

Long-term Voltage Stability Assessment of an Integrated Transmission Distribution System based on LSTM Recurrent Neural Network

Alireza Hatami¹, Iraj Ganjkhani²

¹ Assistant Professor, Department of Electrical Engineering, Bu-Ali Sina University, Hamedan, Iran
hatamisharif@basu.ac.ir

² PhD Student, Department of Electrical Engineering, Bu-Ali Sina University, Hamedan, Iran
i.ganjkhani@eng.basu.ac.ir

Abstract

In this paper, a new method based on long-short-term memory neural networks is proposed for predicting long-term voltage instability in interconnected transmission and distribution networks. Using the online information of the phasor measurement units, the neural network estimates the stability of the network voltage and in case of any event in the network, it estimates the long-term voltage stability status using the information before and after the event. This structure can be used as an auxiliary tool to quickly inform the network operator of possible risks caused by voltage instability after any contingency in the network. The simulation results of different case studies in offline mode have been used to create the training dataset. In order to have different case studies, considering load growth in areas prone to voltage instability, (N-1) and (N-1-1) contingency have been simulated. The Nordic extended network has been used to evaluate the performance of the proposed method. Using the appropriate time shift, the occurrence of all contingencies has been moved to the tenth second so that the neural network only learns the trajectory of the features. The accuracy of the neural network in the 17th second (7 seconds after contingency) is 99.05%.

Keywords: long-term voltage stability, coupled transmission and distribution system, PMU, clustering

Article Type: Research

Received: 21. 12. 2022

Revised: 01. 06. 2023

Accepted: 04. 07. 2023

Corresponding author: Alireza Hatami

Corresponding author's address: Departement of Electrical Engineering, Bu-Ali Sina University, Shahid Mostafa Ahmadi Roshan Street, Hamedan, 6516738695, IRAN



1. Motivation of the work

The significant investment in the development of the power grid has necessitated researchers and operators to seek out novel approaches for the operation of power systems at maximum capacity. This, however, makes the system more prone to voltage instability in case of an emergency. Consequently, the operation of the power system can incur considerable risks, such as voltage collapse in one or more buses that may lead to a system blackout. Despite numerous studies conducted on voltage stability assessment for transmission and distribution systems as independent systems, few have considered their effects on each other. Not taking into account these mutual effects can lead to overestimation or underestimation of the load margin in voltage stability assessment.

To address this gap, we present an online tool installed in control centers for long-term voltage instability detection of integrated transmission and distribution systems using long-short-term memory neural networks (LSTM).

To demonstrate the viability of this tool, it was used to detect long-term voltage instability in the modified Nordic test system.

2. Contributions

The offline training of LSTM was performed based on the data obtained from the stimulation in the time domain using the Digsilent 2017 software. (N-1) and (N-1-1) contingencies were simulated by considering the load growth in the areas prone to voltage instability in the extended Nordic test network. The information obtained using the simulation in the interval of 10 seconds before and a few seconds after the contingency was used to train LSTMs. Here, data from 1 to 50 seconds after the contingency (in steps of 1 or 2 seconds) were used to train LSTMs. The main contributions of this paper are the following:

- Presenting an online tool based on LSTM networks for the detection of long-term voltage stability in integrated transmission and distribution systems
- A training approach for LSTM neural network with different time intervals with the aim of reducing estimation time, considering n-1, n-1-1 contingency, and load growth in training data.
- Performing numerous numerical simulations to determine the minimum time interval of information needed by LSTM after the contingency to achieve maximum performance accuracy.
- Reducing the input dimensions of LSTMs using the clustering method.

3. Procedures

In this approach, various scenarios have been simulated in the time domain using Digsilent 2017 software to create training and testing datasets. The modified IEEE 33-bus distribution system with total loads equivalent to the main network at 20 kV voltage has been replaced

only in the central part of the Nordic system to construct the extended Nordic test system. The generated scenarios including (N-1) and (N-1-1) contingency are simulated by taking into account load growth in areas prone to voltage instability of the extended Nordic test system. After 1200 seconds of the contingency, necessary measures like adjusting the transformer tap and voltage generator are taken. In instances of (N-1-1) contingency, it is assumed that one piece of equipment is out of service; meanwhile, for stable conditions, (N-1) contingency analysis is performed. Then, an LSTM network with two layers of neurons is trained using the generated scenarios in offline mode. The input features include the buses voltage of the transmission system (16 buses) and distribution system (11 buses), the incremental variance of the voltage of all buses (27 items), the position of the transformers tap-changer (13 items), and the reactive power and the voltage of the generators (28 items). The proposed method uses the data gathered by phasor measurement units to assess the voltage stability of the system online.

4. Findings

If an LSTM is trained with data from 10 seconds before and 7 seconds after the contingency, the instability detection accuracy reaches 99.05%. For example, with data gathered at a time interval of 17 seconds (10 seconds before and 7 seconds after the contingency), the LSTM fails to estimate only 63 items from the test set (6575 items). Out of 63 mentioned cases, the system is unstable in 45 cases, and the LSTM could not detect it. In 18 cases, the LSTM mistakenly detects the system as unstable. Indeed, the LSTM in 45 cases of the test set (6575 items) fails to detect voltage instability (0.68% of the total test data). The negligible error indicates the potential of the proposed two-layer LSTM to detect instability only 7 seconds after the contingency occurrence.

5. Conclusion

In this paper, a method based on recurrent long short-term memory (LSTM) neural network was presented to detect the long-term voltage instability of integrated transmission & distribution power systems (T&D). After occurring a contingency in the T&D network, the voltage stability is assessed within a few seconds. Therefore, the proposed method as an online tool can quickly detect voltage instability and inform the operator of the control center. The results show that using data with a longer post-contingency time interval increases the accuracy of the neural network at the cost of more time to respond. Finally, the possibility of reducing the dimensions (features) of input data to the neural network by clustering them has

been investigated, showing that the input features can be reduced from 95 to 80, while the accuracy of the neural network decreases slightly.

ارزیابی پایداری بلند مدت ولتاژ در شبکه‌های انتقال و توزیع به هم پیوسته مبتنی بر شبکه عصبی خود بازگشتی LSTM

علیرضا حاتمی^۱، ایرج گنج خانی^۲

۱- استادیار - دانشکده مهندسی برق - دانشگاه بوعلی سینا - همدان - ایران

hatamisharif@basu.ac.ir

۲- دانشجوی دکتری - دانشکده مهندسی برق - دانشگاه بوعلی سینا - همدان - ایران

i.ganjkhani@eng.basu.ac.ir

چکیده: در این مقاله روشی مبتنی بر شبکه‌های عصبی حافظه طولانی کوتاه‌مدت (LSTM) برای پیش‌بینی ناپایداری بلند مدت ولتاژ در شبکه‌های انتقال و توزیع به هم پیوسته پیشنهاد شده است. شبکه عصبی با استفاده از اطلاعات برخط واحدهای اندازه‌گیری فازور، وضعیت پایداری ولتاژ شبکه را رصد می‌کند و در صورت پیشامدی در شبکه، با استفاده از اطلاعات قبل از رخداد و پس از آن، به ارزیابی وضعیت پایداری ولتاژ می‌پردازد. در واقع شبکه عصبی به‌عنوان ابزاری کمکی، اپراتور شبکه را از خطرات احتمالی پیشروی ناشی از ناپایداری ولتاژ پس از پیشامد رخداد در شبکه به‌سرعت آگاه می‌سازد. داده‌های لازم برای آموزش شبکه عصبی در حالت غیربرخط از نتایج پیشامد رخدادهای شبیه‌سازی شده فراهم شده است. برای تولید سناریوهای مختلف، با در نظر گرفتن رشد بار در مناطق مستعد به ناپایداری ولتاژ، پیشامد رخدادهای (N-1) و (N-1-1) شبیه‌سازی و ارزیابی شده‌اند. برای ارزیابی عملکرد شبکه عصبی پیشنهادی، از شبکه توسعه‌یافته نوردیک استفاده شده است. در فرآیند آموزش شبکه عصبی، با استفاده از شیفت زمانی مناسب رخداد تمام پیشامدها به ثانیه دهم انتقال یافته تا شبکه عصبی، تنها تفاوت الگوهای رفتاری را آموزش ببیند. شبکه عصبی LSTM از خانواده شبکه‌های عصبی عمیق بازگشتی است که قادر است وابستگی‌های طولانی‌مدت احتمالی را دریافت و حفظ کند. به این ترتیب هر گونه تغییرات در ورودی‌ها، در فواصل زمانی مختلف دنبال می‌شود. شباهت خط سیر ویژگی‌های ورودی در ناپایداری بلند مدت ولتاژ به سری‌های زمانی، امکان استفاده از توانایی شبکه عصبی عمیق بازگشتی برای حل مسئله مطرح شده را فراهم کرده است. دقت پیش‌بینی شبکه عصبی در ثانیه هفدهم (۷ ثانیه پس از پیشامد رخداد) ۹۹/۰۵ درصد است. همچنین تأثیر کاهش ورودی‌های شبکه عصبی با خوشه‌بندی داده‌های ورودی مورد بررسی قرار گرفته است.

