این‌که در همان نوسان اول آشکار می‌شود به ناپایداری نوسان اول نیز شناخته می‌شود. اغلب ناپایداری‌های گذرا به همین شیوه رخ می‌دهند. در چنین حالتی در اثر خطای الکتریکی همانند اتصال کوتاه سه فاز طولانی‌مدت، با توجه به صفر شدن ولتاژ پایانه ژنراتور توان الکتریکی خروجی ماشین به سمت صفر میل می‌کند اما توان مکانیکی اعمال شده بر شفت ژنراتور در مقدار قبل از خطا باقی می‌ماند. این تفاوت بین توان مکانیکی ورودی و توان الکتریکی خروجی منجر به یک توان شتاب‌دهنده شده و باعث افزایش سرعت و زاویه روتور ژنراتور می‌گردد. در واقع از لحظه بروز خطا تا زمان رفع آن، توان مکانیکی ورودی به ماشین به صورت انرژی جنبشی در ماشین ذخیره می‌گردد. پس از برطرف شدن خطا، ماشین شروع به تحویل توان الکتریکی می‌کند و در نتیجه انرژی جنبشی موجود را به روتور ماشین باز می‌گرداند. اگر ماشین بتواند انرژی جنبشی به دست آمده در حین خطا را بعد از برطرف شدن خطا بازگرداند، پایدار گذرا می‌ماند، در غیر این صورت ماشین ناپایدار گذرا خواهد شد و به عبارت دیگر دچار خروج از همگامی می‌شود. حالت‌های ۲ و ۳ در شکل (۵) نمونه‌ای از ناپایداری گذرای زاویه روتور هستند. در مورد حالت ۳، زاویه روتور همچنان افزایش می‌یابد تا زمانی که همگامی خود را از دست بدهد و این ناپایداری در زاویه‌ی روتور ناپایداری گذرا نامیده می‌شود [۷].

زمان قبلی (توالی قبلی) به عنوان حافظه دریافت می‌کند. ورودی c یک وضعیت سلول است که تنظیم می‌کند که چه مقدار اطلاعات از توالی‌های بلند گذشته و کدام یک از آن‌ها در بلوک تاثیر داشته باشند.



شکل (۷): یک بلوک LSTM.

به بخش الف از شکل (۷)، درگاه فراموشی^{۱۲} گفته می‌شود که روابط آن در معادله (۴) آورده شده است. این قسمت از بلوک، تصمیم می‌گیرد که کدام بخش از اطلاعات بلند قبلی (توالی‌های بلند گذشته) در بلوک جاری مفید است و کدام بخش مفید نیست.

$$f_t = \sigma(W_{hf}h_{t-1} + W_{if}x_t + b_{hf} + b_{if}) \quad (۴)$$

$$c_t = c_t \odot f_t \quad (۵)$$

بخش ب که درگاه ورودی^{۱۳} نام‌گذاری شده، تصمیم می‌گیرد که چه اطلاعات جدیدی باید به وضعیت سلول (c) برای استفاده‌های بعدی اضافه شود.

$$g_t = \sigma(W_{hg}h_{t-1} + W_{ig}x_t + b_{hg} + b_{ig}) \quad (۶)$$

$$i_t = \sigma(W_{hi}h_{t-1} + W_{ii}x_t + b_{hi} + b_{ii}) \quad (۷)$$

$$\hat{g}_t = g_t \odot i_t \quad (۸)$$

$$c_t = c_t + \hat{g}_t \quad (۹)$$

در بخش ج، درگاه خروجی^{۱۴} وجود دارد که خروجی‌ها را مشخص می‌کند.

$$o_t = \sigma(W_{ho}h_{t-1} + W_{io}x_t + b_{ho} + b_{io}) \quad (۱۰)$$

$$h_t = o_t \odot \tanh(c_t) \quad (۱۱)$$


۳-۳- شبکه GRU

شبکه‌های RNN ساده، مشکل محوشدگی گرادیان را داشتند و شبکه‌های LSTM نیز با این مشکل محوشدگی گرادیان را برطرف می‌کردند، ولی از لحاظ محاسبات سنگین و پیچیده بودند. شبکه‌های عصبی واحد بازگشتی دروازه‌دار^{۱۵} یا همان که به اختصار GRU گفته می‌شود، مشکل

