



Computational Intelligence in Electrical Engineering
Vol. 15, No. 1, 2024
pp. 1-16
Research Paper

Short-term voltage stability prediction based on a Bidirectional Gated Recurrent Unit neural network using phasor measurement data in power systems

Amirhossein Babaali¹, Mohammad Taghi Ameli^{*2}

Dept. of Electrical Engineering, Shahid Beheshti University, Tehran, Iran
Dept. of Electrical Engineering, Shahid Beheshti University, Tehran, Iran

Abstract:

The development of the application of artificial intelligence and machine learning methods and the expansion of the use of phasor measurement units (PMU) have made it possible to analyze the power system as online using measurement data. In this article, a deep learning method based on a Bidirectional Gated Recurrent unit (Bi-GRU) with convolution layers is presented for online prediction of short-term voltage stability (STVS) using PMU data. In order to investigate the dynamic behavior of the power system in STVS, the database includes the time series of voltage magnitude and phase angle. A three-class classification problem (stable, alert and unstable) is defined with the help of a dynamic index including Lyapunov function and voltage deviation. The ability of bidirectional neural network in the simultaneous analysis of past and future data and the ability of the convolution layer in extracting the temporal characteristics of the data have led to an increase in the accuracy of the online STVS assessment. The simulations on IEEE 39 and 118 bus show that the proposed method can predict the voltage stability based on the measurement data pre and post-fault with good accuracy and timely, so that There will be more time for corrective actions in the network. According to the obtained results, the proposed algorithm is resistant to changing the topology of the power grid as well as changing the operating points.

Keywords: Short-term voltage stability; Voltage stability index; Bi-GRU; Convolution; Deep learning.



This is an open access article under the CC BY-NC-ND/4.0/ License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).



<https://doi.org/10.22108/ISEE.2023.135273.1585>

پیش‌بینی وضعیت پایداری ولتاژ کوتاه‌مدت مبتنی بر یک شبکه عصبی بازگشتی دوسویه با

استفاده از داده‌های اندازه‌گیری فازوری در سیستم‌های قدرت

امیرحسین باباعلی^۱، محمدتقی عاملی^{۲*}

۱- دانشجوی دکتری، دانشکده مهندسی برق، دانشگاه شهید بهشتی، تهران، ایران

a_babaali@sbu.ac.ir

۲- استاد، دانشکده مهندسی برق، دانشگاه شهید بهشتی، تهران، ایران

m_ameh@sbu.ac.ir

چکیده: توسعه کاربرد روش‌های یادگیری ماشین و هوش مصنوعی و گسترش به‌کارگیری واحدهای اندازه‌گیری فازور (PMU) قابلیت تحلیل برخط سیستم قدرت با استفاده از داده‌های اندازه‌گیری را فراهم کرده است. در این مقاله یک روش یادگیری عمیق مبتنی بر شبکه عصبی بازگشتی دروازه‌ای دوسویه با لایه‌های کانولوشن برای پیش‌بینی برخط پایداری ولتاژ کوتاه‌مدت (STVS) به کمک داده‌های PMU ارائه شده است. با هدف بررسی رفتار دینامیکی سیستم قدرت در STVS، پایگاه داده شامل سری زمانی دامنه ولتاژ و زاویه فاز است. با استفاده از تابع لیاپانوف و انحراف دامنه ولتاژ یک شاخص دینامیکی برای دسته‌بندی داده‌های اندازه‌گیری در سه کلاس پایدار، هشدار و ناپایدار تعریف شده است. قابلیت شبکه بازگشتی دوسویه در تحلیل هم‌زمان داده‌های گذشته و آینده و قابلیت لایه کانولوشن در استخراج ویژگی‌های زمانی داده‌ها منجر به افزایش دقت ارزیابی برخط پایداری ولتاژ کوتاه‌مدت شده است. شبیه‌سازی‌ها روی شبکه‌های چندماشین ۳۹ و ۱۱۸ شین IEEE نشان می‌دهد روش پیشنهادی می‌تواند پایداری ولتاژ کوتاه‌مدت را براساس داده‌های اندازه‌گیری قبل و بعد از خطا با دقت خوب و در زمان کوتاهی پیش‌بینی کند؛ به طوری که زمان بیشتری برای اقدامات اصلاحی در شبکه وجود داشته باشد. نتایج گواه است که الگوریتم پیشنهادی در مقابل تغییر ساختار شبکه قدرت و نیز تغییر نقاط بهره‌برداری مقاوم است؛ بنابراین، اجرای این مدل در شبکه‌های واقعی امکان‌پذیر خواهد بود.

