

# مدلی هوشمند و زمان-تطبیقی برای شناسایی خطاهای متقارن و نامتقارن در شرایط نوسان توان

حسن سعیدی<sup>۱</sup> و مصطفی سرلک<sup>۲\*</sup>

چکیده	اطلاعات مقاله
<p>عملکرد ناخواسته رله دیستانس طی شرایط نوسان توان، می‌تواند به گسترش اغتشاش و وخیم‌تر شدن وضعیت شبکه قدرت منجر شود. بنابراین، تشخیص سریع و دقیق نوسان توان و قفل نمودن رله دیستانس پس از وقوع نوسان توان برای حفظ امنیت و قابلیت اطمینان شبکه قدرت، امری ضروری است. از سویی دیگر، در صورت وقوع خطا طی نوسان توان، به‌منظور حفظ شاخص قابلیت اتکای سیستم حفاظتی، لازم است تا خطا شناسایی شود. این مقاله الگوریتمی هوشمند و زمان تطبیقی برای تشخیص خطاهای متقارن و نامتقارن در خطوط انتقال جبران‌شده سری طی نوسان توان مبتنی بر شبکه عصبی بازگشتی حافظه کوتاه‌مدت ماندگار (Long Short Term Memory (LSTM)) ارائه می‌دهد. این روش از جریان‌های سه‌فاز در محل رله دیستانس به‌عنوان ورودی استفاده می‌کند. به‌منظور بررسی الگوریتم پیشنهادی، شبکه استاندارد برای تست سیستم حفاظت خطوط انتقال که توسط کمیته حفاظت سیستم قدرت IEEE ارائه شده است، در نظر گرفته شد. انواع خطا در شرایط مختلف از جمله مکان خطا، مقاومت خطا، زاویه بار و زمان وقوع خطا در نرم افزار PSCAD شبیه‌سازی شدند. نتایج نشان می‌دهند که روش پیشنهادی دارای میانگین پاسخ زمانی (Average Response Time (ART)) و میانگین دقت (Average Accuracy (AA)) به ترتیب ۰/۱۰۰۴ میلی‌ثانیه و ۹۹/۰۴ درصد می‌باشد.</p>	<p>دریافت مقاله: ۱۳۹۸/۰۳/۰۶ پذیرش مقاله: ۱۳۹۸/۸۰/۱۴</p> <p><b>واژگان کلیدی:</b> رله دیستانس، شبکه عصبی بازگشتی، حافظه کوتاه‌مدت ماندگار، شناسایی خطا، نوسان توان.</p>

## ۱-مقدمه

دیستانس، تابعی درون رله تعبیه می‌شود تحت عنوان تابع قفل‌کننده نوسان توان<sup>۳</sup> که وظیفه آن قفل نمودن رله دیستانس طی شرایطی نوسان توان است. اگرچه، با وقوع خطا، رله باید از حالت قفل خارج و سیگنال تریپ را در کوتاه‌ترین زمان ممکن به مدارشکن ارسال کند [۱]. روش‌های مختلفی برای تشخیص خطا طی نوسان توان ارائه شده‌اند. در [۲] روشی مبتنی بر فضای فاز پیشنهاد شده است. در [۳] از مکان هندسی دایره‌ای وار مسیر ادمیتانس و رفتار مرکز آن جهت تشخیص نوسان توان

وقوع رخدادهایی هم‌چون جداسدن ژنراتوری بزرگ از شبکه قدرت، خروج یا ورود باری بزرگ به شبکه قدرت و وقوع خطا سبب می‌شوند که زاویه روتور ژنراتورهای شبکه دچار نوسان گردند که این امر خود منجر به نوسان سیگنال‌های ولتاژ و جریان می‌شود. در پی این نوسان، بردار امپدانس محاسبه شده در محل رله دیستانس ممکن است وارد نواحی عملکرد رله دیستانس شود و نتیجتاً عملکرد اشتباه رله مذکور را به دنبال داشته باشد. به‌همین جهت در رله‌های

\* پست الکترونیک نویسنده مسئول: sarlak@jsu.ac.ir

۱. دانشجوی کارشناسی ارشد، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی جندی‌شاپور دزفول، ایران

۲. استادیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی جندی‌شاپور دزفول، ایران

<sup>3</sup> Power Swing Blocking (PSB)

(تنظیمات)، در الگوریتم‌های تشخیص خطا طی نوسان توان، به‌کارگیری الگوریتم‌های یادگیری ماشین در مقالات [۱۸-۱۵] مدنظر قرار گرفت. دلیل این امر، توانایی تعمیم-دهی این‌گونه الگوریتم‌ها در مواجهه با شرایطی است که ممکن است طی مرحله آماده‌سازی الگوریتم تشخیص خطا طی نوسان توان، در نظر گرفته نشده باشند.

در [۱۵-۱۶]، روش‌هایی مبتنی بر ماشین بردار پشتیبان جهت تمایز مابین نوسان توان، خطا و خطا طی نوسان توان ارائه شده است. در [۱۷] روشی مبتنی بر الگوریتم درخت تصمیم جهت تشخیص و دسته‌بندی خطا طی نوسان توان ارائه شده است. در [۱۸]، از ترکیب تبدیل ویولت و سیستم استنتاج فازی استفاده شده است.

اگرچه، خلأیی تحقیقاتی در ارتباط با روش‌های تشخیص خطا طی نوسان توان بر پایه الگوریتم‌های یادگیری ماشین وجود دارد. در همه این روش‌ها، پنجره داده ورودی به‌مدل هوشمند، دارای طول ثابتی است که معنای آن این است که برای ارزیابی هر شرایط به‌منظور تشخیص خطا، بایستی مدت زمان ثابتی طی شود تا تصمیم‌گیری در خصوص از قفل خارج کردن یا قفل باقی ماندن رله دیستانس، به‌عمل آید. در صورتی که برای بسیاری از شرایط وقوع خطا ممکن است لازم نباشد تا این زمان برای تصمیم‌گیری طی شود. به‌عبارت دیگر، در صورت زمان تطبیقی بودن پنجره داده، می‌توان زمان میانگین تشخیص خطا را تا حد قابل توجهی کاهش داد که این امر افزایش سرعت عملکرد سیستم حفاظتی را به‌دنبال خواهد داشت. در این مقاله، برای رسیدن به‌هدف زمان تطبیقی بودن پنجره داده، از شبکه‌ی عصبی بازگشتی LSTM [۱۹] استفاده شده است.

در روش پیشنهادی این مقاله، عملیات تشخیص خطا طی نوسان توان به‌صورت زمان تطبیقی است. به‌عبارت دیگر، طول پنجره داده مورد استفاده در الگوریتم پیشنهادی، متغیر و متناسب با شرایط مختلف وقوع خطا تغییر می‌کند. همچنین، قابل ذکر است که نتایج ارزیابی الگوریتم مبین سرعت و دقت تشخیص بالای الگوریتم پیشنهادی در خطوط انتقال جبران‌شده سری است. به‌طور مشخص مهم‌ترین نوآوری این مقاله عبارت‌است از:

ارائه نظریه شناسایی زمان-تطبیقی و هوشمند انواع خطا طی نوسان توان در خطوط جبران‌شده سری بوده است. نمود اصلی خروجی این کار پژوهشی کاهش میانگین پاسخ زمانی به  $0/1004$  میلی‌ثانیه و حفظ دقت حدود  $99/04$

استفاده شده است. شناسایی خطای متقارن طی نوسان توان با استفاده از میانگین پنجره متحرک سیگنال‌های جریان در [۴] مدنظر قرار گرفته است. در [۵] روشی مبتنی بر پایش گذرا ارائه شده است. استفاده از تبدیل پارک در [۶] پیشنهاد شده است. در [۷] روشی مبتنی بر مؤلفه توانی منفی توان ظاهری پیشنهاد شده است. استفاده از نرخ تغییرات جریان در [۸] مدنظر قرار گرفته است. استفاده از تبدیل هیلبرت سری زمانی توان اکتیو در [۹] ارائه شده است. در [۱۰]، روشی مبتنی بر امواج سیار برای تشخیص انواع خطای متقارن و نامتقارن در خطوط انتقال جبران‌شده سری ارائه گردیده است. در [۱۱]، از معیاری مبتنی بر شکل لیسازوی سیگنال‌های ولتاژ جریان سه‌فاز استفاده شده است. در مقاله [۱۲]، از این حقیقت که تغییرات فازور ولتاژ و تغییرات فازور جریان در شرایط خطا بر خلاف نوسان توان هم‌فاز خواهند بود. برای شناسایی خطا طی نوسان توان استفاده شده است. در پژوهش ارائه‌شده در [۱۳]، روشی مبتنی بر بسط سری تیلور برای سیگنال‌های جریان و ولتاژ ارائه شده که توانایی تشخیص خطا طی نوسان توان را دارد. در [۱۴]، روشی ناحیه گسترده مبتنی بر داده‌های دریافتی از واحدهای اندازه‌گیری فازور برای نظارت بر عملکرد رله‌های دیستانس طی وقوع خطا در شرایط نوسان توان ارائه شده است.