در حالت ترتیبی اگر داده‌ها یکی پس از دیگری، به ترتیب وارد الگوریتم یادگیری ماشین (مثلاً شبکه‌های عصبی ساده) شوند، الگوریتم با مشاهده‌ی داده‌ی شماره‌ی n ، بایستی داده‌ی شماره‌ی $n-1$ را نیز مشاهده کند ولی به صورت پیش‌فرض چنین قابلیت‌ی در الگوریتم‌های ساده مانند شبکه‌های عصبی ساده فراهم نشده است. در واقع یک شبکه‌ی عصبی مانند پرسپترون چندلایه^{۱۰} (MLP)، حافظه‌ای برای یادگیری ترتیبی از داده‌ها ندارد و با مشاهده‌ی یک نمونه از مجموعه‌ی آموزشی و آپدیت کردن وزن‌ها، به سراغ نمونه بعدی رفته و ترتیب و توالی را در حافظه‌ی خود ذخیره نمی‌کند.

شکل (۶) یک بلوک RNN را نمایش می‌دهد. که رابطه آن در معادله (۳) آورده شده است.

$$h_t = f(W_{hh}h_{t-1} + W_{xh}x_t + b_n) \quad (۳)$$

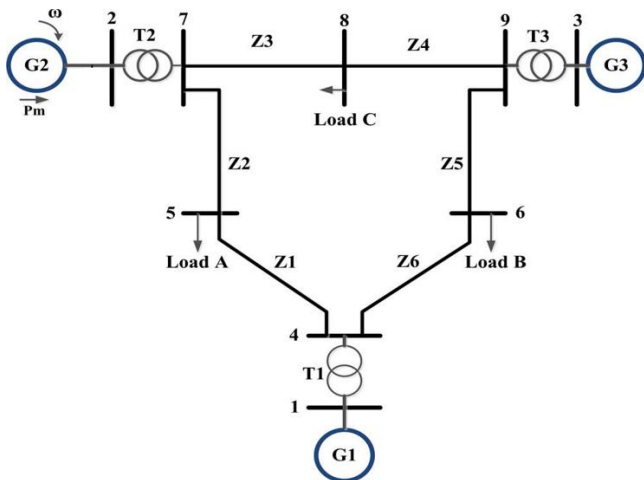


شکل (۶): یک بلوک RNN.

۳-۲- شبکه LSTM

شبکه‌های RNN کاربردی هستند و البته مشکلاتی نیز دارند. یکی از مشکلات RNNها، محوشدگی گرادیان در هنگام یادگیری از توالی‌های بلندمدت است که توانایی یادگیری را در الگوریتم کاهش می‌دهد. در واقع شبکه‌های عصبی بازگشتی ساده نمی‌توانند توالی‌های بلندمدت را یاد بگیرند و این مشکل باعث شد که شبکه‌های عصبی بازگشتی با حافظه‌ی بلند کوتاه‌مدت^{۱۱} یا به اختصار LSTM ایجاد شود.

شبکه‌های LSTM در واقع نوعی از RNNها هستند که تغییری در بلوک آن‌ها ایجاد شده است. این تغییر باعث می‌شود که شبکه‌های عصبی بازگشتی LSTM بتوانند مدیریت حافظه‌ی بلندمدت را داشته باشند و مشکل محوشدگی یا انفجار گرادیان را نیز نداشته باشند. شکل (۷) یک بلوک LSTM را نمایش می‌دهد. بر خلاف RNN ساده که دو ورودی داشت، در این جا سه ورودی وجود دارد. t همان ورودی در زمان (توالی) است و h نیز مانند RNN ساده همان وضعیت پنهان بوده که از خروجی



شکل (۹): نمودار تک خطی سیستم ۹ باسه [3].

سناریوهای شبیه‌سازی باید شامل سناریوهای مختلف خطا و بهره‌برداری برای تولید داده‌های آموزشی و آزمایشی باشند. در این زمینه، محل خطا شامل انتها یا میانه خطوط انتقال، خطای اتصال کوتاه سه‌فاز و تک‌فاز، زمان تداوم خطا از قبیل ۵۰، ۱۰۰، ۱۵۰ میلی‌ثانیه و همچنین تغییرات ساختاری (خروج خط) به عنوان معیارهای خطا بر روی تمامی خطوط انتقال و سمت فشارضعیف ترانسفورماتورها اعمال شده که مجموعاً ۱۳۰ سناریو خطا را شامل می‌شوند.