کلمات کلیدی: پایداری ولتاژ، شبکه انتقال و توزیع به هم پیوسته، شبکه عصبی

نوع مقاله: پژوهشی

دریافت: ۱۴۰۱/۰۹/۳۰

بازنگری: ۱۴۰۲/۰۳/۱۱

پذیرش: ۱۴۰۲/۰۴/۱۳

نام نویسنده‌ی مسئول: دکتر علیرضا حاتمی

نشانی نویسنده‌ی مسئول: ایران - همدان - چهارباغ شهید مصطفی احمدی روشن - دانشگاه بوعلی سینا - دانشکده‌ی مهندسی - گروه برق

نمادها و علائم اختصاری

نماد	توصیف
$x^t \in \mathbb{R}^M$	بردار ورودی
$h^t, h^{t-1} \in \mathbb{R}^N$	بردار خروجی متناظر با t و $t-1$
$f^t \in \mathbb{R}^N$	بردار فعال‌سازی دروازه فراموشی ^۱
$i^t \in \mathbb{R}^N$	بردار فعال‌سازی دروازه ورودی ^۲
$\tilde{c}^t \in \mathbb{R}^N$	بردار دروازه‌های منتخب ^۳
$c^t \in \mathbb{R}^N$	بردار حافظه حالت سلولی ^۴
$o^t \in \mathbb{R}^N$	بردار فعال‌سازی دروازه خروجی ^۵
\otimes	تابع ضرب
σ	تابع سیگموئید
\tanh	تابع هیپربولیک تانژانت
t	بردار زمان
W, U	ماتریس وزن بردارها برای هر دروازه
b	ماتریس بایاس بردارها برای هر دروازه
M	تعداد ورودی‌ها
N	تعداد نرون‌ها

۱- مقدمه

۱-۱- معرفی مسئله

با وجود توسعه منابع انرژی تجدیدپذیر به دلیل مسائل زیست‌محیطی، شبکه‌های انتقال برق به‌عنوان زیرساخت حیاتی برای انتقال انرژی همچنان حائز اهمیت هستند. برای توسعه شبکه انتقال هزینه‌های هنگفتی موردنیاز است؛ بنابراین استفاده حداکثری از ظرفیت شبکه انتقال همواره مدنظر محققان و بهره‌برداران شبکه است [۱].

یکی از مسائل مهم در بهره‌برداری از شبکه‌های انتقال، حفظ پایداری بلندمدت ولتاژ^۶ است. پس از رخداد یک اختلال در سیستم قدرت، ناپایداری بلندمدت ولتاژ در بازه زمانی چند ثانیه تا چند دقیقه ظاهر شود [۲]. در صورت رخداد ناپایداری بلندمدت ولتاژ، بهره‌برداری از شبکه انتقال با مخاطرات قابل توجهی مواجه می‌شود و می‌تواند زمینه‌ای برای خاموشی‌های گسترده در شبکه را فراهم سازد [۳].

برای اطمینان از بهره‌برداری پایدار، اغلب از روش ارزیابی دینامیکی^۷ استفاده می‌شود. در ارزیابی دینامیکی سیستم پاسخ در حوزه زمان به مجموعه‌ای از پیشامدهای احتمالی^۸ مورد بررسی قرار می‌گیرد. ارزیابی دینامیکی مسئله پیچیده و زمان‌بر است و اجرای آن به‌صورت زمان واقعی غیرممکن است. ارزیابی پایداری ولتاژ را می‌توان شاخه‌ای از ارزیابی دینامیکی سیستم قدرت دانست که در آن به اثرات رخدادهای مرتبط با ناپایداری ولتاژ می‌پردازد.

در بررسی بلندمدت ولتاژ به‌صورت مرسوم بارهای شبکه توزیع به‌صورت مجتمع در سطح انتقال مدل‌سازی می‌شود؛ درحالی‌که در دنیای واقعی بارها به‌صورت پراکنده و از طریق شبکه توزیع به شبکه انتقال متصل هستند. مدل کردن بار شبکه توزیع به‌صورت مجتمع برای بررسی پایداری ولتاژ شبکه انتقال و نیز مدل‌سازی شبکه انتقال

به‌صورت باس ولتاژ ثابت برای بررسی پایداری ولتاژ شبکه توزیع، باعث به‌وجودآمدن خطاهایی در محاسبات پایداری می‌شود [۴].

علی‌رغم تحقیقات گسترده، ارزیابی پایداری ولتاژ استاتیک^۹ در شبکه‌های انتقال و توزیع به‌طور جداگانه بررسی شده‌اند و از تأثیر آنها بر یکدیگر صرف‌نظر شده است. در نظرنگرفتن اثرات شبکه انتقال و توزیع بر یکدیگر در هنگام ارزیابی پایداری ولتاژ شبکه انتقال یا توزیع، می‌تواند سبب شود حاشیه بار به‌صورت اغراق‌آمیزی بیشتر یا کمتر از مقدار واقعی تخمین زده شود [۵].

تحقیقات متعددی در زمینه بهره‌برداری و مدل‌سازی شبکه‌های انتقال و توزیع به‌هم‌پیوسته^{۱۰} ارائه شده است؛ علاوه بر این در گزارش‌های اخیر NERC^{۱۱} [۵] و IISGAN^{۱۲} [۶] نیز بر اهمیت تأثیر تولیدات پراکنده بر کنترل فرکانس و ولتاژ در شبکه‌های انتقال و توزیع به‌هم‌پیوسته تأکید شده است.

۱-۲- مروری بر تحقیقات صورت گرفته

مطالعات صورت‌گرفته در مبحث پایداری بلندمدت ولتاژ را می‌توان به دودسته تقسیم کرد. در دسته اول، ارزیابی پایداری بلندمدت ولتاژ در شبکه‌های انتقال یا توزیع به‌صورت جداگانه انجام شده است [۱۴-۷]؛ در دسته دوم مطالعات پایداری بلندمدت ولتاژ برای شبکه انتقال و توزیع به‌هم‌پیوسته انجام شده است [۲۵-۲۰]. در دسته اول، برای ارزیابی پایداری ولتاژ و تعیین حاشیه پایداری روش‌های گوناگونی ارائه شده است. از جمله آنها می‌توان به محاسبه مدار معادل تونن از طریق داده‌های واحد اندازه‌گیری فازور^{۱۳} [۷]، محاسبه مدار معادل تونن از طریق قضیه تلگان [۸]، محاسبه برخط شاخص‌های حساسیت فروپاشی ولتاژ در ساختار توزیع شده [۹] و مجتمع [۱۰] و پایش برخط پایداری ولتاژ با استفاده از رابطه همبستگی بین ذخایر توان راکتیو ژنراتورها [۱۱] اشاره کرد.

در [۱۲] روشی برای پایش برخط ناپایداری ولتاژ در شبکه انتقال، از طریق محاسبه اندیسی که می‌تواند فاصله نقطه کار شبکه از نقطه فروپاشی ولتاژ را تخمین بزند، ارائه شده است. در [۱۳] روشی برای محاسبه نسبت بار شبکه‌های توزیع در حضور تولیدات پراکنده ارائه شده است و از طریق آن می‌توان پایداری شبکه توزیع را ارزیابی کند. در [۱۴] از روش درخت تصمیم برای ارزیابی برخط ناپایداری ولتاژ در شبکه انتقال در حضور تولیدات پراکنده بهره‌برده است. گروه دیگری از تحقیقات صورت گرفته به کاربرد یادگیری ماشین در ارزیابی بلندمدت ولتاژ شبکه‌های انتقال پرداخته‌اند [۱۹-۱۵].