علی‌رغم ارزشمند بودن روش‌های غیرهوشمند ارائه شده در این مقالات [۱۴-۲]، میزان موفقیت آن‌ها در تشخیص خطا طی نوسان توان متأثر از انتخاب تنظیم (تنظیماتی) است که برای معیارهای پیشنهاد شده توسط هریک از این الگوریتم‌ها در نظر گرفته می‌شود. در این خصوص، در همه این مقالات [۲-۱۴] سعی شده است تا بحرانی‌ترین حالات با توجه به شرایط بهره‌برداری سیستم قدرت برای انتخاب تنظیم (تنظیمات) معرفی شوند. لیکن، این احتمال وجود دارد که حالاتی وخیم‌تر باشند اما در مرحله تنظیم الگوریتم مدنظر مهندس حفاظت قرار نگرفته باشند. به‌عنوان مثال وقوع خطا در شرایط بهره‌برداری که معیار مربوطه دارای مقداری کمتر از مقدار تنظیم از قبل تعیین‌شده باشد و یا وقوع شرایط غیرخطایی که معیار مربوطه دارای مقداری بیشتر از مقدار تنظیم از قبل تعیین شده باشد. در هر دو این شرایط، الگوریتم دچار اشتباه در تصمیم‌گیری خواهد شد. به‌طور دقیق، این روش‌های غیرهوشمند فاقد قابلیت تعمیم هستند. به‌منظور حل مسأله انتخاب تنظیم

درصدی است. در بخش ۲، تشخیص هوشمند و زمان-تطبیقی خطا طی نوسان توان و شبکه عصبی بازگشتی LSTM توضیح داده شده است. مدل سازی شبکه عصبی بازگشتی LSTM تشخیص خطا طی نوسان توان در بخش ۳ آورده شده است. در بخش ۴، الگوریتم آنلاین پیشنهادی بیان گردیده است. مدل سازی و پیاده سازی الگوریتم پیشنهادی در بخش ۵ تشریح شده است. در بخش های ۶ و ۷ به ترتیب به نتایج حاصل از پیاده سازی الگوریتم پیشنهادی و ارزیابی مقایسه ای آن پرداخته شده است. در نهایت، در بخش ۸ مقاله، نتیجه گیری بیان گردیده است.

در بخش ۲، تشخیص هوشمند و زمان-تطبیقی خطا طی نوسان توان و شبکه عصبی بازگشتی LSTM توضیح داده شده است. مدل سازی شبکه عصبی بازگشتی LSTM تشخیص خطا طی نوسان توان در بخش ۳ آورده شده است. در بخش ۴، الگوریتم آنلاین پیشنهادی بیان گردیده است. مدل سازی و پیاده سازی الگوریتم پیشنهادی در بخش ۵ تشریح شده است. در بخش های ۶ و ۷ به ترتیب به نتایج حاصل از پیاده سازی الگوریتم پیشنهادی و ارزیابی مقایسه ای آن پرداخته شده است. در نهایت، در بخش ۸ مقاله، نتیجه گیری بیان گردیده است.

## ۲- تشخیص هوشمند و زمان-تطبیقی خطا طی نوسان توان و شبکه عصبی بازگشتی LSTM

### ۲-۱- تشخیص هوشمند و زمان-تطبیقی خطا طی نوسان توان

وقوع خطاها، کلیدزنی در خط انتقال، جداسدن ژنراتور و وارد یا خارج شدن بارهای بزرگ در شبکه قدرت، تغییرات شدید و ناگهانی در توان الکتریکی را سبب می شود؛ در حالی که توان مکانیکی ورودی به ژنراتورها نسبتاً ثابت است. این اختلالات شبکه باعث نوسانات در زاویه رتور ماشین ها شده و در نتیجه نوسانات شدید توان را در پی خواهند داشت. چنین نوساناتی، اعم از پایدار یا ناپایدار، موجب عملکرد ناخواسته رله های دیستانس می گردد و این امر خود می تواند به اوضاع بدتر منجر شود. به طور کلی، رله های دیستانس باید تحت این شرایط دینامیکی، دستور قطع را صادر نکنند. بر همین اساس، تابع PSB در رله های دیستانس برای جلوگیری از ارسال دستور قطع ناخواسته طی نوسان توان در درون این رله ها تعبیه شده است. لیکن، برای حفظ شاخص قابلیت اتکا، لازم است تا در صورت وقوع خطا اعم از خطای متقارن و نامتقارن، رله دیستانس از حالت قفل خارج و با تشخیص خطای رخ داده، دستور قطع را برای کلیدهای مربوطه ارسال نماید.

وقوع خطاها، کلیدزنی در خط انتقال، جداسدن ژنراتور و وارد یا خارج شدن بارهای بزرگ در شبکه قدرت، تغییرات شدید و ناگهانی در توان الکتریکی را سبب می شود؛ در حالی که توان مکانیکی ورودی به ژنراتورها نسبتاً ثابت است. این اختلالات شبکه باعث نوسانات در زاویه رتور ماشین ها شده و در نتیجه نوسانات شدید توان را در پی خواهند داشت. چنین نوساناتی، اعم از پایدار یا ناپایدار، موجب عملکرد ناخواسته رله های دیستانس می گردد و این امر خود می تواند به اوضاع بدتر منجر شود. به طور کلی، رله های دیستانس باید تحت این شرایط دینامیکی، دستور قطع را صادر نکنند. بر همین اساس، تابع PSB در رله های دیستانس برای جلوگیری از ارسال دستور قطع ناخواسته طی نوسان توان در درون این رله ها تعبیه شده است. لیکن، برای حفظ شاخص قابلیت اتکا، لازم است تا در صورت وقوع خطا اعم از خطای متقارن و نامتقارن، رله دیستانس از حالت قفل خارج و با تشخیص خطای رخ داده، دستور قطع را برای کلیدهای مربوطه ارسال نماید.

فلسفه تشخیص هوشمند خطا طی شرایط نوسان توان بر این فرضیه استوار است که می توان به صورت آفلاین رابطه ای غیرخطی مابین وقوع یا عدم وقوع خطا طی نوسان توان و مقادیر پارمترهای قابل اندازه گیری در محل رله دیستانس هم چون ولتاژ و جریان، بر اساس روش های موجود در یاد گیری ماشین استخراج نمود. سپس، بر مبنای تابع

کلیت الگوریتم هوشمند پیشنهادی به صورت آنلاین در شکل (۱) نشان داده شده است. همان طور که در این شکل مشاهده می شود، پس از وقوع اغتشاش، اولین مجموعه از داده های مربوط به پارامتر اندازه گیری شده  $(X_t)$  به مدل هوشمند جهت تصمیم گیری اعمال می شود. سپس، خروجی مدل هوشمند در این لحظه  $(Y_t)$  از منظر این که آیا قابل اطمینان است یا خیر، بررسی می شود. در صورت قابل اطمینان بودن خروجی در لحظه  $t$ ، الگوریتم متوقف و نتیجه اعلام می شود و اگر نتیجه خروجی از قابلیت اطمینان کافی برخوردار نباشد، دومین مجموعه از داده های اندازه گیری شده  $(X_{t+1})$  به همراه خروجی مدل هوشمند در لحظه  $t$  ( $h_t$ ) توسط مدل هوشمند دریافت و سپس، تصمیم گیری به عمل می آید. این روند تا لحظه ای که پاسخ با قابلیت اطمینان کافی به دست آید، ادامه می یابد.