تمامی ۱۳۰ سناریو خطای گفته شده، در شرایط بارگذاری مطابق جدول (۱) در نظر گرفته می‌شوند و در نتیجه تعداد سناریوها معادل $3900 = 130 \times 30$ خواهد بود. لازم به ذکر است که تمامی خطاها در ثانیه ۱ به شبکه اعمال می‌شوند و مدت زمان شبیه‌سازی نیز ۶ ثانیه است.


دامنه ولتاژ، زاویه روتور، سرعت، توان اکتیو و توان راکتیو ژنراتور دوم از سیستم استاندارد ۹ باس به عنوان ورودی شبکه عصبی استفاده می‌شوند.

۴-۲- نتایج شبیه‌سازی‌ها

از ۳۹۰۰ سناریو شبیه‌سازی شده در نرم‌افزار Digsilent با حالت‌های بارگذاری متفاوت، مجموعاً ۸۱۴ سناریو دچار نوسان توان ناپایدار و خروج از همگامی ژنراتور شماره ۲ گردید. نتایج کلی نشان می‌دهد در شرایط یکسان خطا، سناریوهایی که ژنراتور در سطح بالایی از توان بارگذاری می‌شود، بیشتر دچار ناپایداری می‌شوند. به عبارت دیگر، چنانچه ژنراتور در بارگذاری بالایی از توان خود باشد و شبکه دچار اغتشاش شود، به علت این‌که ژنراتور در نزدیکی محدوده پایداری در حال کار است، احتمال ناپایداری شبکه به مراتب بیشتر خواهد بود.

همچنین در سناریوهایی که ژنراتور به صورت پیشفاز بارگذاری شده، احتمال وقوع ناپایداری بیشتر از حالت بارگذاری به صورت پس‌فاز است.

محوشدگی گرادیان را ندارند و از لحاظ محاسبات نیز ساده و سبک هستند.



شکل (۸): یک بلوک GRU.

در شکل (۸) یک بلوک GRU نشان داده شده است. به بخش الف دروازه‌ی آپدیت^{۱۶} می‌گویند. وظیفه‌ی دروازه‌ی آپدیت مدیریت اطلاعات گذشته است و اینکه چه مقدار از این اطلاعات در توالی‌های قبلی برای ارسال به توالی بعدی مفید هستند. بخش ب از شبکه‌های GRU دروازه‌ی ریست^{۱۷} نام دارد. دروازه‌ی ریست مشخص می‌کند که چقدر از اطلاعات گذشته می‌تواند به فراموشی سپرده شود. مانند RNN و LSTM، شبکه‌های GRU نیز از وزن‌هایی که به صورت شبکه‌های عصبی کوچک درونی در بلوک تعریف شده‌اند برای یادگیری و آپدیت وزن‌ها استفاده می‌کند.

۴-۳- شبکه CNN

شبکه عصبی پیچشی نیز مانند سایر شبکه‌های عصبی دارای لایه‌های نورونی با وزن و بایاس و قابلیت یادگیری هستند. سایر شبکه‌های عصبی، داده‌های ورودی را بازسازی می‌کنند و یک ماتریس دوبعدی را تبدیل به یک برداری با ابعاد مشابه می‌کنند. اما شبکه CNN ساختار ورودی را تغییر نمی‌دهد و ارتباط بین پیکسل‌های مجاور را حفظ می‌کند. یک شبکه پیچشی معمولاً از واحدهای مختلفی تشکیل شده است. این لایه‌ها عبارتند از: لایه ورودی^{۱۸}، لایه پیچشی^{۱۹}، لایه غیرخطی^{۲۰}، لایه یکپارچه^{۲۱}، لایه متراکم^{۲۲}.

۴-۴- شبیه‌سازی

۴-۱- آماده‌سازی داده

طرح پیشنهادی این پژوهش، جهت شناسایی خروج از همگامی ژنراتور شماره دوم از شبکه ۹ باس استاندارد IEEE (شکل (۹)) تحت انواع خطاها و بارگذاری‌های اولیه شبیه‌سازی شده است.