روش‌های یادگیری عمیق معمولاً به مجموعه داده‌های بزرگی نیاز دارند که شامل داده‌های مرتبط با شبکه در هر دو حالت پایدار و ناپایدار باشد. در عمل، داده‌های وضعیت ناپایدار بسیار نادر است، زیرا نقطه کار سیستم قدرت باید دور از فروپاشی ولتاژ قرار گیرد. در مرجع [۱۵] یک روش مبتنی بر شبکه عصبی خود رمزنگار^{۱۴} برای ارزیابی پایداری ولتاژ سیستم قدرت ارائه شده است. در مرجع [۱۶] ارزیابی

زمان ممکن پس از پیشامد وضعیت ولتاژ شینه ها را از نظر پایداری یا ناپایداری پیش بینی می‌کند؛ به علاوه در مقاله حاضر وضعیت هشدار - که در آن ولتاژ برخی شینه‌ها در مرز پایداری و ناپایداری قرار می‌گیرند- نیز تعیین تکلیف شده است.

آموزش شبکه عصبی به صورت غیربرخط با داده‌های به دست آمده از شبیه‌سازی در حوزه زمان، توسط نرم‌افزار دیگسایلنت انجام می‌شود.

در شبیه‌سازی صورت گرفته روی شبکه تست نوردیک با در نظر گرفتن رشد بار در مناطق مستعد ناپایداری، پیشامد رخداد‌های (N-1) و (N-1-1) از لحاظ پایداری بلند مدت و ولتاژ ارزیابی شده‌اند. ولتاژ شینه‌ها، واریانس افزایشی ولتاژها، تپ ترانسفورماتورها و توان راکتیو تولیدی ژنراتورها به عنوان ورودی در نظر گرفته شده‌اند. همانطوری که در بخش پیشامد سنجی توضیح داده خواهد شد، خروجی شبکه عصبی تنها شامل وضعیت ناپایدار و پایدار خواهد بود که به ترتیب با اعداد ۰ و ۱ به عنوان هدف به شبکه عصبی داده می‌شود.

با استفاده از شیفت زمانی مناسب، رخداد تمام پیشامدها به ثانیه دهم انتقال یافته تا شبکه عصبی فقط الگوهای رفتاری حاصل از پیشامد رخداد‌های مختلف را آموزش ببیند. برای آموزش شبکه عصبی، از اطلاعات ۱۰ ثانیه قبل از پیشامد رخداد و چند ثانیه پس از آن استفاده شده است. از آنجا که تشخیص سریع ناپایداری و ولتاژ در شبکه حائز اهمیت است، مطالعات متعددی برای تعیین مدت زمان اطلاعات مورد نیاز پس از پیشامد رخداد صورت گرفته است. در واقع این مطالعات برای آموزش شبکه‌های عصبی از ۱ ثانیه تا ۵۰ ثانیه (در گام‌های ۱ یا ۲ ثانیه) انجام شده است. نتایج بیانگر دقت عملکرد بالای ۹۹ درصد تنها ۵ ثانیه پس از پیشامد رخداد است، همچنین حداکثر دقت عملکرد، مربوط به شبکه عصبی آموزش داده شده با بازه اطلاعاتی ۲۳ ثانیه پس از پیشامد رخداد است. در ادامه نشان داده می‌شود که با استفاده از تکنیک خوشه‌بندی می‌توان ابعاد داده ورودی به شبکه عصبی را بدون تغییر در عملکرد آن کاهش داد.

به طور خلاصه نوآوری‌های مقاله مذکور عبارت‌اند از:

- ارائه روشی مبتنی بر شبکه عصبی حافظه طولانی کوتاه مدت (LSTM) برای ارزیابی سریع ناپایداری بلند مدت و ولتاژ در شبکه‌های انتقال و توزیع به هم پیوسته.
- آموزش شبکه عصبی پیشنهادی به صورت غیربرخط با استفاده از داده‌های حاصل از شبیه‌سازی در حوزه زمان، پیشامد رخداد‌های (N-1) و نیز (N-1-1) با لحاظ رشد بار.
- برای همسانسازی داده‌های مربوط به پیشامد رخداد (N-1) و نیز (N-1-1) که به صورت خارج بودن تجهیز مورد نظر از قبل مدل شده است، از شیفت زمانی استفاده شده است. به این ترتیب فقط اطلاعات چند ثانیه قبل و چند ثانیه بعد از آخرین پیشامد رخداد، برای آموزش شبکه عصبی استفاده شده است.

پایداری بلند مدت و ولتاژ از طریق محاسبه حاشیه بارگذاری، با استفاده از تکنیک‌های مختلف یادگیری ماشین را ارائه می‌دهد. مرجع [۱۷] روشی برای پیش‌بینی احتمالی حاشیه پایداری و ولتاژ^{۱۵} با استفاده از ماشین یادگیری افراطی^{۱۶} ارائه می‌کند. در مرجع [۱۸] مروری جامع بر جدیدترین مطالعات انجام شده در بکارگیری یادگیری ماشین در زمینه امنیت و پایداری سیستم قدرت به ویژه در تشخیص حملات سایبری، مطالعات کیفیت توان^{۱۷} و ارزیابی امنیت دینامیکی ارائه شده است. در مرجع [۱۹] ارزیابی پایداری بلند مدت و ولتاژ در شبکه‌های انتقال توسط شبکه عصبی حافظه طولانی کوتاه مدت پیشنهاد شده است.

برای آموزش شبکه عصبی فاصله‌ی زمانی بین دو پیشامد متوالی به صورت تصادفی در نظر گرفته شده است که سبب می‌شود شبکه عصبی برای فرایند یادگیری به تعداد بسیار زیادی داده‌های ورودی نیازمند باشد؛ در نتیجه فرایند آموزش شبکه عصبی با کندی و در برخی موارد با اختلال مواجه شود و برای ارزیابی پایداری و ولتاژ زمان طولانی نیاز است (نتایج با دقت بالا با تأخیر زمانی حاصل می‌شود).

در تحقیقات صورت گرفته در دسته دوم می‌توان به مواردی اشاره کرد که در ادامه بیان می‌شوند: در [۲۰] نویسنده به مشکلات ناشی از عدم در نظر گرفتن شبکه‌های انتقال و توزیع به هم پیوسته در مطالعات ناپایداری بلند مدت و ولتاژ پرداخته است. در [۲۱] روش جدیدی مبتنی بر محاسبات وابسته و تقریبی برای اجرای پخش بار در شبکه‌های انتقال و توزیع به هم پیوسته پیشنهاد شده است. در [۲۲] محاسبات سری و موازی برای شبیه‌سازی دینامیکی شبکه‌های انتقال و توزیع به هم پیوسته پیشنهاد شده است.

در [۲۳] یک روش وقتی برای کنترل ولتاژ اضطراری بر مبنای همزمان سازی کنترل واحدهای تولید پراکنده و تپ ترانسفورماتورها ارائه شده است. در [۲۴] روشی برای محاسبه شاخص مربوط به ناپایداری بلند مدت و ولتاژ در شبکه‌های انتقال و توزیع به هم پیوسته با استفاده از مدار معادل تونن ارائه شده است؛ علاوه بر این اندیسی برای تشخیص حد تعیین کننده پایداری و ولتاژ مربوط به شبکه انتقال یا توزیع پیشنهاد شده است. بدون در نظر گرفتن اثر متقابل شبکه‌های انتقال و توزیع، مقدار حاشیه بار در مطالعات مربوط به شبکه توزیع به صورت اغراق آمیزی بیش از مقدار واقعی و مطالعات در شبکه انتقال مقدار حاشیه بار کمتر از مقدار واقعی تخمین زده می‌شود [۲۵].

۱-۳- نوآوری مقاله

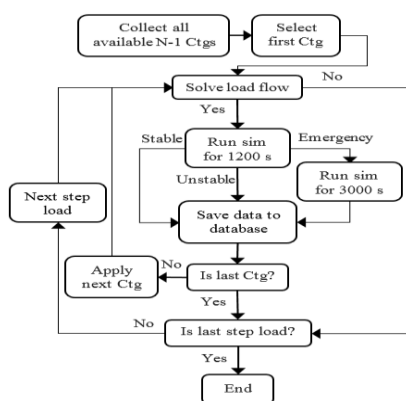
در مقاله حاضر روش مبتنی بر شبکه عصبی حافظه طولانی کوتاه مدت^{۱۸} برای ارزیابی برخط پایداری بلند مدت و ولتاژ در شبکه‌های انتقال و توزیع به هم پیوسته پیشنهاد شده است. روش پیشنهادی به عنوان یک ابزار کمکی در مراکز دیسپاچنگ به صورت برخط مورد استفاده کاربران قرار می‌گیرد. شبکه عصبی با دریافت اطلاعات برخط ارسالی توسط واحدهای اندازه‌گیری فازور، وضعیت حاضر را ارزیابی کرده و به پیش‌بینی پایداری و ولتاژ در لحظات پیشرو در حداقل

برای تنظیم ولتاژ در شبکه شامل تغییر تپ ترانسفورماتورها و تنظیمات ولتاژ ژنراتورها صورت می‌گیرد؛ سپس رشد بار در پله‌های ۱۰ مگاواتی در بخش مرکزی صورت می‌گیرد و پیشامدسنجی (N-1) ارزیابی می‌شود. به این ترتیب ۷۰ پله رشد بار ۱۰ مگاواتی به بخش مرکزی اعمال می‌شود و در نهایت ۴۲۷۰ حالت مختلف در پله‌های افزایش بار و خروج المان‌ها در پیشامدسنجی (N-1) مطالعه و ارزیابی شده است.