### ۲-۲- شبکه ی عصبی بازگشتی LSTM

بدون شک، امروزه ابزار شبکه های عصبی از مهمترین ابزار برای حل مسائل مختلف مهندسی شناخته می شوند [۲۰-۲۱]. شبکه های عصبی بازگشتی نوعی خاص از شبکه های عصبی هستند که در ساختار خود شاخه بازگشتی دارند [۱۹] و برای مدل سازی و پیش بینی داده های زمانی که در حوزه زمان وابستگی دارند، استفاده می شوند. در واقع دسته ای از شبکه ها هستند که یک سری زمانی از بردارها مانند  $[X_1, X_2, \dots, X_T]$  را به عنوان ورودی می گیرند و خروجی های آن ها یک سری زمانی از بردارها

مانند  $[h_1, h_2, \dots, h_T]$  می‌باشد که خروجی آن برای مقادیر مختلف زمانی مانند  $t=1, 2, \dots, T$  از معادله زیر بدست می‌آید [۲۲].

$$h_t = f(Wx_t + Hh_{t-1} + b) \quad (1)$$

که در معادله فوق  $f$  تابع فعال‌ساز و غیرخطی است و  $W$  و  $H$  پارامترهای یادگیری می‌باشند.



شکل ۱- نحوه عملکرد الگوریتم هوشمند و زمان-تطبیقی تشخیص خطای نوسان توان

کاهشی و مشتق‌های زنجیره‌ای می‌باشد، این‌گونه شبکه‌ها در داده‌های زمانی که وابستگی طولانی دارند دچار مشکل می‌شوند و کارایی خود را در این‌گونه داده‌ها از دست می‌دهند که البته این مشکل به‌عنوان نقیصه برای این شبکه‌ها به حساب می‌آید [۲۳] و سبب شده‌است تا این دسته از شبکه‌های عصبی از عملکرد ضعیفی در برابر داده‌های با وابستگی طولانی برخوردار باشند [۲۴]. از این جهت، شبکه‌های عصبی بازگشتی LSTM برای حل معضل مطرح‌شده پیشنهاد شده‌است که شبکه‌هایی کامل‌تر و پیشرفته‌تری نسبت به شبکه‌های عصبی بازگشتی سنتی هستند.

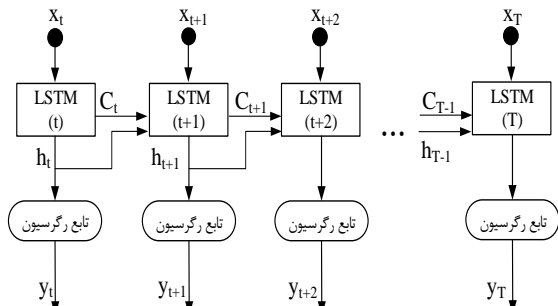
### ۲-۳- واحد LSTM

در حقیقت هدف اصلی طراحی شبکه‌های عصبی بازگشتی LSTM، حل کردن مشکل وابستگی‌های بلند مدت می‌باشد. در این‌گونه شبکه‌ها به‌جای نورون‌ها در لایه‌های پنهان از بلوک‌های حافظه‌ای استفاده می‌شود که این بلوک‌ها می‌توانند شامل یک یا چندین سلول حافظه‌ای

این شبکه‌ها به‌دلیل داشتن شاخه بازگشتی در ساختار خود، عملاً قدرت حافظه‌ای دارند. به‌دلیل این قابلیت حافظه‌ای، شبکه‌ها می‌توانند اطلاعات گذشته را برای استفاده در لحظه‌های بعدی نگهداری کنند و در واقع وابستگی زمانی در داده‌های ورودی را لحاظ نمایند [۲۳] و [۲۹]. مزیتی که شبکه‌های عصبی کلاسیک فاقد آن هستند. چنین مزیتی، این امکان را فراهم می‌کند تا بتوان مبتنی بر این-گونه شبکه‌های عصبی، الگوریتم‌هایی زمان-تطبیقی طراحی نمود [۲۲]. قابلیتی که شبکه‌های عصبی کلاسیک از آن بی‌بهره‌اند. دقیقاً چنین خصوصیتی سبب‌شد تا نویسندگان این مقاله بتوانند الگوریتمی زمان-تطبیقی برای تشخیص خطای نوسان توان پیشنهاد دهند. درکنار این مزیت مهم، مزیت‌های دیگری نیز هستند که می‌توان به- مواردی شامل قدرت تعمیم بالا، پشتیبانی سخت‌افزاری و نرم‌افزاری اشاره نمود [۲۹].

از آنجایی که فرایند آموزش معماری و ساختار شبکه‌های عصبی بازگشتی سنتی، مبتنی بر الگوریتم‌های گرادیان

این ساختار برای سادگی در قالب یک لایه پنهان نشان داده شده است. اگرچه، در روش پیشنهادی این مقاله، از سه لایه از نورون‌های عصبی مبتنی بر واحدهای LSTM استفاده شده است. همان‌طور که در شکل (۳) مشاهده می‌شود، در هر زمان، مقادیر حالت ( $C_t$ ) و خروجی ( $h_t$ ) بلوک‌ها جهت استفاده در لحظه بعدی منتقل می‌شوند و در ادامه هر یک از بلوک‌ها، تابع رگرسیونی برای استخراج خروجی نهایی، تعبیه شده است.



شکل ۳- ساختار شبکه عصبی بازگشتی بر پایه واحدهای LSTM برای سری زمانی داده‌های  $\{x_t, x_{t+1}, \dots, x_T\}$

## ۲-۵- نحوه آموزش شبکه

در آموزش روش پیشنهادی ابتدا بردار داده در لحظه  $t$  ( $x_t$ ) در نظر گرفته می‌شود و پس از محاسبه مقادیر حالت و خروجی بلوک LSTM و مقدار خروجی شبکه که به ترتیب در شکل (۳)،  $C_t$ ،  $h_t$  و  $y_t$  هستند، مقدار خطای خروجی توسط تابع هدف محاسبه می‌گردد و پس از محاسبه مقدار خطا، مقادیر تغییرات وزن‌های شبکه توسط تابع بهینه‌ساز محاسبه می‌گردد و این مقادیر تغییرات در جایی ذخیره می‌شوند. سپس، بردار داده در لحظه  $t+1$  ( $x_{t+1}$ ) در نظر گرفته می‌شود. در این لحظه باید مقادیر حالت و خروجی بلوک LSTM در لحظه قبل به این لحظه منتقل شوند. در ادامه، در این مرحله نیز حالت و خروجی LSTM و مقدار خروجی شبکه که در شکل (۳) به ترتیب با  $C_{t+1}$ ،  $h_{t+1}$  و  $y_{t+1}$  مشخص شده‌اند، محاسبه و مقدار خطای خروجی توسط تابع هدف تعیین و بر اساس آن مقادیر تغییرات وزن‌های شبکه محاسبه و در جایی ذخیره می‌شوند. این فرایند تا زمانی ادامه پیدا می‌کند که تمام بردارهای یک سناریو تا لحظه از قبل تعیین شده  $T$  به شبکه اعمال شوند. در پایان و بعد از اعمال بردار  $x_T$ ، مقادیر تغییرات همه وزن‌ها که در لحظات قبلی محاسبه شده‌اند، به وزن‌های اولیه اضافه و اصلاح وزن‌ها انجام می‌گیرد. این کار برای تمام سناریوها تکرار می‌شود [۱۹].

شوند. سلول‌ها در بلوک‌ها جهت ذخیره و ایجاد یک حافظه بلند مدت (حالت) در طول زمان، استفاده می‌شوند [۱۹]. ساختار و شکل یک بلوک حافظه با یک سلول در شکل (۲) نشان داده شده است.

همان‌طور که در شکل (۲) نشان داده شده است، هر بلوک در شبکه‌های عصبی بازگشتی LSTM دارای سه گیت می‌باشد که عبارتند از گیت‌های فراموشی، ورودی و خروجی. این گیت‌ها پاک کردن حافظه بلوک، کنترل و خروج داده‌ها به بلوک را بر عهده دارند. این گیت‌ها برای انجام وظایف خود با یک حافظه سلول هماهنگ هستند که نحوه انجام این کنترل و اعمال تغییرات در حافظه بلوک، با استفاده از روابط زیر انجام می‌پذیرد [۲۲].