عملکرد مناسب الگوریتم نیاز است تا داده‌های ورودی استانداردسازی شوند.

روش انتخاب شده برای استانداردسازی داده‌ها، روش Min-Max است. این تبدیل به صورت معادله (۱۲) تعریف می‌شود و خروجی آن داده‌ها را به بازه ۱- تا ۱+ تبدیل می‌کند [۹].

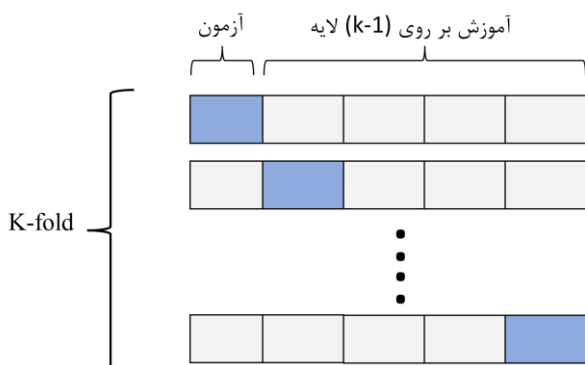
$$x^{norm} = \frac{x - x^{min}}{x^{max} - x^{min}} \quad (12)$$

در این رابطه، x^{min} مقدار کمینه داده‌ها و x^{max} مقدار بیشینه داده‌هاست [15].

۴-۵- روش اعتبارسنجی ضربدری k-fold²³

روش اعتبارسنجی ضربدری k-fold یکی از روش‌های مختلفی است که برای آزمایش عملکرد یک طبقه‌بندی کننده مورد استفاده قرار می‌گیرد. این روش اعتبارسنجی مجموعه‌ی داده‌ها را به‌طور تصادفی به k دسته با تعداد اعضای تقریباً یکسان تقسیم می‌کند. در این صورت الگوریتم k مرتبه مورد آموزش قرار می‌گیرد و سپس آزمایش می‌شود. با این روش اعتبارسنجی کل داده‌ها برای آموزش و آزمون مورد استفاده قرار می‌گیرند [۹].

در روش اعتبارسنجی k-fold تعداد k-1 بخش از k بخش داده‌ها به‌منظور آموزش و لایه باقی‌مانده برای آزمون استفاده می‌شود که اعتبارسنجی نیز در این بخش انجام می‌گیرد [۹]. در این پژوهش جهت اعتبارسنجی طرح پیشنهادی k=5 در نظر گرفته شده است.



شکل (۱۰): نحوه عملکرد روش اعتبارسنجی ضربدری k-fold

۴-۶- پارامترهای ارزیابی

برای اندازه‌گیری اثربخشی روش پیشنهادی تشخیص خطای خروجی از همگامی از چهار معیار، صحت، دقت، پوشش^{۲۴} و F1-score استفاده می‌شود که با استفاده از ماتریس اغتشاش قابل محاسبه هستند و طبق

جدول (۱): سناریوهای بارگذاری اولیه ژنراتورها.