۳-۲-۳- پیشامدسنجی (N-1)

در شبکه‌های انتقال، برخی از تجهیزات شبکه بنا به علل مختلف از قبیل تعمیرات یا حادثه ممکن است خارج از مدار باشند. در پیشامدسنجی (N-1) فرض بر این است که یکی از تجهیزات شبکه از مدار خارج شده است و در صورت پایداری شبکه، ارزیابی پیشامدسنجی (N-1) صورت می‌گیرد.

شبیه‌سازی پیشامدسنجی (N-1) همانند پیشامدسنجی (N-1) است. در پیشامدسنجی (N-1)، ۹ پله اول رشد بار به صورت ۱۰ مگاواتی و در ادامه ۹ پله دیگر با افزایش ۵۰ مگاواتی همراه است. در پیشامد (N-1) در بار پایه شبکه شاهد چندین مورد ناپایداری هستیم، بنابراین برای بارهای کمتر از بار پایه، پله‌های کاهش بار با نرخ ۲۰ مگاوات طبق روال قبل، به مجموعه آموزشی اضافه شده است. در شبیه‌سازی صورت گرفته در برخی مقالات، ولتاژها باس‌های انتقال به سه گروه مختلف شامل شرایط پایدار، ($|V| > 1.00 pu$)، شرایط هشدار، ($0.9 \leq |V| \leq 1.00 pu$) و شرایط اضطراری ($|V| < 0.9 pu$) تقسیم‌بندی شده‌اند. وجود شرایط هشدار باعث سردرگمی اپراتور شبکه می‌شود. از این‌رو شبیه‌سازی برای حالت‌هایی که در شرایط هشدار قرار گرفته‌اند به مدت ۳۰۰۰ ثانیه ادامه می‌یابد تا پایداری یا ناپایداری حالت موردنظر معلوم شود. به این ترتیب شرایط هشدار نیز به شرایط نرمال و اضطراری تقسیم شده و خروجی نهایی شبیه‌سازی فقط شامل موارد پایدار یا ناپایدار است. این پروسه برای پیشامد (N-1) و (N-1-1) نیز تکرار شده است. شکل (۴) و (۵) به ترتیب فلوچارت نحوه ایجاد داده‌های آموزشی پیشامدسنجی (N-1) و (N-1-1) را نشان می‌دهد.



شکل (۴): فلوچارت برای تولید داده‌های پیشامدسنجی (N-1)

$$i' = \sigma(W_i x' + U_i h^{t-1} + b_i) \quad (1)$$

$$f' = \sigma(W_f x' + U_f h^{t-1} + b_f) \quad (2)$$

$$c' = f' \otimes c^{t-1} + i' \otimes \tanh(W_c x' + U_c h^{t-1} + b_c) \quad (3)$$

$$\tilde{c}' = \tanh(W_c x' + U_c h^{t-1} + b_c) \quad (4)$$

$$c' = f' \otimes c^{t-1} + i' \otimes \tilde{c}' \quad (5)$$

$$o' = \sigma(W_o x' + U_o h^{t-1} + b_o) \quad (6)$$

$$h' = o' \otimes \tanh(c') \quad (7)$$

جزئیات بیشتر در روابط داخلی شبکه عصبی را می‌توان در [۳۲] یافت.

۳-۲-۲- تولید داده‌های آموزشی

یکی از عوامل مهم در عملکرد صحیح شبکه عصبی، تولید داده‌های آموزشی است. داده‌های آموزشی می‌بایست تمام حالت‌های محتمل را شامل شود تا شبکه عصبی در مواجهه با شرایط مشابه عملکرد مورد قبولی داشته باشد. در اینجا برای ایجاد حالت‌های مختلف در کنار رشد بار از پیشامد رخدادهای احتمالی استفاده شده است.

۳-۲-۱- شرایط اولیه و رشد بار

آنالیز پیشامد باتوجه به بار پایه و شرایط اولیه ارائه شده در [۲۷] آغاز شده است. شبیه‌سازی هر مرحله پس از تأیید همگرایی پخش بار آغاز می‌شود. پیشامد احتمالی شامل خروج ژنراتور، ترانسفورماتور یا خط انتقال است. پیشامد خطوط، به صورت اتصال کوتاه سه‌فاز به زمین و خروج خط پس از ۰/۱ ثانیه در نظر گرفته شده است. پس از رخداد حادثه، تجهیز موردنظر تا پایان شبیه‌سازی خارج از مدار باقی می‌ماند. برای تولید سناریوهای مختلف، رشد بار شینه‌های شبکه به صورت پله‌ای برای بخش مرکزی که مستعد ناپایداری است، در نظر گرفته شده است. درصد افزایش بار شینه‌ها در بخش مرکزی شبکه یکسان بوده و فرض بر ثابت بودن ضریب توان در شبکه است. رشد بار انجام شده بین تمام ژنراتورهایی باتوجه به ضریب مشارکت آنها تقسیم می‌شود و مقدار باقی‌مانده توسط ژنراتور مینا جبران می‌شود. رشد بار می‌تواند به صورت پله‌ای به تمام شبکه اعمال شود. از آنجایی که بخش مرکزی مستعد ناپایداری است، برای افزایش تعداد سناریوها، بررسی دقیق‌تر تغییرات در ورودی‌ها و نقش خطوط تبادلی بین نواحی، رشد بار فقط به منطقه مرکزی اعمال شده است. اگر رشد بار به کل شبکه اعمال می‌شود، تأثیری بر عملکرد شبکه عصبی نداشت.

۳-۲-۳- پیشامدسنجی (N-1)

در شبکه مورد مطالعه، ۶۱ مورد از المان‌های شبکه نوردیک شامل خطوط، ژنراتورها و ترانس‌های انتقال برای پیشامدسنجی (N-1) انتخاب شده‌اند. پیشامدسنجی (N-1) در بار پایه شبکه با شرایط اولیه ذکر شده و پس از همگرایی پخش بار در ثانیه ۶۰ ام به شبکه اعمال می‌شود. پس از پیشامد رخداد، در بازه زمانی ۱۲۰۰ ثانیه اقدامات لازم

برای تخمین ناپایداری در کمترین زمان و دیتای ورودی، پنجره دیتای ورودی به شبکه عصبی را به طول ۱ ثانیه بعد از پیشامد دوم در نظر می‌گیریم. لازم به ذکر است اطلاعات ۱۰ ثانیه قبل از پیشامد دوم نیز در اختیار شبکه عصبی قرار می‌گیرد. صحت عملکرد شبکه عصب با ۱۰ ثانیه قبل و ۱۰ ثانیه بعد از پیشامد دوم ارزیابی می‌شود. در مطالعه بعدی، طول بازه زمانی اطلاعات بعد از پیشامد به دو ثانیه افزایش می‌یابد و فرآیند ارزیابی تکرار می‌شود. این پروسه تا ۴۰ ثانیه بعد از پیشامد دوم تکرار شده است.

در نمودار شکل (۷) فلش سبز رنگ طول دیتای فید شده به شبکه عصبی جهت تخمین ناپایداری را نشان می‌دهد. این طول دیتا شامل قسمت ثابت (فلش نارنجی) ۱۰ ثانیه قبل از پیشامد رخداد و قسمت متغییر (فلش آبی) از ۱ تا ۴۰ ثانیه پس از پیشامد رخداد است.