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (2)$$

$$c_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (3)$$

$$f_t = (W_f x_t + U_f h_{t-1} + b_f) \quad (4)$$


$$C_t = f_t \times C_{t-1} + i_t \times c_t \quad (5)$$

بنابراین، طبق روابط فوق خروجی بلوک به صورت زیر برورسانی می‌شود [۲۲].

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (6)$$

$$h_t = o_t \times \tanh(C_t) \quad (7)$$

که در این روابط،  $\sigma(x) = \frac{1}{1+e^{-x}}$  تابع سیگموئید می‌باشد و  $W$ ،  $U$  و  $b$  ماتریس‌های مربوط به پارامترهای یادگیری هستند.



شکل ۲- ساختار کلی یک بلوک LSTM [۲۲]

## ۲-۴- ساختار شبکه

ساختار شبکه‌ی عصبی بازگشتی LSTM برای یادگیری و برای سری زمانی از داده‌های ورودی  $\{x_t, x_{t+1}, \dots, x_T\}$  در شکل (۳) نمایش داده شده است. لازم به ذکر است که

که  $\bar{y}(n)$  مقدار خروجی و  $y(n)$  مقدار واقعی می‌باشند و پارامترهای b, U, W, همان ماتریس‌های وزن‌های شبکه هستند.

### ۳-۳-۳- ارزیابی آنلاین مدل هوشمند

برای ارزیابی روش پیشنهادی ابتدا داده تست را آماده و سپس به روش اعمال شده‌است. با توجه به اینکه در روش پیشنهادی لایه رگرسیونی در لایه آخر قرار دارد، بنابراین خروجی در بازه [0 1] قرار می‌گیرد. در نتیجه برای رسیدن به پاسخ نهایی موردنظر مقدار آستانه‌ای تعریف می‌شود که در این مقاله و در ادامه، این مقدار آستانه با DF مشخص می‌شود.

### ۴- الگوریتم آنلاین پیشنهادی

در روش پیشنهادی، پنجره داده با طولی متغیر در نظر گرفته شده‌است. در نتیجه مدت زمان پاسخ الگوریتم مذکور متغیر است. در این بخش، الگوریتمی هوشمند و زمان تطبیقی مبتنی بر شبکه‌های عصبی بازگشتی LSTM که در بخش پیشین توضیح داده شد، ارائه می‌گردد. قابل ذکر- است که هدف این الگوریتم، تشخیص خطای نوسان توان است همراه با حفظ دقت و قابلیت اطمینان بالا در کوتاه‌ترین زمان.

الگوریتم پیشنهادی این مقاله در شکل (۴) نشان داده شده است. همان‌طور که مشاهده می‌شود، این الگوریتم از چهار بخش (۱) دریافت داده، (۲) تشخیص لحظه وقوع اغتشاش، (۳) تشخیص هوشمند و زمان-تطبیقی خطا و (۴) ارسال دستور به رله برای باقی ماندن در شرایط قفل و یا خارج شدن از شرایط قفل، تشکیل شده‌است که در ادامه به این بخش‌ها پرداخته می‌شود.

(۱) دریافت داده: در این قدم، سیگنال‌های دریافتی

از خروجی ترانسفورماتورهای ولتاژ و جریان در هر سه فاز با فرکانس نمونه‌برداری ۱۰ کیلوهرتز نمونه‌برداری می‌شوند.

(۲) تشخیص لحظه وقوع اغتشاش: برای تشخیص

لحظه وقوع اغتشاش (وقوع خطا و یا کلیدزنی)، در این مقاله از روش تشخیص لحظه اغتشاش مبتنی بر اطلاعات امواج سیار که در مقاله [۱۰] ارائه گردیده‌است، استفاده شده‌است. در فلوچارت نشان داده شده در شکل (۴)، در صورت تشخیص وقوع اغتشاش، کلید S3 بسته می‌شود.

### ۳- مدل‌سازی شبکه عصبی بازگشتی LSTM

#### تشخیص خطای نوسان توان

#### ۳-۱- تولید داده

به منظور طراحی مدلی هوشمند بر پایه شبکه عصبی بازگشتی LSTM که بتواند به صورت آنلاین برای تشخیص خطای نوسان توان مورد استفاده قرار گیرد، ضروری است تا قبلاً به صورت آفلاین آموزش داده شود. برای آموزش چنین مدلی، به سری زمانی از داده‌های اندازه‌گیری شده طی شبیه‌سازی سیستم قدرت تحت حفاظت در شرایط مختلف بهره‌برداری شامل کلیدزنی‌ها و خطاها نیاز است. در این مقاله، از جریان‌های سه‌فاز به‌عنوان داده ورودی مدل هوشمند استفاده گردیده است. فرکانس نمونه‌برداری برابر با ۱۰ کیلوهرتز در نظر گرفته شده که معادل ۱۶۷ نمونه در هر سیکل فرکانس اصلی شبکه قدرت (۶۰ هرتز) است. ماتریس یک سناریو داده بعد از وقوع یک اغتشاش در لحظه  $t_0$  به صورت زیر است.

$$X = \begin{bmatrix} i_a^1 & i_a^2 & \dots & i_a^T \\ i_b^1 & i_b^2 & \dots & i_b^T \\ i_c^1 & i_c^2 & \dots & i_c^T \end{bmatrix} \quad (8)$$

$$= [x_1 \quad \dots \quad x_T]$$

که T حداکثر زمان مجاز برای تصمیم‌گیری پس از وقوع اغتشاش است که در این مقاله، برابر با ۰/۵ میلی‌ثانیه در نظر گرفته شده است.

#### ۳-۲- آموزش آفلاین مدل هوشمند

به منظور استفاده از داده‌های اندازه‌گیری شده برای آموزش آفلاین، برای هر سناریو و در لحظه t بعد از وقوع اغتشاش، جفت داده زیر تعریف شد:

$$\{x_t, y_t\}, x_t = \begin{bmatrix} i_a^t \\ i_b^t \\ i_c^t \end{bmatrix}, y_t = \begin{cases} 1 & \text{خطا} \\ 0 & \text{غیرخطا} \end{cases} \quad (9)$$

و بر این اساس، مجموعه داده آموزش  $\{X(n), y(n)\}_{n=1}^N$  آماده گردید. هدف از آموزش شبکه، محاسبه مقادیر بهینه وزن‌های شبکه (ماتریس‌های U, W, b در روابط (۲) تا (۷)) می‌باشد. در این مقاله، از بهینه‌ساز آدام همراه با تابع حداقل مربعات خطا جهت پیدا کردن مقادیر بهینه وزن‌های شبکه استفاده شده است [۲۵]:

$$\min_{b,U,W} \frac{1}{2} \sum_{n=1}^N (\hat{y}(n) - y(n))^2 \quad (10)$$

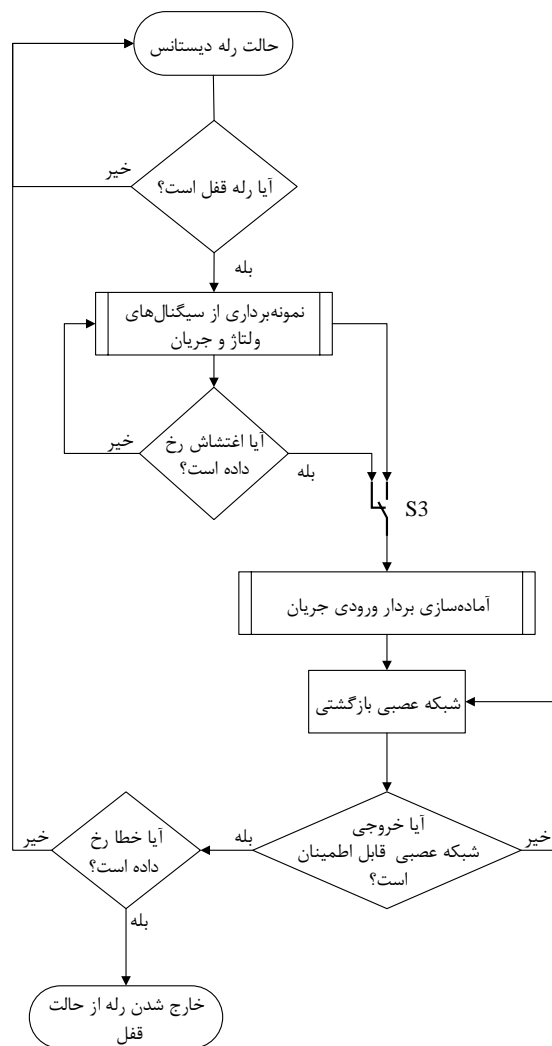
بخش پیشین به آن اشاره شد، در لایه خروجی شبکه عصبی از تابع رگرسیونی استفاده شده است که مبین خروجی در بازه  $[0 \ 1]$  است. برای اخذ تصمیم نهایی، ضروری است تا خروجی مذکور با حد آستانه DF مقایسه گردد. اکنون اگر خروجی از مقدار آستانه به حد کافی بزرگتر و یا از آن کوچکتر باشد، تصمیم اتخاذ شده از قابلیت اطمینان بالایی برخوردار است و در غیر این صورت قابل اطمینان نیست و بایستی داده در لحظه بعدی هم دریافت شود. در این پژوهش، از تابع زیر در خروجی شبکه عصبی بازگشتی LSTM در هر لحظه  $t$  استفاده شده است:

خروجی تصمیم =

$$(11) \quad \begin{cases} \text{خطا} & y_t > 1 - DF \\ \text{غیر خطا} & y_t < DF \\ \text{عدم تصمیم گیری} & DF \leq y_t \leq 1 - DF \end{cases}$$

که  $y_t$  و DF به ترتیب خروجی شبکه عصبی LSTM و حد آستانه هستند. همان طور که در رابطه (۱۱) مشاهده می شود، برای تصمیم گیری نهایی، لازم است تا خروجی شبکه عصبی LSTM در لحظه  $t$  از  $(1-DF)$  بزرگتر و یا از DF کوچکتر باشد. در غیر این صورت، الگوریتم برای استخراج تصمیم نهایی نیازمند نمونه های جریان در لحظه  $t+1$  است. حد آستانه DF تأثیر زیادی بر دقت و سرعت پاسخ دهی الگوریتم دارد که لازم است تا طی مرحله طراحی و آموزش شبکه عصبی با انجام مطالعه حساسیت (در زیر بخش ۱-۶ به آن پرداخته شده است) انتخاب می گردد. در این مقاله، مبتنی بر آنالیز حساسیت انجام گرفته بر شبکه قدرت مورد مطالعه [۲۶]، مقدار  $0.47$  در نظر گرفته شده است.

(۴) ارسال دستور به رله: پس از بررسی اغتشاش رخ داده، در صورت تشخیص اغتشاش به عنوان خطا، دسترسی جهت از قفل خارج شدن رله دیستانس ارسال می گردد. بدیهی است در صورت شرایط غیرخطا، رله کماکان در شرایط قفل باقی خواهد ماند.



شکل ۴- الگوریتم پیشنهادی

(۳) تشخیص هوشمند و زمان-تطبیقی خطا: پس از تشخیص وقوع اغتشاش در لحظه  $t_0$ ، در قدم قبلی، نمونه های جریان در هر سه فاز در قالب برداری  $x_t$ ، به شبکه عصبی بازگشتی LSTM که از قبل و به صورت آفلاین آموزش داده شده است، اعمال می گردد. در صورتی که خروجی شبکه عصبی از قابلیت اطمینان بالایی برخوردار باشد، اعلام و بسته به خروجی، رله دیستانس از حالت قفل خارج و یا در آن باقی می ماند. در غیر این صورت، نمونه های جریان در هر سه فاز برای لحظه  $t+1$  دریافت و در قالب برداری  $x_{t+1}$ ، به شبکه عصبی اعمال و همین روند تا حصول نتیجه با قابلیت اطمینان بالا و یا پایان لحظه بررسی که در این پژوهش برابر با  $0.5$  میلی ثانیه پس از وقوع اغتشاش است، ادامه پیدا می کند. همان طور که در

از دو مدار در خط انتقال دومداره، با خازن‌های سری با ضریب جبران‌سازی ۴۰ درصد جبران شده‌اند. در شبیه‌سازی‌های انجام‌گرفته در نرم‌افزار PSCAD، خطوط با مدل‌گسترده مدل‌شده‌اند و برای فراهم‌آوردن شرایط ایجاد نوسان، ژنراتور سنکرون سمت باس ۳ همراه با پارامترهای ماشین، تنظیم‌کننده ولتاژ و گاورنر مدل‌شده است. در حالی که مدل در نظر گرفته‌شده برای منبع سمت باس ۱، مدار معادل تونن دیده‌شده از دید باس ۱ می‌باشد. در این شبکه برای اندازه‌گیری‌های ولتاژ و جریان در محل رله، ترانسفورماتورهای ولتاژ و جریان مدل‌شده‌اند. کلیه مشخصات شبکه قدرت نمونه مطابق با [۲۶] می‌باشد.

### ۵-۲- تشکیل داده‌های کلیدزنی و خطا در شرایط نوسان توان

همان‌طور که در بخش‌های پیشین به آن اشاره شد، برای آموزش آفلاین مدل‌های هوشمند، ضروری است تا داده‌های کافی برای آموزش در دسترس باشند. از این جهت، در این پژوهش مبتنی بر شبیه‌سازی شبکه نمونه نشان داده‌شده در شکل (۵)، داده‌های موردنیاز برای آموزش شبکه عصبی بازگشتی LSTM تولیدگردید. این داده‌ها در دودسته داده‌های مرتبط با شرایط کلیدزنی طی نوسان توان و داده‌های مرتبط با شرایط خطا طی نوسان توان قرار گرفتند و برای آموزش شبکه هوشمند پیشنهادی این مقاله به کار گرفته شدند. در ادامه، به سناریوهای مختلف برای ایجاد شرایط مختلف کلیدزنی طی نوسان توان و شرایط مختلف ایجاد خطا طی شرایط نوسان توان اشاره شده است.

### ۵-۳- ایجاد شرایط نوسان توان

عوامل مختلفی می‌توانند منجر به نوسان توان در شبکه‌های قدرت شوند. به‌عنوان نمونه، در شبکه نمونه نشان داده‌شده در شکل (۵)، وقوع خطا در مدار دوم خط انتقال دومداره و سپس، برطرف شدن آن، می‌تواند منجر به نوسان توان در مدار اول خط انتقال دومداره شود. در این مقاله، از همین عامل برای ایجاد شرایط نوسان توان در مدار اول خط انتقال مورد مطالعه استفاده شده است. در پی وقوع خطای سه‌فاز در مدار دوم، کلیدهای دوطرف خط انتقال (B1 و B2) در ۱/۰ ثانیه پس از وقوع خطا بازمی‌شوند. با برطرف شدن خطا، نوسان توان ایجاد و در محل رله در مدار اول خط دومداره دیده می‌شود. لازم به ذکر است که داده‌های مرتبط با این سناریوها در محل رله در ابتدای مدار اول خط دومداره

### ۵- مدل‌سازی و پیاده‌سازی الگوریتم پیشنهادی


در این مقاله، برای اثبات فرضیه شناسایی زمان-تطبیقی و هوشمند انواع خطا طی نوسان توان در خطوط جبران‌شده سری به کمک شبکه عصبی کوتاه‌مدت ماندگار، سه مرحله انجام گرفته است:

- ۱) مدل‌سازی سیستم نمونه کمیته حفاظت IEEE برای تست حفاظت خط انتقال [۲۶] در نرم‌افزار PSCAD،
- ۲) انتخاب سناریوهای شبیه‌سازی سیستم نمونه برای تشکیل داده‌های کلیدزنی و خطا در شرایط نوسان توان
- ۳) آموزش و ارزیابی مدل هوشمند مبتنی بر داده‌های آماده‌شده.