Scenarios	Initial Loading (P(MW), Cos(φ))	Generators Voltage (V _{G1} , V _{G2} , V _{G3})
1	(1.50*163, 0.85) lagging	(1.04, 1.25, 1.025)
2	(1.25*163, 0.85) lagging	(1.04, 1.23, 1.025)
3	(1.00*163, 0.85) lagging	(1.04, 1.20, 1.025)
4	(0.75*163, 0.85) lagging	(1.04, 1.16, 1.025)
5	(0.50*163, 0.85) lagging	(1.04, 1.12, 1.025)
6	(0.25*163, 0.85) lagging	(1.04, 1.07, 1.025)
7	(1.50*163, 0.95) lagging	(1.04, 1.15, 1.025)
8	(1.25*163, 0.95) lagging	(1.04, 1.14, 1.025)
9	(1.00*163, 0.95) lagging	(1.04, 1.12, 1.025)
10	(0.75*163, 0.95) lagging	(1.04, 1.10, 1.025)
11	(0.50*163, 0.95) lagging	(1.04, 1.08, 1.025)
12	(0.25*163, 0.95) lagging	(1.04, 1.05, 1.025)
13	(1.50*163, 0.90) leading	(1.15, 0.89, 1.15)
14	(1.25*163, 0.90) leading	(1.15, 0.93, 1.15)
15	(1.00*163, 0.90) leading	(1.15, 0.98, 1.15)
16	(0.75*163, 0.90) leading	(1.15, 1.05, 1.15)
17	(0.50*163, 0.90) leading	(1.15, 1.10, 1.15)
18	(0.25*163, 0.90) leading	(1.15, 1.13, 1.15)
19	(1.50*163, 0.95) leading	(1.15, 0.93, 1.15)
20	(1.25*163, 0.95) leading	(1.15, 0.99, 1.15)
21	(1.00*163, 0.95) leading	(1.15, 1.05, 1.15)
22	(0.75*163, 0.95) leading	(1.15, 1.09, 1.15)
23	(0.50*163, 0.95) leading	(1.15, 1.12, 1.15)
24	(0.25*163, 0.95) leading	(1.15, 1.14, 1.15)
25	(1.50*163, 0.90) lagging	(1.04, 1.22, 1.025)
26	(1.25*163, 0.90) lagging	(1.04, 1.20, 1.025)
27	(1.00*163, 0.90) lagging	(1.04, 1.16, 1.025)
28	(0.75*163, 0.92) lagging	(1.04, 1.12, 1.025)
29	(0.50*163, 0.99) lagging	(1.04, 1.05, 1.025)
30	(0.25*163, 0.85) leading	(1.15, 0.89, 1.15)

۴-۳- تمیز کردن داده‌های ورودی

به دلیل اینکه زمان خروج از همگامی برای هر سناریوی نوسان توان ناپایدار متفاوت است، مدت زمان هر دوره شبیه‌سازی ۶ ثانیه در نظر گرفته شده است. ۶ ثانیه زمان مناسبی است چون ناپایداری گذرا یا همان خروج از همگامی خیلی زودتر از آن اتفاق می‌افتد [۸].

در مراجع مختلف از پنجره‌های زمانی مختلفی برای تشخیص خطا استفاده شده است. در [۹] از ۴ سیکل بعد از رفع خطا استفاده شده، مرجع [۱۳] به ۳۰ سیکل بعد از رفع خطا احتیاج دارد، در [۱۰-۱۲] از پنجره زمانی ۲۰۰ میلی‌ثانیه پس از پاکسازی خطا استفاده شده، و در [۱۵] ۵ سیکل بعد از رفع خطا برای تشخیص خروج از همگامی در نظر گرفته شده است. در این پژوهش، پنجره زمانی ۱۰ سیکل بعد از رفع خطا برای بخش تمیز کردن داده‌ها انتخاب می‌شود.

۴-۴- استانداردسازی داده‌های ورودی

خروجی‌های شبیه‌سازی شامل ولتاژ پایانه ژنراتور برحسب پریونیت، توان اکتیو ژنراتور برحسب مگاوات و زاویه روتور بر حسب درجه است. برای

جدول (۵): جدول ارزیابی مبتنی بر ویژگی سرعت روتور.

<i>F1-Score</i>	<i>Recall</i>	<i>Precision</i>	<i>Accuracy</i>	
94.70%	93.06%	96.40%	98.08%	<i>CNN</i>
95.74%	93.75%	97.83%	98.46%	<i>RNN</i>
76.49%	66.67%	89.72%	92.44%	<i>LSTM</i>
97.20%	96.53%	97.89%	98.97%	<i>GRU</i>

جدول (۶): جدول ارزیابی مبتنی بر ویژگی توان راکتیو.

<i>F1-Score</i>	<i>Recall</i>	<i>Precision</i>	<i>Accuracy</i>	
91.84%	93.75%	90.00%	96.02%	<i>CNN</i>
89.35%	90.28%	88.44%	96.03%	<i>RNN</i>
88.58%	88.89%	88.28%	95.77%	<i>LSTM</i>
42.11%	27.78%	86.96%	85.90%	<i>GRU</i>

جدول (۷): جدول ارزیابی مبتنی بر ویژگی توان اکتیو.