واژه‌های کلیدی: پایداری ولتاژ کوتاه‌مدت، شاخص پایداری ولتاژ، شبکه عصبی بازگشتی دوسویه، کانولوشن، یادگیری عمیق.

۱- مقدمه

می‌کند. هنگامی که نواحی مرکز بار دچار اختلال بزرگی می‌شوند، بارهای دینامیکی چشمگیری تمایل دارند در چند ثانیه بازیابی شوند که می‌تواند منجر به ناپایداری ولتاژ کوتاه‌مدت سیستم قدرت شود [1].

مشکلات ناشی از افزایش نفوذ انرژی‌های تجدیدپذیر در شکل‌های مختلف همچون شبکه‌های توزیع فعال [2]، ریزشبکه‌ها و سیستم‌های انرژی یکپارچه [3]، سیستم‌های قدرت را به دلیل عدم قطعیت‌های تجدیدپذیر به سمت ناپایداری‌های ولتاژ بالقوه سوق می‌دهد؛ به‌ویژه با رشد فزاینده بارهای موتورهای القایی مانند سیستم‌های تهویه

ظرفیت انتقال شبکه‌های برق به دلیل اصلاح بازار برق و افزایش مصرف برق به مرز خود نزدیک می‌شود که امنیت و پایداری عملکرد سیستم‌های قدرت را به‌طور جدی تهدید

^۱ تاریخ ارسال مقاله: ۱۴۰۱/۰۷/۱۲

تاریخ پذیرش مقاله: ۱۴۰۲/۰۷/۰۳

نام نویسنده مسئول: محمدتقی عاملی

نشانی نویسنده مسئول: ایران - تهران - دانشگاه شهید بهشتی -

دانشکده مهندسی برق

روی‌کرد روش‌های یادگیری کم‌عمق نمی‌تواند وابستگی‌های زمانی نهفته در دینامیک سیستم قدرت را در نظر بگیرد. درمقابل، روش‌های یادگیری عمیق قابلیت دارند تا ویژگی‌های همبستگی حوزه زمان را بدون وابستگی به دانش حوزه تخصصی از داده‌های سری زمانی به‌طور کامل استخراج کنند. در موضوع پایداری سیستم قدرت، برخی از الگوریتم‌های یادگیری عمیق نظیر شبکه عصبی بازگشتی (RNN^{۱۳}) و شبکه عصبی کانولوشن (CNN^{۱۴}) برای ارزیابی پایداری گذرای سیستم قدرت به کار گرفته شده‌اند. برای مسئله پایداری ولتاژ کوتاه‌مدت، شبکه کانولوشن گراف (GCN^{۱۵})، حافظه طولانی کوتاه‌مدت (LSTM^{۱۶}) به کار گرفته شده است.

مرجع [17] ترکیب شبکه مولد متخاصم (GAN^{۱۸}) را برای تولید داده‌های از دست رفته و شبکه واحد بازگشتی دروازه‌ای دوسویه (BiGRU^{۱۹}) همراه با مکانیسم توجه (Attention) را برای ارزیابی STVS پیشنهاد کرده است. الگوریتم RNN [18] برای ملاحظه وابستگی مکانی و زمانی در تعیین پایداری ولتاژ استفاده شده است. مدل RNN در تحلیل داده‌های سری زمانی کارآمد است؛ اما توانایی یادگیری وابستگی‌های طولانی مدت داده‌ها را ندارد. شبکه‌های LSTM و GRU به‌عنوان مدل‌های بهبودیافته RNN می‌توانند مسئله محو شدن (Disappearance) گرادیان و وابستگی طولانی مدت را برطرف کنند [19]. همچنین، GRU در مقایسه با LSTM ساختار ساده‌تر و پارامترهای کمتری دارد که این باعث می‌شود بازده آموزشی بالاتری را بدون کاهش دقت داشته باشد [20].