در ارتباط با مرحله اول، در این پژوهش، برای مطالعه و بررسی روش پیشنهادی، از سیستم نمونه [۲۶] که توسط کمیته حفاظت IEEE برای تست حفاظت خط انتقال ارائه گردیده، استفاده شده است. در خصوص مرحله دوم نیز در این مقاله، تعداد ۵۷۶۰ سناریو برای انواع شرایط خطا و کلیدزنی‌های بانک خازنی و بار طی شرایط نوسان توان برای تولید ورودی‌های نمونه جهت تریق مدل هوشمند در نظر گرفته شده است. در خصوص مرحله سوم نیز مدل هوشمند آموزش داده شده با ۷۰ درصد کل داده‌های تولیدی، بر روی ۳۰ درصد از داده‌ها که در مرحله آموزش به کار نگرفته شده بودند و شامل مجموع متنوعی از انواع خطا و شرایط کلیدزنی است، اعمال و نتایج استخراج شدند. در ادامه، به دو مرحله اول به تفصیل پرداخته می‌شود و مرحله سوم که شامل نتایج می‌شود در بخش ۶ آورده خواهد شد.

### ۵-۱- مدل‌سازی شبکه نمونه

شکل (۵) شبکه قدرت استفاده‌شده برای مطالعه و بررسی روش پیشنهادی را نشان می‌دهد.



شکل ۵- شبکه قدرت نمونه [۲۶]

در این شبکه قدرت، دو خط انتقال ۲۳۰ کیلوولت وجود دارد. اولین خط انتقال، خط انتقالی دو مداره بین باس‌های ۱ و ۲ و دومین خط انتقال، خط انتقالی تک‌مداره بین باس ۲ و ۳ می‌باشد. طول هر خط انتقال ۷۲/۴۲ کیلومتر است. هر یک



اندازه‌گیری و جمع‌آوری شده‌اند.

(۵)، آورده شده‌اند. همان‌طور که در جداول مذکور ملاحظه می‌شود، ۱۶۸۰ مورد مربوط به کلیدزنی بانک خازنی و ۱۴۴۰ مورد مربوط به کلیدزنی بار می‌باشند که جمعاً ۳۱۲۰ مورد می‌باشند که از این تعداد ۲۸۸۰ مورد در نظر گرفته شده است.

#### ۵-۴- سناریوهای کلیدزنی طی نوسان توان

در جداول ۱ و ۲ شرایط مختلف برای وقوع کلیدزنی بانک خازنی و بار بر روی باس (۲) شبکه نشان داده شده در شکل

جدول ۲- مشخصات و تعداد کل سناریوهای کلیدزنی بار طی

تعداد کل سناریوها	زاویه بار (رادیان)	لحظه کلیدزنی (درجه)	نوع عملیات	میزان بار برای کلیدزنی (مگاوات آمپر)
۶×۲×۱۰×۱۴۰=۱۶۸۰	از ۰/۴ تا ۱/۴ با گام ۰/۲ رادیانی	از صفر تا ۱۸۰ گام‌های ۹ درجه‌ای	ورود بار، خروج بار	۵۰±۲۵
				۱۰۰±۷۵
				۱۵۰±۷۵
				۲۰۰±۱۰۰
				۲۵۰±۱۲۵
۵۰±۳۰۰				
(۶)	(۶)	(۲۰)	(۲)	(۶)

جدول ۱- مشخصات و تعداد کل سناریوهای کلیدزنی بانک

تعداد کل سناریوها	زاویه بار (رادیان)	لحظه کلیدزنی (درجه)	نوع عملیات	ظرفیت خازن برای کلیدزنی (مگاوار)
۷×۲×۲۰×۶=۱۶۸۰	از ۰/۴ تا ۱/۴ با گام‌های ۰/۲ رادیانی	از صفر تا ۱۸۰ گام‌های ۹ درجه‌ای	ورود بانک خازنی، خروج بانک خازنی	۲۰۰ تا ۵۰
				با گام‌های ۲۵
				مگاواوری
(۶)	(۶)	(۲۰)	(۲)	(۷)

جدول ۳- مشخصات و تعداد سناریوهای خطا طی نوسان توان روی مدار اول خط انتقال دومداره

تعداد کل سناریوها	زاویه بار (رادیان)	زمان وقوع خطا	مقاومت خطا (اهم)	نوع خطا	مکان خطا (برحسب درصد از طول مدار اول خط دومداره)
۶×۱۰×۲۰×۱۲×۱۱=۱۶۸۰	۱/۴، ۱	ماکزیمم ولتاژ در هر سه‌فاز، ماکزیمم جریان در هر سه‌فاز، مینیمم ولتاژ در هر سه‌فاز و مینیمم جریان در هر سه‌فاز	۵۰، ۰/۰۱	AG-BG-CG-AB-BC-AC-ABG-BCG-ACG-ABC	صفر، ۰.۳۳، ۰.۲۵، ۰.۵۰، ۰.۶۶، ۰.۷۵
(۶)	(۲)	(۱۲)	(۲)	(۱۰)	(۶)

#### ۵-۵- سناریوهای خطا نوسان توان

سناریوهای مختلف برای وقوع خطا طی نوسان توان در این پژوهش مطابق با جدول ۳ هستند. در این سناریوها، پارامترهای مختلف شامل نوع خطای رخ داده، مکان وقوع خطا، اندازه مقاومت خطا، لحظه وقوع خطا با توجه به لحظات ماکزیمم و مینیمم ولتاژ و جریان طی نوسان توان و میزان بار عبوری قبل از وقوع خطا مدنظر قرار گرفته‌اند. بر این اساس، جمعاً تعداد ۲۸۸۰ سناریو برای وقوع خطا طی نوسان توان در نظر گرفته شد.

#### ۵-۶- آموزش آفلاین مدل هوشمند و زمان-تطبیقی برای

##### تشخیص خطا طی نوسان توان

با توجه به جداول ۱ تا ۳ کل سناریوهای تولید شده برابر با ۵۷۶۰ مورد می‌باشد. در این پژوهش، به‌طور تصادفی مجموعه ۷۰ درصد داده تولیدی (برابر با ۴۰۳۲ مورد) انتخاب و برای آموزش به‌کار گرفته شد و مابقی ۳۰ درصد (معادل با ۱۷۲۸ مورد) نیز برای ارزیابی مدل هوشمند آموزش داده شده مدنظر قرار گرفت. شبکه عصبی بازگشتی LSTM پیشنهادی در این مقاله، از سه لایه تشکیل شده

$$A(t_i) = \frac{C(t_i) - M(t_i)}{C(t_i)} \quad (12)$$

$A(t)$ : دقت شبکه‌عصبی بازگشتی LSTM تا نمونه  $t$  (درصد)

$$A(t) = \frac{C(t) - M(t)}{C(t)} \quad (13)$$

میانگین پاسخ زمانی (Average Response Time (ART)) و میانگین دقت (Average Accuracy (AA)) که مبتنی بر روابط (۱۴) و (۱۵) تعریف می‌شوند [۲۷]:

$$ART = \frac{\sum_{i=1}^m (t_i \times C(t_i))}{\sum_{i=1}^m (C(t_i))} \quad (14)$$

$$AA = \frac{\sum_{i=1}^m A(t)}{m} \quad (15)$$

که در روابط فوق  $m$  برابر با تعداد نمونه‌ها در حداکثر طول پنجره داده پس از وقوع اغتشاش برای ارزیابی شرایط وقوع و یا عدم وقوع خطا توسط الگوریتم است که در این مقاله برابر با ۵ انتخاب شده‌است. برای داده آموزش، ART و AA مطابق با روابط (۱۴) و (۱۵)، برای تشخیص خطا طی نوسان توان به ترتیب برابر با  $0.1003$  میلی‌ثانیه و  $99/34$  درصد به‌دست آمده‌اند. همچنین، برای داده‌های تست که برابر با ۱۷۲۸ مورد هستند، ART و AA برای تمایز تشخیص خطا طی نوسان توان به ترتیب برابر با  $0.1004$  میلی‌ثانیه و  $99/04$  درصد هستند.

است که هر لایه هم شامل ۵ بلوک LSTM است. از آنجا که بردار ویژگی ورودی متشکل از جریان هر سه فاز است، برابر با ۳ می‌باشد. همچنین، پارامترهای DF و حداکثر زمان مجاز برای تصمیم‌گیری پس از وقوع اغتشاش به ترتیب برابر با  $0.47$  و ۵ نمونه تنظیم شده‌اند.