<i>F1-Score</i>	<i>Recall</i>	<i>Precision</i>	<i>Accuracy</i>	
83.90%	77.78%	91.06%	94.49%	<i>CNN</i>
83.65%	76.39%	92.44%	94.49%	<i>RNN</i>
84.53%	77.78%	92.56%	94.74%	<i>LSTM</i>
76.08%	67.36%	87.39%	92.18%	<i>GRU</i>

با در نظر گرفتن نتایج جداول (۳) تا (۸)، می‌توان مشاهده کرد که ویژگی‌های زاویه و سرعت روتور عملکرد بهتری نسبت به سایر ویژگی‌ها از خود نشان داده‌اند که دلیل آن می‌تواند تاثیر مستقیم پدیده خروج از همگامی بر روی این ویژگی‌ها باشد.

در گام بعد، عملکرد روش پیشنهادی با استفاده از تمام ویژگی‌ها مورد بحث قرار می‌گیرد و نتایج آن در جدول (۸) آورده شده است. علاوه بر آن، به منظور مقایسه روش پیشنهادی با روش‌های سنتی در جدول (۸) مقادیر معیارهای ارزیابی مربوط به رله 7UM62-Siemens که در مرجع [۱۸] به آن اشاره شده بود، آورده شده است.

جدول (۸): جدول ارزیابی مبتنی بر تمامی ویژگی‌ها.

<i>F1-Score</i>	<i>Recall</i>	<i>Precision</i>	<i>Accuracy</i>	
98.62%	99.31%	97.95%	99.49%	<i>CNN</i>
98.62%	99.31%	98.62%	99.62%	<i>RNN</i>
91.78%	93.06%	90.54%	96.92%	<i>LSTM</i>
97.59%	98.61%	96.60%	99.10%	<i>GRU</i>
78.62%	75.64%	81.84%	83.11%	<i>7UM</i>

در جداول (۸) تا (۱۲) ماتریس اغتشاش مربوط به ۴ شبکه پیشنهادی در حالت استفاده از تمامی ویژگی‌ها نشان داده شده است.

جدول (۹): ماتریس اغتشاش شبکه CNN.

ساختار عملکرد روش اعتبارسنجی k-fold میانگین مقادیر معیارها را برای ۵ لایه منتخب به عنوان جواب نهایی محاسبه می‌شوند. با توجه به روابط (۴) تا (۷) می‌توان به مفهوم هر یک از شاخص‌ها پرداخت [17].

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TP} \quad (13)$$

$$Precision = \frac{TP}{TP + FP} \quad (14)$$

$$Recall = \frac{TP}{TP + FN} \quad (15)$$

$$F1 - score = \frac{2 * (Recall * Precision)}{(Recall + Precision)} \quad (16)$$

که در این روابط TP^{26} تعداد نمونه‌های عضو دسته یک (ناپایدار) است و عضو همین کلاس تشخیص داده می‌شود. متغیر FN^{27} تعداد نمونه‌های عضو کلاس یک است و عضو صفر (پایدار) تشخیص داده می‌شود. TN^{28} نمونه‌های عضو کلاس صفر است که عضو همین کلاس تشخیص داده می‌شود. و در نهایت FP^{29} نمونه‌های عضو کلاس صفر است و عضو کلاس یک تشخیص داده می‌شوند.

۵- ارزیابی کارایی ویژگی‌ها

در این بخش ابتدا عملکرد هر یک از ویژگی‌ها در تشخیص خروج از همگامی به صورت جداگانه بر روی چهار شبکه *CNN*، *RNN*، *LSTM* و *GRU* بررسی می‌شود و نتایج در جداول (۳) تا (۷) نشان داده شده است. لازم به ذکر است، تمامی مراحل پیاده‌سازی در نرم‌افزار Python انجام شده است. شبیه‌سازی‌هایی که منجر به ناپایدار شدن شبکه می‌گردند با برچسب یک و سناریوهای نوسان توان پایدار با برچسبی از صفر مشخص می‌گردند.

جدول (۳): جدول ارزیابی مبتنی بر ویژگی ولتاژ پایانه.