۳-۳- ساختار شبکه عصبی پیشنهادی

ساختار شبکه LSTM پیشنهادی با دولایه نرون برای طبقه‌بندی داده‌های ورودی در شکل (۸) نشان داده شده است. ورودی شبکه عصبی شامل ولتاژهای بخش انتقال (۱۶ باس بار) و توزیع (۱۱ باس بار)، واریانس افزایشی^{۱۹} [۳۴] ولتاژ همه باسها (۲۷ مورد)، تپ ترانسفورماتورهای موجود (۱۳ مورد شامل ترانسهای بار و انتقال) و اطلاعات مربوط به توان راکتیو و ولتاژ خروجی ژنراتورها (۲۸ مورد) می‌باشد. به این ترتیب ۹۵ ویژگی به‌عنوان ورودی شبکه عصبی انتخاب شده است. در این مقاله از اطلاعات مربوط به نوع و محل خطا و همچنین توان عبوری از خطوط و ترانسفورماتورها برای آموزش شبکه عصبی استفاده نشده است.



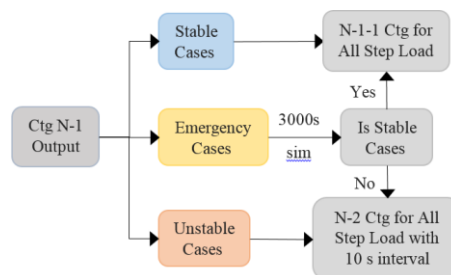
شکل (۸): ساختار شبکه LSTM پیشنهادی

جدول (۱) جزئیات داده‌های مورد استفاده در فرایند آموزش و ساختار شبکه عصبی پیشنهادی را نشان می‌دهد.

جدول (۱): جزئیات مورد استفاده در فرایند آموزش

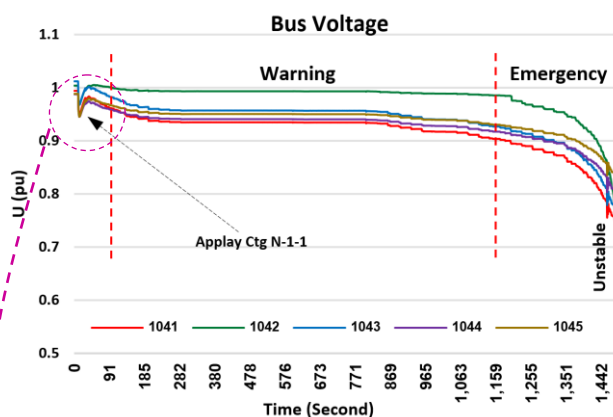
	PARAMETER	VALUES AND SIZE
DATA	Simulation interval (Second)	1200 - 3000
	Feature dimension	95, 80
	Target classes	2
	Training cases (N-1+N-1-1)	4,270 + 29,000
	Validation cases (N-1/N-1-1)	0
	Test cases (N-1/N-1-1)	741 / 5,834 (20%)
ARCHITECTURE	LSTM layers	2
	LSTM sequence length (Second)	Variable 1 to 50
	FC activation function	Softmax
	Number of hidden units 1	Variable 80 to 300
	Number of hidden units 2	Variable 30 to 90
	LSTM Activation function	Tanh
	Gate Activation Function	sigmoid
TRAINING	Max Epochs	Variable from 12 to 20
	Learning rate (α)	0.001
	Optimizer	Adam
	Gradient threshold method	L ₂ norm

در نهایت برای ۲۱ پله تغییرات بار در بخش مرکزی شبکه نوردیک ۲۹۰۰۰ مورد مطالعاتی از پیشامدسنجی (N-1-1) حاصل شده که با احتساب پیشامدسنجی (N-1) در مجموع حدود ۳۳۰۰۰ مورد مطالعاتی از شبکه استخراج گردید.




شکل (۵): فلوچارت نحوه ایجاد داده‌های پیشامدسنجی (N-1-1)

در شکل (۶) مقدار ولتاژ باس بارهای منتخب در نمونه ای از مورد مطالعاتی ناپایدار (خروج خط ۴۰۳۲-۴۰۴۴ و نیز خروج واحد G8) نشان داده شده است. محور عمودی ولتاژ باس بارها بر حسب پریونیت و محور افقی، زمان بر حسب ثانیه است. می‌توان حالت های هشدار و اضطراری و ناپایدار را به تفکیک مشاهده نمود. زمان اعمال پیشامد دوم مشخص می‌باشد. شکل شماره (۷) بزرگ نمایی قسمت مشخص شده با دایره بنفش رنگ در شکل شماره (۶) است.



شکل (۶): ولتاژ چند باسبار در یک مورد مطالعاتی ناپایدار

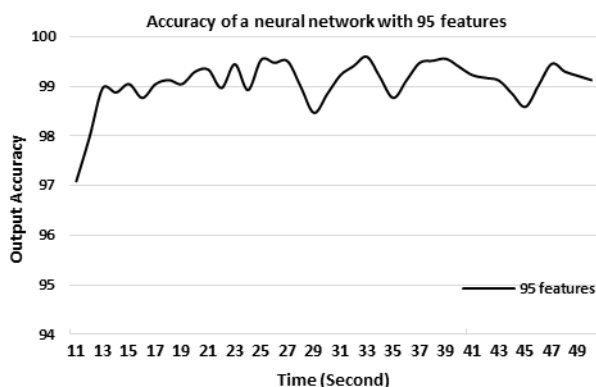


شکل (۷): بزرگنمایی شکل (۶)

۴- بحث و نتایج شبیه‌سازی

۴-۱- بررسی عملکرد و دقت شبکه عصبی

شکل (۹)، دقت شبکه‌های عصبی آموزش‌دیده با ۹۵ ویژگی (ورودی) را نشان می‌دهد. محور افقی زمان بر حسب ثانیه و محور عمودی دقت شبکه عصبی در تشخیص درست ناپایداری بلند مدت ولتاژ را بر حسب درصد نشان می‌دهد. فرض می‌شود که پیشامد در ثانیه دهم رخ می‌دهد. اطلاعات ۱۰ ثانیه قبل از رخداد و نیز چند ثانیه پس از آن برای آموزش شبکه‌های عصبی استفاده شده است.



شکل (۹): صحت خروجی شبکه عصبی آموزش‌دیده با ۹۵ ویژگی

با افزایش زمان پس از رخداد (افزایش اطلاعات ورودی به شبکه عصبی)، دقت تشخیص ناپایداری بلند مدت ولتاژ توسط شبکه عصبی افزایش می‌یابد؛ اگر شبکه عصبی با داده‌های ۱۰ ثانیه قبل از پیشامد رخداد و ۷ ثانیه پس از پیشامد رخداد آموزش داده شود، دقت عملکرد آن در تشخیص ناپایداری به ۹۹/۰۵ درصد می‌رسد.

به‌عنوان مثال، هنگام آموزش یک شبکه عصبی با داده‌های بازه زمانی ۱۷ ثانیه (۷ ثانیه پس از رخداد و ۱۰ ثانیه قبل از آن)، برآورد ۶۳ مورد از ۶۵۷۵ مطالعه موردی (مجموعه تست)، نادرست است (صحت عملکرد ۹۹,۰۵٪). در ۴۵ مورد از ۶۳ مورد ذکر شده، سیستم ناپایدار بود و شبکه عصبی قادر به تشخیص آن نبود و در ۱۸ مورد، شبکه عصبی به اشتباه شبکه را ناپایدار شناسایی کرده است.

اگرچه شناسایی یک مورد پایدار به‌عنوان مورد ناپایدار، باعث انجام اقدامات اصلاحی نادرست می‌شود، اما سیستم در معرض فروپاشی قرار نمی‌گیرد، اما ۴۵ مورد که شبکه در حال فروپاشی است و شبکه عصبی قادر به شناسایی آن نمی‌باشد (۰/۶۸ درصد از کل داده‌های آزمایشی) نشان‌دهنده خطای واقعی ارزیابی پایداری بلند مدت ولتاژ است (صحت عملکرد ۹۹,۳۰٪). خطای پایین نشان‌دهنده توانایی بالای شبکه عصبی بازگشتی دولایه پیشنهادی برای تشخیص وضعیت پایداری شبکه تنها ۷ ثانیه پس از رخداد دوم است. با بهینه‌سازی تعداد نرون‌های موجود در لایه پنهان شبکه LSTM و همچنین تعداد تکرارها، می‌توان دقت نتایج را افزایش داد. اطلاعات شبکه‌های عصبی به همراه دقت آنها در جدول (۲) گزارش شده است. خطای ۰/۶۸ درصدی در عدم تشخیص ناپایداری از بین ۶۵۷۵ مورد از مجموعه

برای نرمال‌سازی دیتابیس از روش MaxMin استفاده شده و برای حداقل‌سازی Padding، دیتابیس موجود بر اساس طول زمان شبیه‌سازی مرتب شده‌اند. با انتخاب درست مقدار MiniBach مقدار Padding به حداقل ممکن کاهش می‌یابد.