## ۶- نتایج

در جدول ۴ نتایج خروجی شبکه‌عصبی بازگشتی LSTM برای داده‌های آموزشی و تست مشاهده می‌شوند. لازم به ذکر است که اطلاعات جداول مذکور فقط تا نمونه  $t_5$  نشان داده شده‌است. پارامترهای نشان داده شده در این جداول به صورت زیر تعریف می‌شوند [۲۷]:  
 $t_i$ : لحظه متناظر با نمونه  $t$  بعد از وقوع اغتشاش (لحظه وقوع اغتشاش  $t_0$ ).

$U(t)$ : تعداد کل مواردی که تا لحظه  $t$  هنوز شناسایی نشده‌اند.

$C(t_i)$ : تعداد کل مواردی که با نمونه  $t_i$  شناسایی شده‌اند.

$C(t)$ : تعداد کل مواردی که تا لحظه  $t$  شناسایی شده‌اند.

$M(t_i)$ : تعداد کل مواردی که با نمونه  $t_i$  به درستی شناسایی نشده‌اند.

$M(t)$ : تعداد کل مواردی که تا نمونه  $t$  به درستی شناسایی نشده‌اند.

$A(t_i)$ : دقت شبکه‌عصبی بازگشتی LSTM در نمونه  $t_i$  (درصد)

جدول ۴- نتایج خروجی شبکه عصبی بازگشتی برای داده‌های آموزش و تست

$t_i$	داده‌های آموزش							داده‌های تست						
	U(t)	C(t <sub>i</sub> )	C(t)	M(t <sub>i</sub> )	M(t)	A(t <sub>i</sub> ) (%)	A(t) (%)	U(t)	C(t <sub>i</sub> )	C(t)	M(t <sub>i</sub> )	M(t)	A(t <sub>i</sub> ) (%)	A(t) (%)
۰	۴۰۳۲	-	-	-	-	-	-	۱۷۲۸	-	-	-	-	-	-
۱	۸	۴۰۲۴	۴۰۲۴	۲۵	۲۵	۹۹/۳۸	۹۹/۳۸	۲	۱۷۲۶	۱۷۲۶	۱۶	۱۶	۹۹/۰۷	۹۹/۰۷
۲	۳	۵	۴۰۲۹	۱	۲۶	۸۰	۹۹/۳۵	۲	۰	۱۷۲۶	۰	۱۶	۰	۹۹/۰۷
۳	۱	۲	۴۰۳۱	۱	۲۷	۵۰	۹۹/۳۳	۲	۰	۱۷۲۶	۰	۱۶	۰	۹۹/۰۷
۴	۰	۱	۴۰۳۲	۰	۲۷	۱۰۰	۹۹/۳۳	۱	۱	۱۷۲۷	۱	۱۷	۰	۹۹/۰۲
۵	۰	۰	۴۰۳۲	۰	۲۷	۰	۹۹/۳۳	۰	۱	۱۷۲۸	۱	۱۸	۰	۹۸/۹۶


سپس، به‌ازای هر مقدار DF، مقادیر ART و AA بر روی داده‌های تست به‌دست آمد. در شکل (۶)، مقادیر مختلف ART و AA برای DF های مختلف نشان داده شده‌اند. همان‌طور که دیده می‌شود با افزایش DF، ART سیر

## ۶-۱- بررسی حساسیت DF

برای بررسی حساسیت مقدار DF و در نهایت انتخاب مقدار آن برای شبکه قدرت مورد مطالعه، مقادیر مختلف DF در محدوده (0.5 0) و با گام‌های  $0.1$  در نظر گرفته شد.

برابر با ۰/۴۷ که متناظر با ART برابر با ۰/۱۰۰۴ میلی ثانیه و AA برابر با ۹۹/۰۴ درصد است، برای الگوریتم پیشنهادی انتخاب گردید.

کاهش و AA سیر افزایشی دارد. این رفتار تا مقدار ۰/۴۷ برای DF مشاهده می‌گردد. پس از این مقدار، هر دو شاخص تقریباً ثابت باقی مانده‌اند. از این جهت، مقدار DF



شکل ۶- بررسی حساسیت مقدار DF

در مقاله آماده شده بود، نمودند.

## ۷- ارزیابی مقایسه‌ای الگوریتم پیشنهادی

نتایج مندرج در جدول (۴) مبین این نکته است که اکثریت موارد می‌توانند در زمان خیلی سریع بعد از وقوع اغتشاش، به درستی شناسایی شوند. همان‌طور که در جدول ۴ مشاهده می‌شود تعداد ۱۷۲۶ از ۱۷۲۸ مورد تست با دقتی معادل با ۹۹/۰۷ درصد با همان نمونه اول به درستی شناسایی شده‌اند. این عملکرد قابل قبول به طور بالقوه به وسیله شبکه عصبی مجهز به واحدهای LSTM به دست آمده است. برای بررسی کارایی روش پیشنهادی در مقایسه با روش‌های مختلف هوشمند ارائه شده برای تشخیص خطای نوسان توان، مقادیر ART و AA روش پیشنهادی با این روش‌ها مقایسه شده است که نتایج این مقایسه در جدول ۵ آورده شده است. همان‌طور که مشاهده می‌شود، روش پیشنهادی دارای سرعت بالاتری نسبت به روش‌های هوشمند ارائه شده تاکنون برای تشخیص خطای نوسان توان است. از طرف دیگر، هیچکدام از روش‌های مبتنی بر یادگیری ماشین ارائه شده تاکنون نمی‌تواند به صورت زمان تطبیقی کار کنند. در حالی که روش پیشنهادی می‌تواند به صورت زمان تطبیقی خطای نوسان توان را تشخیص دهد. به علاوه این روش برای خطوط انتقال جبران شده سری پیاده سازی شده است. همچنین به منظور بررسی عملکرد استفاده از شبکه بازگشتی در طرح پیشنهادی در مقایسه با شبکه عصبی کلاسیک، نویسندگان اقدام به طراحی شبکه عصبی کلاسیک پرسپترون با استفاده از داده‌هایی که قبلاً

جدول ۵- ارزیابی مقایسه‌ای الگوریتم پیشنهادی

ART (ms)	AA (%)	نوع پنجره داده	بررسی خط جبران شده سری	روش
۱۰	۹۸/۷۱	ثابت	-	[۱۵]
گزارش نشده	۹۷/۵	ثابت	-	[۱۶]
۱۰	۱۰۰	ثابت	-	[۱۷]
۰/۱۰۰۴	۹۹/۰۴	تطبیقی	√	روش پیشنهادی

این شبکه متشکل از ۲ لایه پنهان، یک لایه ورودی با تعداد ورودی‌های برابر با ۴۵ (به ازای هر فاز ۱۵ نمونه جریان) و یک لایه خروجی با دو حالت خطا و غیرخطا است. در هر لایه پنهان از ۲۰ نرون استفاده شده است. شایان ذکر است که مشخصات مدل شبکه عصبی و طول پنجره داده برابر با ۱۵، مبتنی بر پیاده‌سازی‌های با مشخصات مدل و طول پنجره مختلف و با توجه به بهترین نتیجه به دست آمده، تعیین شده است. مطابق با آنچه که در مقاله برای مدل هوشمند پیشنهادی در نظر گرفته شده بود، از ۷۰ درصد از داده‌ها برای آموزش و از ۳۰ درصد برای تست استفاده شده است.

در جدول ۶ نتایج آورده شده است.

جدول ۶- مقایسه شبکه عصبی بازگشتی LSTM با شبکه عصبی کلاسیک پرسپترون

AA (%)	نوع پنجره داده	نوع الگوریتم
۹۶/۱۲	ثابت با طول ۱۵ نمونه‌ای	شبکه عصبی کلاسیک پرسپترون
۹۹/۰۴	تطبیقی	شبکه عصبی بازگشتی LSTM

همان‌طور که در جدول ۶ دیده می‌شود شبکه عصبی بازگشتی LSTM برتری محسوسی از منظر دقت نسبت به روش شبکه عصبی کلاسیک پرسپترون دارد. به علاوه، از خصوصیت تطبیقی بودن طول پنجره داده نیز برخوردار است.