<i>F1-Score</i>	<i>Recall</i>	<i>Precision</i>	<i>Accuracy</i>	
87.54%	85.42%	89.78%	95.51%	<i>CNN</i>
90.71%	88.19%	93.38%	96.67%	<i>RNN</i>
84.28%	87.50%	81.29%	93.97%	<i>LSTM</i>
93.52%	95.14%	91.95%	97.56%	<i>GRU</i>

جدول (۴): جدول ارزیابی مبتنی بر ویژگی زاویه روتور.

<i>F1-Score</i>	<i>Recall</i>	<i>Precision</i>	<i>Accuracy</i>	
95.27%	97.92%	92.76%	98.21%	<i>CNN</i>
95.50%	95.83%	95.17%	98.33%	<i>RNN</i>
87.94%	86.11%	89.86%	95.64%	<i>LSTM</i>
96.25%	97.92%	94.63%	98.59%	<i>GRU</i>

۶- نتیجه‌گیری

در این مطالعه به زمینه تشخیص خطای خروج از همگامی در ژنراتورهای سنکرون از طریق ابزار یادگیری عمیق پرداخته شد و با استفاده از یک مجموعه جامع شامل ۳۹۰۰ سناریو شبیه‌سازی شده در Digsilent، قابلیت‌های انواع معماری‌های یادگیری عمیق مورد بررسی قرار گرفت. نتایج، کارآمدی مدل‌های یادگیری عمیق را در تشخیص خطاهای خروج از همگامی اثبات کرد. شبکه GRU در تشخیص ناپایداری با استفاده از تک‌ویژگی عملکرد مناسبی از خود نشان داد. شبکه‌های RNN و CNN عملکرد رقابتی را نشان دادند و اثربخشی خود را با در نظر گرفتن وابستگی‌های زمانی که برای تشخیص خطا حیاتی هستند، برجسته کردند. مانند هر تلاش تحقیقاتی، این مطالعه نیز محدودیت‌هایی دارد. تحقیقات آینده می‌تواند معماری‌های ترکیبی را بررسی کند که نقاط قوت CNN، LSTM، RNN و GRU را ترکیب می‌کند. علاوه بر این، ادغام ویژگی‌های اضافی یا معرفی سناریوهای آزمایش در دنیای واقعی، باعث استحکام بیشتر مدل‌های پیشنهادی خواهد شد.

مراجع

- [1] A report to the Power System Relaying Committee of the IEEE Power Engineering Society, "Power Swing and Out-of-Step Consideration on Transmission Lines", 2006.
- [2] Paudyal. S, Ramakrishna. G, and Sachdev. M. S, "Application of equal area criterion conditions in the time domain for out-of-step protection," *IEEE Transactions on Power Delivery*, vol. 25, pp. 600-609, 2010.
- [3] T. Amraee and S. Ranjbar, "Transient Instability Prediction Using Decision Tree Technique," in *IEEE Transactions on Power Systems*, vol. 28, no. 3, pp. 3028-3037, Aug. 2013, Doi: 10.1109/TPWRS.2013.2238684.
- [4] R. Yan, G. Geng, Q. Jiang, Y. Li, *Fast transient stability batch assessment using cascaded convolutional neural networks*, *IEEE Trans. Power Syst.* 34 (4) (2019) 2802–2813 July.
- [5] J.J.Q. Yu, D.J. Hill, A.Y.S. Lam, J. Gu, V.O.K. Li, *Intelligent time-adaptive transient stability assessment system*, *IEEE Trans. Power Syst.* 33 (1) (2018) 1049–1058 Jan.
- [6] Farantatos. E, Huang. R, Cokkinides. G. J, and Meliopoulos A. P, "A predictive generator out-of-step protection and transient stability monitoring scheme enabled by a distributed dynamic state estimator," *IEEE Transactions on Power Delivery*, vol. 31, pp. 1826-1835, 2015.
- [7] Kundur. P, Balu. N. J, Lauby. M. G, *Power system stability and control*, vol. 7, McGraw-Hill New York, 1994.
- [8] Rasoulpour. M, "Loss of field detection in synchronous generators using data mining of electric output variables," M.Sc.Thesis, Faculty of Electrical and Computer Engineering Department of Mechatronics, K. N. Toosi University of Technology, 2018.