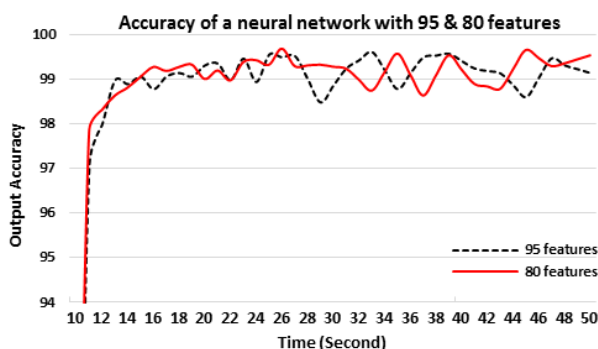
۴-۳- آموزش شبکه عصبی

شبیه‌سازی در حوزه زمان با استفاده از نرم‌افزار دیگ سایلنت ورژن ۲۰۱۷ انجام شده است، مدت‌زمان شبیه‌سازی برای هر رخداد ۱۲۰۰ ثانیه و برای رخداد‌های اضطراری ۳۰۰۰ ثانیه در نظر گرفته شده است. (در هر ثانیه سه نمونه از نتایج شبیه‌سازی ذخیره شده است) تعداد رخداد‌های بررسی شده ۳۳۰۰۰ مورد است که ۱۰۰۰۰ عدد از آن مربوط به رخداد‌های اضطراری است؛ بنابراین با در نظر گرفتن تعداد ورودی‌های شبکه عصبی که برابر ۹۵ است، مجموعاً داده‌های آموزشی به ابعاد $(23000 \times 95 \times 3600) + (10000 \times 95 \times 9000)$ مورد استفاده قرار گرفته است. ۲۰ درصد از این تعداد داده آموزشی جهت تست شبکه عصبی و مابقی برای آموزش استفاده شده است.

لازم به ذکر است پله‌های زمانی در هر شبیه‌سازی ۷۰ میلی‌ثانیه در نظر گرفته شده است که بر اساس سعی و خطا به‌دست آمده است. گام‌های زمانی بیشتر از ۷۰ میلی‌ثانیه سبب خطای محاسباتی (به‌واسطه محاسبات مربوط به AVR ژنراتورها و ترانسفورماتورها) و در پله‌های کمتر از ۷۰ میلی‌ثانیه سبب افزایش حجم محاسبات می‌شود. پیشامدسنجی (N-1)، پس از همگرایی پخش بار و در ثانیه ۶۰ ام به شبکه اعمال می‌شود. اطلاعات ورودی ۱۰ ثانیه قبل از پیشامد رخداد (N-1) و چند ثانیه پس از آن برای آموزش شبکه عصبی استفاده می‌شود. پیشامدسنجی (N-1-1) پس از پایداری شبکه در وضعیت (N-1) اعمال می‌شود. همچنین از اطلاعات ورودی ۱۰ ثانیه قبل از پیشامد رخداد (N-1-1) و چند ثانیه پس از آن برای آموزش شبکه عصبی استفاده می‌شود.

برای ارزیابی پایداری ولتاژ در حداقل زمان ممکن، مطالعات عددی مختلف صورت گرفته است. این کار با استفاده از آموزش شبکه عصبی با اطلاعات بازه‌های زمانی مختلفی از ۱ تا ۴۰ ثانیه (با گام‌های زمانی ۱ یا ۲ ثانیه) پس از پیشامد رخداد انجام شده است. در واقع ۳۰ شبکه عصبی مختلف با ۳۰ نمونه داده آموزش داده شده‌اند و نتایج عملکرد آنها مورد ارزیابی قرار گرفته است. شبکه‌های عصبی که با فواصل زمانی مختلف آموزش داده می‌شوند، مستقل عمل می‌کنند و حتی برای افزایش دقت خروجی، تعداد نرون‌ها در لایه‌های LSTM و تعداد تکرارها متفاوتی دارند که به‌صورت سعی و خطا به‌دست آمده و جزئیات آن در جدول (۲) گزارش شده است. به این ترتیب با مقایسه صحت عملکرد شبکه عصبی می‌توان بهترین بازه برای آموزش را با توجه به صحت عملکرد خروجی انتخاب کرد.

یادگیری در زمان کمتری انجام می‌شود. شکل (۱۱) تفاوت عملکرد شبکه عصبی با ۸۰ و ۹۵ ویژگی ورودی را نشان می‌دهد.



شکل (۱۱): خروجی شبکه عصبی با ۸۰ و ۹۵ ویژگی به‌عنوان ورودی

محور افقی مربوط به بازه زمانی و محور عمودی صحت عملکرد به درصد است. همان‌طوری که دیده می‌شود، صحت عملکرد شبکه عصبی قبل و بعد از حذف ورودی‌های که با یکدیگر همبستگی r^2 (Correlation) دارند، تغییر محسوسی نداشته است. صحت شبکه عصبی با ۸۰ ویژگی ورودی، مابین ثانیه‌های ۱۵ تا ۱۹ و ۲۶ تا ۲۹ کمی بهبود یافته است.

عملکرد شبکه عصبی در ۲۰ ثانیه اول، کمی بهبود یافته است. با مقایسه نتایج شبکه‌های عصبی با ۸۰ و ۹۵ ورودی، ملاحظه می‌شود که کاهش ورودی‌ها تأثیر قابل‌توجهی بر کاهش صحت عملکرد شبکه عصبی، در تشخیص ناپایداری نداشته است. جدول (۲) جزئیات مربوط به خروجی شبکه‌های عصبی با ۸۰ و ۹۵ ویژگی ورودی را نشان می‌دهد که در آن ستون اول میزان تأخیر بر حسب ثانیه پس از اعمال پیشامد رخداد در ثانیه دهم است. ستون دوم مربوط به صحت شبکه عصبی مربوطه در تشخیص ناپایداری، ستون سوم و چهارم، تعداد نرون‌های موجود در لایه‌های اول و دوم و در نهایت آخرین ستون مربوط به تعداد تکرارها در فرایند آموزش شبکه عصبی است.


جدول (۲): صحت و جزئیات مربوط به شبکه عصبی آموزش‌دیده با ۸۰ و ۹۵ ویژگی به‌عنوان ورودی

Time (s)	95 FEATERS				80 FEATERS			
	Accuracy (%)	First Layer Neurons	Second Layer Neurons	Max Epochs	Accuracy (%)	First Layer Neurons	Second Layer Neurons	Max Epochs
11	97.09	90	50	11	97.85	110	30	12
12	97.98	80	50	15	96.90	90	30	15
13	98.97	90	50	15	98.63	120	40	15
14	98.88	180	40	15	98.81	120	40	15
15	99.05	180	40	15	99.05	110	30	12
16	98.77	150	50	15	99.27	110	30	15
17	99.05	180	30	15	99.18	110	30	15
18	99.13	200	40	15	99.27	150	50	15
19	99.05	100	30	15	99.32	110	30	15
20	99.30	100	30	15	99.00	110	30	15
21	99.34	120	40	15	99.19	100	30	15
22	98.97	250	90	15	98.97	120	40	15
23	99.45	200	40	15	99.38	120	40	15
24	98.93	200	40	15	99.42	150	40	15

تست که ۲۰ درصد از کل مجموعه آموزشی است، عدد بسیار کوچکی است، ولی در صورت حادث شدن، شبکه با ناپایداری بلند مدت ولتاژ روبرو می‌شود و باعث عملکرد سیستم‌های حفاظتی ولتاژی در شبکه انتقال و توزیع شده و خاموشی غیر قابل کنترل در سراسر شبکه ایجاد می‌کند.