#### ۸- نتیجه‌گیری

در روش پیشنهادی این مقاله، با استفاده از شبکه عصبی

بازگشتی (Long Short Term Memory (LSTM)) عملیات تشخیص خطای نوسان توان به صورت زمان تطبیقی است. به عبارت دیگر، طول پنجره داده مورد استفاده در الگوریتم هوشمند پیشنهادی متغیر و متناسب با شرایط مختلف وقوع خطا تغییر می‌کند. نتایج پیاده‌سازی روش پیشنهادی برای شرایط مختلف بر روی شبکه نمونه شامل انواع خطا، مکان خطا، مقاومت خطا و میزان بار، مبین میانگین پاسخ زمانی تشخیص بالای ۰/۱۰۰۴ میلی ثانیه همراه با میانگین دقت تشخیص قابل قبول ۹۹/۰۴ درصد می‌باشد. الگوریتم هوشمند و زمان-تطبیقی پیشنهادی دارای محاسبات ساده است و قابلیت جاسازی در رله‌های دیستانس را دارد. اگرچه، الگوریتم پیشنهادی قابلیت دسته‌بندی نوع خطا را که در رله‌های دیستانس مدرن وجود دارد را ندارد که در ادامه پژوهش حاضر، این موضوع مدنظر نویسندگان است.

#### مراجع

- [1] IEEE Power System Relaying Committee of the IEEE Power Engineering Society, Power swing and out-of-step considerations on transmission line. Report from PSRC WG D6; July 2005 [Online]. Available: <http://www.pes-psrc.org>.
- [2] R. Dubey, S. R. Samantaray, B. K. Panigrahi, and V. G. Venkoparao, "Phase-Space-Based Symmetrical Fault Detection during Power Swing," IET Generation, Transmission & Distribution, Vol. 10, No. 8, 2016, pp. 1947-1956.
- [3] R. Jafari, N. Moaddabi, M. Eskandari-Nasab, G. B. Gharehpetian and M. S. Naderi, "A Novel Power Swing Detection Scheme Independent of the Rate of Change of Power System Parameters," IEEE Transactions on Power Delivery, Vol. 29, No. 3, 2014, pp. 1192-1202.
- [4] R. J. Ganeswara and A. K. Pradhan, "Power-Swing Detection Using Moving Window Averaging of Current Signals," IEEE Transactions on Power Delivery, Vol. 30, No. 1, 2015, pp. 368-376.
- [5] J. Khodaparast and M. Khederzadeh, "Three-Phase Fault Detection During Power Swing by Transient Monitor," IEEE Transactions on Power Systems, Vol. 30, No. 5, 2015, pp. 2558-2565.
- [6] K. Andanapalli, and B. R. Varma, "Park's Transformation Based Symmetrical Fault Detection during Power Swing", 8<sup>th</sup> National Power Systems Conference, 2014.
- [7] J. Kumar, P. Jena, "Detection of Fault during Power Swing Using Superimposed Negative Sequence Apparent Power Based Scheme", 6<sup>th</sup> International Conference on Computer Applications In Electrical Engineering-Recent Advances, 2017, pp. 57-62.
- [8] P. Gawande and S. Dambhare, "A Novel Unblocking Function for Distance Relay to Detect Symmetrical Faults during Power Swing", IEEE Power and Energy Society General Meeting, 2016, pp. 1-6.
- [9] S. Das and B. K. Panigrahi, "Detecting Symmetrical Faults during Power Swing for Deblocking Distance Relays", IEEMA Engineer Infinite Conference, 2018, pp. 1-6.
- [10] M. Daryalal and M. Sarlak, "Fast Fault Detection Scheme for Series-Compensated Lines during Power Swing", International Journal of Electrical Power & Energy Systems, Vol. 230-244, 2017, pp. 230-244.
- [11] B. Patel and P. Bera, "Detection of Power Swing and Fault during Power Swing Using Lissajous Figure", IEEE Transactions on Power Delivery, Vol. 33, No. 6, 2018, pp. 3019-3027.

- [12] S. M. Hashemi, M. Sanaye-Pasand and M. Shahidehpour, "Fault Detection during Power Swings Using the Properties of Fundamental Frequency Phasors", IEEE Transactions on Smart Grid, Vol. 10, No. 2, 2019, pp. 1385-1394.
- [13] I. G. Tekdemir and B. Alboyaci, "A Novel Approach for Improvement of Power Swing Blocking and Deblocking Functions in Distance Relays", IEEE Transactions on Power Delivery, Vol. 32, No. 4, 2017, pp. 1986-1994.
- [14] J. G. Raol and A. K. Pradhan, "Supervising Distance Relay during Power Swing using Synchrophasor Measurements", IET Generation, Transmission & Distribution, Vol. 11, No. 17, 2017, pp. 4136-4145.
- [15] N. G. Chothani, B. R. Bhalja and U. B. Parikh, "New Support Vector Machine-Based Digital Relaying Scheme for Discrimination Between Power Swing and Fault", IET Generation, Transmission & Distribution, Vol. 8, No. 1, 2014, pp. 17-25.
- [16] K. Seethalekshmi, S. N. Singh S. N and S. C. Srivastava, "A Classification Approach Using Support Vector Machines to Prevent Distance Relay Maloperation under Power Swing and Voltage Instability", IEEE Transactions on Power Delivery, Vol. 27, No. 3, 2012, pp. 1124-1133.
- [17] A. Swetapadma and A. Yadav, "Data-Mining-Based Fault during Power Swing Identification in Power Transmission System", IET Science, Measurement & Technology, Vol. 10, No. 2, 2016, pp. 130-139.
- [18] M. J. Reddy and D. K. Mohanta, "Adaptive-Neuro-Fuzzy Inference System Approach for Transmission Line Fault Classification and Location Incorporating Effects of Power Swings", IET Generation, Transmission & Distribution, Vol. 2, No. 2, 2008, pp. 235-244.
- [19] Understanding LSTM networks. [Online]. Available: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [۲۰] زهرا مروج و جواد آذرخش، "شبیه‌سازی و طبقه‌بندی وقایع کیفیت توان با استفاده از شبکه‌عصبی"، مدل‌سازی در مهندسی، دوره ۱۳، شماره ۴۱، بهار ۱۳۹۴، صفحه ۱۳۷-۱۴۶.
- [۲۱] روح‌الله فیروزنیا و نیما امجدی، "پیش‌بینی بار کوتاه‌مدت با استفاده از تجزیه سری زمانی بار و شبکه‌عصبی"، مدل‌سازی در مهندسی، دوره ۲، شماره ۱۶، بهار ۱۳۸۷، صفحه ۲۳-۳۲.
- [22] J. J. Q. Yu, D. J. Hill, A. Y. S. Lam, J. Gu and DV. O. K. Li, "Intelligent Time Adaptive Transient Stability Assessment System", IEEE Transactions on Power Systems, Vol. 8, No. 5, 2017, pp.1125-1135.
- [23] Y. Bengio, P. Simard and P. Frasconi, "Learning Long-Term Dependencies with Gradient Descent is Difficult", IEEE Transactions on Neural Networks, Vol. 5, No. 2, 1994, pp. 157-166.
- [۲۴] محمود معلم و علی‌اکبر پویان، "کشف ناهنجاری با استفاده از کدکننده خودکار مبتنی بر بلوک‌های LSTM"، مدل‌سازی در مهندسی، دوره ۱۷، شماره ۵۶، بهار ۱۳۹۸، صفحه ۲۱۱-۲۱۹.
- [25] J. B. D. Kingma, "Adam: A Method for Stochastic Optimization", in Proceeding of International Conference for Learning Representations, 2015, pp. 1-15.
- [26] Power Systems Relaying Committee, EMTP reference models for transmission line relay testing report, Draft 10a. Technical report, 2004, [Online], Available: [http:// www.pserc.org](http://www.pserc.org).
- [27] R. Zhang, Y. Xu, Z. Y. Dong, and K. P. Wong, "Post-Disturbance Transient Stability Assessment of Power Systems by a Self-Adaptive Intelligent System," IET Generation, Transmission & Distribution, Vol. 9, No. 3, 2015, pp. 296-305.
- [28] S. Zhang, Y. Wang, M. Liu and Z. Bao, "Data-Based Line Trip Fault Prediction in Power Systems Using LSTM Networks and SVM", IEEE Access, Vol. 6, 2017, pp. 7675-7686.
- [29] Y. LeCun, Y. Bengio and G. Hinton, "Deep learning", Nature International Journal of Science, Vol. 521, No. 7553, 2015, pp. 436-444.