ارزیابی برخط STVS با ملاحظه وابستگی زمانی داده‌های اندازه‌گیری و وابستگی مکانی شین‌های سیستم قدرت [15]، [16,17] به‌شدت به مدل سیستم وابسته است؛ به طوری‌که با تغییر توپولوژی شبکه دقت پیش‌بینی STVS به‌شدت افت خواهد کرد. روش LSTM در [16] وابستگی زمانی داده‌ها را در تعیین STVS در نظر گرفته است؛ اما تنها براساس وابستگی‌های گذشته کار می‌کند؛ اما در شبکه قدرت که یک سیستم غیرخطی است، ممکن است تمام وابستگی‌ها استخراج نشود که منجر به نتایج ضعیف LSTM می‌شود. مدل GRU به دلیل ساده‌تر بودن می‌تواند عملکرد بهتری در شبکه‌های پیچیده قدرت داشته باشد.

مطبوع [4]، ارزیابی پایداری ولتاژ کوتاه‌مدت (STVS^۱) به یک موضوع مهم در شبکه برق تبدیل شده است. STVS به توانایی سیستم قدرت در بازگرداندن ولتاژ شین‌های خود به سطح نرمال در یک بازه زمانی کوتاه بعد از وقوع خطا گفته می‌شود [1]. برای ارزیابی STVS برخی روش‌های سنتی مبتنی بر مدل شبکه اجرا شده است؛ روش‌هایی مانند تابع انرژی [5] و نمودار P-V [6]. ضعف این روش‌ها عدم دسترسی به مدل فیزیکی دقیق شبکه در حین بهره‌برداری است؛ حتی در صورت وجود این مدل به دلیل پیچیدگی‌های زیادی که دارد نمی‌تواند به‌صورت به‌هنگام در دسترس باشد؛ زیرا هزینه محاسباتی بالایی دارد. برای حل این چالش‌ها روش‌هایی مبتنی بر داده‌های اندازه‌گیری ارائه شده‌اند. روش‌های مبتنی بر داده نیاز به فرآیند یادگیری ماشین دارند که به‌صورت یادگیری کم‌عمق و عمیق انجام می‌شود.

در سال‌های اخیر، با توسعه زیرساخت‌های پیشرفته سیستم‌های اندازه‌گیری ناحیه گسترده (WAMS) در سیستم‌های قدرت، داده‌های اندازه‌گیری همگام‌شده زیادی برای تعیین STVS مبتنی بر داده در دسترس است [7,8]. براساس داده‌های واحدهای اندازه‌گیری فازور (PMU) و روش‌های یادگیری ماشین، تلاش‌های زیادی برای ارزیابی STVS انجام شده است. یادگیری مجموعه‌ای از شبکه‌های عصبی با وزن‌های تصادفی [7]، استفاده از درخت تصمیم مبتنی بر شکل‌بندی سری‌های زمانی [8]، ماشین یادگیری افراطی (ELM^۲) برای تعیین وضعیت پایداری به روش سلسله‌مراتبی خودتطبیقی [9]، به‌کارگیری روش یادگیری تقویتی مشتمل بر جنگل تصادفی وزن‌دهی‌شده [10] از جمله روش‌های یادگیری کم‌عمق هستند. به‌کارگیری مدل ترکیبی تصادفی از ELM و شبکه پیوند عملکردی تصادفی بردار (RVFL^۳) [11] نمونه دیگری از یادگیری کم‌عمق است که دقت ارزیابی بهتری نسبت به ELM و RVFL منفرد دارد. مرجع [12] پایش هم‌زمان پایداری ولتاژ و پایداری گذرا را پیشنهاد داده است که در آن استفاده از داده‌ها بدون ملاحظه فرآیند یادگیری ماشین و طی یک فرآیند محاسباتی انجام شده است. استفاده از این روش‌ها در حین بهره‌برداری و به‌هنگام چالش برانگیز است؛ زیرا زمان محاسباتی دقیق مشخص نیست.