۲-۴- خوشه‌بندی

در بخش دیگری از مطالعات عددی انجام شده، همبستگی بین ورودی‌های شبکه عصبی مورد بررسی قرار گرفت. برای این منظور، متغیرهای مربوط به ولتاژ انتقال (۱۶ مورد) انتخاب شدند. از آنجایی‌که شباهت رفتاری ولتاژهای باس‌های انتقال در حوالی نقطه فروپاشی ولتاژ مدنظر است، موارد پایدار از خوشه‌بندی حذف شدند و موارد ناپایداری که زمان باقی‌مانده تا فروپاشی ولتاژ بیشتر از ۱۰۰ ثانیه دارند استخراج شدند و اطلاعات مربوط به ۱۰۰ ثانیه آخر آنها خوشه‌بندی شدند. از روش نمونه‌گیری مجدد برای برابر کردن تعداد نمونه‌ها و همانندسازی مدت‌زمان شبیه‌سازی استفاده شده که منجر به قرارگیری خروجی‌ها در مقیاس زمانی یکسان می‌شود و در نهایت خوشه‌بندی با روش k-means به خروجی فرایند اعمال شده است. برای جلوگیری از تکرار، تنها خروجی مربوط به خوشه‌بندی در هفت گروه در شکل (۱۰) نشان داده شده است.



برای مثال شبکه عصبی که با داده‌های ۱۰ ثانیه قبل از پیشامد رخداد و ۲۳ ثانیه پس از آن آموزش دیده است، دارای دقت ۹۹٫۶ در پیش‌بینی ناپایداری ولتاژ است؛ در ادامه مطالعات انجام شده، امکان کاهش ابعاد (تعداد) داده‌های ورودی به شبکه عصبی با خوشه‌بندی آنها صورت گرفت. نتایج بیانگر امکان کاهش ورودی‌های شبکه عصبی از ۹۵ ورودی به ۸۰ ورودی است، گرچه با کاهش تعداد ورودی‌ها، دقت شبکه عصبی اندکی کاهش پیدا می‌کند.

در صورت توسعه شبکه اعم از تغییرات یا اضافه شدن تجهیزات جدید می‌توان شبکه عصبی موجود را با داده‌های جدید اضافه شده به مجموعه آموزشی باز آموزی کرد. عملکرد شبکه عصبی وابسته به خط سیر ورودی‌های آن است و به همین خاطر در صورت توسعه شبکه و اضافه شدن تجهیزات دیگر، عملکرد آن تغییر محسوسی نمی‌کند. علاوه بر آن می‌توان شبکه عصبی موجود را با داده‌های جدید که حاصل پیشامد رخدادها اضافه شده به مجموعه آموزشی است، آموزش اضافی^{۲۴} کرد. روش بیان شده انعطاف شبکه عصبی در حل مسئله تخمین ناپایداری بلند مدت ولتاژ را تکمیل می‌کند.

مراجع

- [1] B. Petroleum, "Statistical Review of World Energy globally consistent data on world energy markets . and authoritative publications in the field of energy", BP Energy Outlook 2021, vol. 70, pp. 8–20, 2021.
- [2] P. Kundur et al., "Definition and classification of power system stability", IEEE Trans. Power Syst., vol. 19, no. 3, pp. 1387–1401, 2004, doi: 10.1109/TPWRS.2004.825981.
- [3] A. Muir, J. L.—Canada P. S. O. T. Force, undefined Canada, and undefined 2004, "Final report on the August 14, 2003 blackout in the United States and Canada: causes and recommendations", osti.gov, Accessed: Nov. 30, 2020. [Online]. Available: <https://www.osti.gov/etdeweb/biblio/20461178>.
- [4] Z. Li, Q. Guo, H. Sun, J. Wang, Y. Xu, and M. Fan, "A Distributed Transmission-Distribution-Coupled Static Voltage Stability Assessment Method Considering Distributed Generation", IEEE Trans. Power Syst., vol. 33, no. 3, pp. 2621–2632, 2018, doi: 10.1109/TPWRS.2017.2762473.
- [5] NERC (North American Electric Reliability Corp.), "Essential Reliability Services Task Force Measures Framework Report", Nerc, no. November, pp. 1–129, 2015.
- [6] A. Zegers and H. Brunner, "TSO-DSO interaction: An Overview of current interaction between transmission and distribution system operators and an assessment of their cooperation in Smart Grids", Int. Smart Grid Action Netw. Discuss. Pap. Annex, vol. 6, pp. 2–32, 2014.
- [7] S. Corsi, G. N. Taranto, and S. Member, "A Real-Time Voltage Instability Identification Algorithm Based on Local Phasor Measurements", vol. 23, no. 3, pp. 1271–1279, 2008.
- [8] I. Smon, G. Verbic, and F. Gubina, "Local voltage-stability index using Tellegen's theorem," IEEE Trans. Power Syst., vol. 21, no. 3, pp. 1267–1275, 2006.
- [9] Asadi H, Sanayepasand M, Davarpanah M. Introducing a Novel Method for Real Time

25	99.54	200	40	15	99.32	150	50	15
26	99.48	150	50	15	99.68	150	50	15
27	99.51	150	50	15	99.29	120	40	15
29	98.47	250	90	15	99.32	120	40	15
31	99.23	180	30	12	99.23	150	50	15
33	99.60	250	90	15	97.74	120	30	15
35	98.77	100	30	20	99.57	100	30	20
37	99.48	100	30	20	98.63	100	30	20
39	99.56	110	30	20	99.53	180	40	12
41	99.23	300	90	12	98.89	180	30	12
43	99.12	300	90	12	98.18	180	30	12
45	98.59	300	90	15	99.65	100	30	16
47	99.46	180	30	14	99.29	100	30	16
50	99.13	300	90	12	99.53	200	30	16

در نهایت این نکته قابل ذکر است که خطاهای موجود در مدل‌سازی و اختلاف بین عملکرد واقعی شبکه و شبیه‌سازی‌ها باید مدنظر قرار گیرند. شبکه عصبی بازگشتی به زمان وقوع خطا در داده‌های آموزشی حساس است و در صورت عدم اعمال شیفت زمانی مناسب در اطلاعات ورودی، شبکه عصبی تغییرات زمانی وقوع خطا در اطلاعات ورودی را دنبال کرده و آموزش می‌بیند. در صورتی که هدف اصلی آموزش شبکه عصبی، یادگیری الگوهای رفتاری در ویژگی‌های ورودی پس از اعمال پیشامد رخدادها مختلف در شبکه است. به زبان ساده، اهمیتی ندارد که چند مرحله کانتینجیسی در شبیه‌سازی در نظر گرفته شده است و این کانتینجیسی‌ها در چه زمان‌هایی اعمال شده است، مهم این است که با استفاده از شیفت زمانی مناسب چند ثانیه قبل و بعد از آخرین کانتینجیسی به‌عنوان ورودی شبکه عصبی در نظر گرفته شود.

۵- نتیجه‌گیری

در این مقاله روشی مبتنی بر شبکه عصبی حافظه طولانی کوتاه‌مدت (LSTM) برای پیش‌بینی ناپایداری بلند مدت ولتاژ در شبکه‌های انتقال و توزیع به‌هم‌پیوسته ارائه شده است. شبکه عصبی با استفاده از داده‌های برخاسته از اندازه‌گیری فازوری، به‌صورت دائمی وضعیت شبکه را رصد می‌کند. پس از پیشامد رخدادی در شبکه انتقال و توزیع به‌هم‌پیوسته، با داشتن اطلاعات قبل از رخداد و پس از آن، وضعیت ناپایداری ولتاژ شبکه پیش‌بینی می‌شود؛ بنابراین روش پیشنهادی به‌عنوان یک ابزار کمکی می‌تواند اپراتور شبکه را از خطرات احتمالی ناشی از ناپایداری ولتاژ آگاه سازد.