پیش‌بینی توسط الگوریتم		
برچسب واقعی	ناپایدار (۱)	
	پایدار (۰)	ناپایدار (۱)
	پایدار (۰)	۶۳۳
ناپایدار (۱)	۱	۱۴۳

جدول (۱۰): ماتریس اغتشاش شبکه RNN.

پیش‌بینی توسط الگوریتم		
برچسب واقعی	ناپایدار (۱)	
	پایدار (۰)	ناپایدار (۱)
	پایدار (۰)	۶۳۴
ناپایدار (۱)	۱	۱۴۳

جدول (۱۱): ماتریس اغتشاش شبکه LSTM.

پیش‌بینی توسط الگوریتم		
برچسب واقعی	ناپایدار (۱)	
	پایدار (۰)	ناپایدار (۱)
	پایدار (۰)	۶۲۴
ناپایدار (۱)	۱۵	۱۲۹

جدول (۱۲): ماتریس اغتشاش شبکه GRU.

پیش‌بینی توسط الگوریتم		
برچسب واقعی	ناپایدار (۱)	
	پایدار (۰)	ناپایدار (۱)
	پایدار (۰)	۶۳۱
ناپایدار (۱)	۲	۱۴۲

- 19 Convolutional Layer
- 20 Non-Linear Activation Function
- 21 Pooling Layer
- 22 Fully Connected Layer
- 23 K-fold Cross Validation
- 24 Precision
- 25 Recall
- 26 True Positive
- 27 False Negative
- 28 True Negative
- 29 False Positive

- [9] D. You, K. Wang, L. Ye, J. Wu, R. Huang, *Transient stability assessment of power system using support vector machine with generator combinatorial trajectories inputs*, Int. J. Electr. Power Energy Syst. 44 (1) (2013) 318–325.
- [10] S. Das, B.K. Panigrahi, *Prediction and control of transient stability using system integrity protection schemes*, IET Gener. Transm. Distrib. 13 (8) (2019) 1247–1254
- [11] P. Bhui, N. Senroy, *Real-time prediction and control of transient stability using transient energy function*, IEEE Trans. Power Syst. 32 (2) (2017) 923–934 March.
- [12] M. Li, A. Pal, A.G. Phadke, J.S. Thorp, *Transient stability prediction based on apparent impedance trajectory recorded by PMUs*, Int. J. Electr. Power Energy Syst. 54 (2014) 498–504.
- [13] Y. Zhou, J. Wu, Z. Yu, L. Ji, L. Hao, *A hierarchical method for transient stability prediction of power systems using the confidence of a SVM-based ensemble classifier*, Energies 9 (10) (2016).
- [14] B. Wang, B. Fang, Y. Wang, H. Liu, Y. Liu, *Power system transient stability assessment based on big data and the core vector machine*, IEEE Trans. Smart Grid 7 (5) (2016) 2561–2570 Sept.
- [15] Han. J, Pei. J, and Kamber. M, *Data mining: concepts and techniques*, Elsevier, 2011.
- [16] Rodriguez. J. D, Perez. A, and Lozano. J. A, "Sensitivity analysis of k-fold cross validation in prediction error estimation," IEEE transactions on pattern analysis and machine intelligence, vol. 32, pp. 569-575, 2009.
- [17] Olson. D. L, Delen. D, *Advanced data mining techniques*, Springer Science & Business Media, 2008.

[۱۸] کنعانی، سمیرا، ارائه یک الگوریتم مبتنی بر داده‌کاوی برای تشخیص خروج از همگامی در ژنراتورهای سنکرون. کارشناسی ارشد، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ۱۴۰۰.

زیرنویس‌ها

- ¹ Convolutional Neural Network
- ² Machine Learning
- ³ Artificial neural network
- ⁴ Backpropagation
- ⁵ Bias
- ⁶ Stochastic gradient descent
- ⁷ Sequential
- ⁸ Time Series
- ⁹ Recurrent (Recursive) Neural Network
- ¹⁰ Multi-Layer Perceptron
- ¹¹ Long Short-Term Memory
- ¹² Forget Gate
- ¹³ Input Gate
- ¹⁴ Output Gate
- ¹⁵ Gated Recurrent Unit
- ¹⁶ Update Gate
- ¹⁷ Reset Gate
- ¹⁸ Input Layer