دقیق‌تر وضعیت STVS به کمک داده‌های اندازه‌گیری قبلی و بعد از خطا.

این مقاله معیارهای عملکردی و پارامترهای آماری گسترده نظیر دقت، منحنی مشخصه عملکرد و سطح زیر منحنی مشخصه را برای ارزیابی مدل پیشنهادی اجرا کرده است.

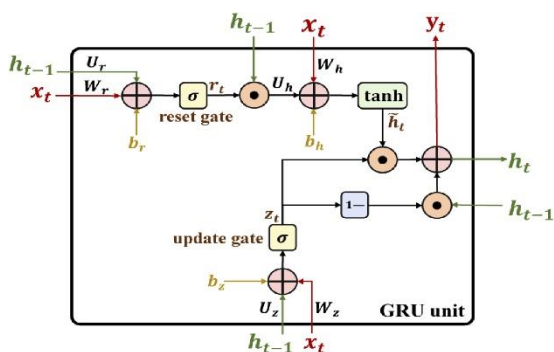
بخش‌های مختلف مقاله عبارت‌اند از: معرفی الگوریتم یادگیری ماشین پیشنهادی، شاخص دینامیک پایداری ولتاژ، چارچوب مسئله، شبیه‌سازی و نتیجه‌گیری.

۲- شبکه بازگشتی دروازه‌ای دوسویه با لایه‌های کانولوشن

در این بخش، ابتدا مقدمه‌ای از شبکه عصبی GRU و BiGRU گفته می‌شود، سپس مدل پیشنهادی این مقاله معرفی خواهد شد.

۲-۱- شبکه واحد بازگشتی دروازه‌ای (GRU)

GRU نسخه بهبودیافته‌ای از RNN است که در آن دروازه‌های به‌روزرسانی (z_t) و بازنشانی (r_t) با هدف رفع مشکل محوشدن گرادیان ارائه شده‌اند [22]. ساختار یک واحد GRU دارای دو ورودی در لحظه‌های زمانی مختلف است که بردار ورودی جاری x_t و بردار h_{t-1} خروجی لحظه قبلی است. خروجی هر دروازه از طریق عملیات منطقی و تبدیل ورودی غیرخطی به دست می‌آید [23].



شکل (۱): جزئیات ساختار یک واحد GRU [24]

همچنین، BiGRU به دلیل ملاحظه وابستگی‌های گذشته و حال داده‌های ورودی می‌تواند خروجی معنادارتری را تولید کند و عملکرد بهتری نسبت به GRU داشته باشد.

شبکه GRU به صورت متوالی عمل می‌کند. خروجی ورودی دوم به ورودی اول بستگی دارد؛ بنابراین، نمی‌توان GRUها را موازی کرد؛ در حالی که کانولوشن‌ها این مشکل را ندارند و هر پیچ که یک هسته (kernel) کانولوشن روی آن کار می‌کند، مستقل از دیگری است و این یعنی می‌توان کل لایه ورودی را به صورت هم‌زمان مرور کرد. همچنین، کانولوشن می‌تواند روند تغییرات و ویژگی‌های عمیق داده‌ها را دنبال کند که می‌تواند منجر به نتایج بهتری در یادگیری ماشین شود.