مطالعات عددی روی شبکه توسعه‌یافته انتقال نوردیک صورت گرفته است. با در نظر گرفتن رشد بار به‌صورت پله‌ای در مناطق مستعد ناپایداری (مناطق مرکزی)، حالت‌های مختلف پیشامد رخدادهای (N-1) و (N-1-1) مورد ارزیابی قرار گرفته است. از آنجاکه سرعت پیش‌بینی ناپایداری ولتاژ، در اتخاذ تصمیم درست برای اقدامات اصلاحی حائز اهمیت است؛ شبکه‌های عصبی با داده‌های با بازه زمانی متفاوتی پس از پیشامد رخداد آموزش دیده و مورد ارزیابی قرار گرفتند. نتایج بیانگر بهبود دقت شبکه عصبی در پیش‌بینی ناپایداری ولتاژ است هنگامی که از داده‌های با بازه زمانی بزرگ‌تر پس از پیشامد رخداد استفاده شود گرچه زمان ارائه پاسخ شبکه عصبی طولانی‌تر می‌شود،

- Transmission-Distribution System with Integration Time Step Impact on Convergence”, *IEEE Trans. Power Syst.*, vol. 34, no. 2, pp. 1171–1181, 2019, doi: 10.1109/TPWRS.2018.2874807.
- [23] L. D. P. Ospina and T. Van Cutsem, “Emergency Support of Transmission Voltages by Active Distribution Networks: A Non-Intrusive Scheme”, *IEEE Trans. Power Syst.*, vol. 36, no. 5, pp. 3887–3896, 2021, doi: 10.1109/TPWRS.2020.3027949.
- [24] A. R. Ramapuram Matavalam, A. Singhal, and V. Ajjarapu, “Monitoring long term voltage instability due to distribution and transmission interaction using unbalanced μ PMU and PMU measurements”, *IEEE Trans. Smart Grid*, vol. 11, no. 1, pp. 873–883, 2020, doi: 10.1109/TSG.2019.2917676.
- [25] A. Singhal and V. Ajjarapu, “Long-term voltage stability assessment of an integrated transmission distribution system”, 2017 North Am. Power Symp. NAPS 2017, 2017, doi: 10.1109/NAPS.2017.8107402.
- [26] T. Van Cutsem et al., “Test Systems for Voltage Stability Studies: IEEE Task Force on Test Systems for Voltage Stability Analysis and Security Assessment”, *IEEE Trans. Power Syst.*, no. August, pp. 1–1, 2020, doi: 10.1109/tpwrs.2020.2976834.
- [27] L. D. P. Ospina, A. F. Correa, and G. Lammert, “Implementation and validation of the Nordic test system in DIGSILENT PowerFactory”, 2017 IEEE Manchester PowerTech, Powertech 2017, 2017, doi: 10.1109/PTC.2017.7980933.
- [28] K. Strunz, C. Abbey, C. Andrieu, R. C. Campbell, and R. Fletcher, Benchmark Systems for Network Integration of Renewable and Distributed Energy Resources, no. July, 2009.
- [29] S. Barsali, Benchmark systems for network integration of renewable and distributed energy resources. 2014.
- [30] “Western Electricity Coordinating Council (WECC) Renewable Energy Modeling Task Force. (2014, Apr) WECC solar plant dynamic modeling guidelines”, [Online]. Available: [https://www.wecc.biz/Reliability/WECC%0ASolar Plant Dynamic Modeling Guidelines.pdf](https://www.wecc.biz/Reliability/WECC%0ASolar%20Plant%20Dynamic%20Modeling%20Guidelines.pdf).
- [31] and M. B. G. Lammert, L. D. Pab’on Ospina, P. Pourbeik, D. Fetzer, “Implementation and Validation of WECC Generic Photovoltaic System Models in DIGSILENT PowerFactory”, *IEEE Power Energy Soc. Gen. Meet.*, pp. 1–5.
- [32] I. G. and Y. B. and A. Courville, Deep Learning. MIT Press, 2016.
- [33] A. Graves, A. Mohamed, and G. Hinton, “Speech recognition with deep recurrent neural networks”, in 2013 IEEE international conference on acoustics, speech and signal processing, 2013, pp. 6645–6649.
- [34] M. Ghalei Monfared Zanjani, K. Mazlumi, and I. Kamwa, “Combined analysis of distribution-level PMU data with transmission-level PMU for early detection of long-term voltage instability”, *IET Gener. Transm. Distrib.*, vol. 13, no. 16, pp. 3634–3641, 2019, doi: 10.1049/iet-gtd.2019.0311.
- Estimation of Power System Voltage Instability Based on Wide Area Protection. *Journal of Iranian Association of Electrical and Electronics Engineers* 2007; 4 (2) :3-13
- [10] M. Glavic and T. Van Cutsem, “Wide-area detection of voltage instability from synchronized phasor measurements. Part I: Principle”, *IEEE Trans. Power Syst.*, vol. 24, no. 3, pp. 1408–1416, 2009, doi: 10.1109/TPWRS.2009.2023271.
- [11] L. Bao, Z. Huang, and W. Xu, “Online Voltage Stability Monitoring Using Var Reserves”, *IEEE Trans. Power Syst.*, vol. 18, no. 4, pp. 1461–1469, 2003, doi: 10.1109/TPWRS.2003.818706.
- [12] M. Kamel, A. A. Karrar, and A. H. Eltom, “Development and Application of a New Voltage Stability Index for On-Line Monitoring and Shedding”, *IEEE Trans. Power Syst.*, vol. 33, no. 2, pp. 1231–1241, 2018, doi: 10.1109/TPWRS.2017.2722984.
- [13] Rajaeyan E, Zeinali Davarani R. Optimal Allocation and Capacity Determination of Hybrid Distributed Generation Resources to Provide Load, Optimal Use of Renewable Resources, Reduce Net Present Cost, and Improve Network Voltage Stability. *Journal of Iranian Association of Electrical and Electronics Engineers* 2023; 20 (2) :19-27
- [14] T. Wang, T. Bi, H. Wang, and J. Liu, “Decision tree based online stability assessment scheme for power systems with renewable generations”, *CSEE J. Power Energy Syst.*, vol. 1, no. 2, pp. 53–61, 2015, doi: 10.17775/cseejpes.2015.00019.
- [15] H. Yang, R. C. Qiu, and H. Tong, “Reconstruction Residuals Based Long-term Voltage Stability Assessment Using Autoencoders”, *J. Mod. Power Syst. Clean Energy*, vol. 8, no. 6, pp. 1092–1103, 2020, doi: 10.35833/MPCE.2020.000526.
- [16] K. D. Dharmapala, A. Rajapakse, K. Narendra, and Y. Zhang, “Machine Learning Based Real-Time Monitoring of Long-Term Voltage Stability Using Voltage Stability Indices”, *IEEE Access*, vol. 8, pp. 222544–222555, 2020, doi: 10.1109/ACCESS.2020.3043935.
- [17] H. Y. Su and H. H. Hong, “An Intelligent Data-Driven Learning Approach to Enhance Online Probabilistic Voltage Stability Margin Prediction”, *IEEE Trans. Power Syst.*, vol. 36, no. 4, pp. 3790–3793, 2021, doi: 10.1109/TPWRS.2021.3067150.
- [18] O. A. Alimi, K. Ouahada, and A. M. Abu-Mahfouz, “A Review of Machine Learning Approaches to Power System Security and Stability”, *IEEE Access*, vol. 8, pp. 113512–113531, 2020, doi: 10.1109/ACCESS.2020.300.
- [19] H. Hagmar, L. Tong, R. Eriksson, and L. A. Tuan, “Voltage Instability Prediction Using a Deep Recurrent Neural Network”, *IEEE Trans. Power Syst.*, vol. 36, no. 1, pp. 17–27, 2021, doi: 10.1109/TPWRS.2020.3008801.
- [20] Z. Li, Q. Guo, H. Sun, and J. Wang, “Impact of Coupled Transmission-Distribution on Static Voltage Stability Assessment”, *IEEE Trans. Power Syst.*, vol. 32, no. 4, pp. 3311–3312, 2017, doi: 10.1109/TPWRS.2016.2631896.
- [21] K. Tang, S. Dong, C. Zhu, and Y. Song, “Affine Arithmetic-Based Coordinated Interval Power Flow of Integrated Transmission and Distribution Networks”, *IEEE Trans. Smart Grid*, vol. 11, no. 5, pp. 4116–4132, 2020, doi: 10.1109/TSG.2020.2991210.
- [22] R. Venkatraman, S. K. Khaitan, and V. Ajjarapu, “Dynamic Co-Simulation Methods for Combined

زیر نویس ها

¹ Forget Gate

² Input Gate

-
- ³ Vector of The Candidate gate
 - ⁴ Cell State Memory Vector
 - ⁵ Activation Vector of the Output Gate
 - ⁶ Long-term Voltage Stability
 - ⁷ Dynamic Security Assessment (DSA)
 - ⁸ Contingency
 - ⁹ Static Voltage Stability
 - ¹⁰ Integrated Transmission-Distribution Systems (T&D)
 - ¹¹ North American Electric Reliability Corporation
 - ¹² The International Smart Grid Action Network
 - ¹³ Phasor Measurement Unit (PMU)
 - ¹⁴ Autoencoder
 - ¹⁵ Voltage Stability Margin (VSM)
 - ¹⁶ Extreme Learning Machine (ELM)
 - ¹⁷ Power Quality (PQ)
 - ¹⁸ Long Short-term Memory(LSTM)
 - ¹⁹ Incremental variance
 - ²⁰ Correlation
 - ²¹ Trajectory
 - ²² Retrain Neural Network