به طور کلی هدف این مقاله، تعیین وضعیت برخط STVS با داده‌های اندازه‌گیری و دقت بالا و بازه زمانی کوچکی بعد از وقوع خطا است؛ به طوری که زمان لازم برای اقدامات اصلاحی فراهم باشد تا از سرایت مشکلات پیشامد در بخش‌های دیگر شبکه جلوگیری شود. برای این هدف، یک روش یادگیری عمیق ترکیبی از لایه‌های کانولوشن و شبکه BiGRU پیشنهاد شده است تا با پردازش عمیق داده‌های اندازه‌گیری فازوری سیستم قدرت و تحلیل وابستگی زمانی داده‌ها، با دقت بالایی وضعیت STVS به صورت برخط برای بهره‌برداری مشخص باشد و پیچیدگی روش‌های مبتنی بر مدل مانع از پایش برخط سیستم نشود.

با توجه به بررسی کارهای گذشته و ضعف‌های موجود، نوآوری‌های اصلی این مقاله عبارت‌اند از:

استفاده از داده‌های اندازه‌گیری دامنه ولتاژ و زاویه فاز که برای ارزیابی پایداری ولتاژ کوتاه‌مدت در هر شین به طور مجزا به صورت به‌هنگام از طریق PMUها در دسترس هستند.

ارائه شاخص دینامیکی پایداری ولتاژ برای دسته‌بندی داده‌های سری زمانی و ایجاد یک مسئله دسته‌بندی سه کلاس؛ به طوری که بین حالت پایدار و ناپایدار یک کلاس دیگری تعریف شود تا بهره‌بردار برای اقدامات اصلاحی متناسب تصمیم‌گیری بهتری داشته باشد.

به‌کارگیری شبکه عصبی - بازگشتی دوسویه با لایه‌های کانولوشن (Conv-BiGRU) با هدف پیش‌بینی

خواهد شد.

شبکه عصبی کانولوشن (CNN^{۱۲}) علاوه بر دسته‌بندی تصاویر در تحلیل داده‌های یک‌بعدی سری زمانی نیز کاربرد دارد؛ به‌طور مثال، در پیش‌بینی بار الکتریکی از شبکه کانولوشن استفاده شده است [27]. CNN یک شبکه پیش‌خور (feed-forward) است که امکان رمزگذاری اطلاعات مهم موجود در داده‌های ورودی را با پارامترهای بسیار کمتری نسبت به سایر مدل‌های یادگیری عمیق فراهم می‌کند [26]. ترکیب CNN با BiGRU برای پیش‌بینی کوتاه‌مدت بار [28] و ترکیب CNN با GRU برای پیش‌بینی کوتاه‌مدت بار مسکونی [27] به کار گرفته شده‌اند. کانولوشن در ساختار یادگیری ماشین منجر به استخراج ویژگی زمانی داده‌ها و تعیین وابستگی زمانی داده‌ها خواهد شد. از آنجایی که رفتار مقادیر ولتاژ و زاویه فاز در طول زمان به مقادیر گذشته خود بستگی دارند، شناسایی این وابستگی و آموزش پایگاه داده با تعیین این وابستگی منجر به آموزش عمیق‌تر پایگاه داده خواهد شد؛ به طوری که در سیگنال‌های اندازه‌گیری جدید که حتی ماشین یادگیری در حین آموزش ندیده است، ماشین قادر خواهد بود با فهم این وابستگی زمانی وضعیت STVS را دقیق‌تر پیش‌بینی کند.

در این مقاله از دو لایه کانولوشن بعد از داده‌های ورودی استفاده شده است تا اطلاعات مهم داده‌های اندازه‌گیری استخراج شود. شکل (۲) یکی از لایه‌های کانولوشن را نشان می‌دهد. شبکه پیشنهادی شامل ۷ لایه است که عبارت‌اند از دو لایه کانولوشن، دو لایه BiGRU، یک لایه نرمال‌کردن دسته‌ها (Batch) و جلوگیری از بیش‌برازش (Overfitting)، یک لایه تمام‌اتصال (Fully Connected) و لایه خروجی شامل تابع softmax. لایه‌های کانولوشن حاصل ضرب درایه‌ای ورودی در وزن‌های نوروهای CNN را محاسبه می‌کنند و با استفاده از تابع فعال‌ساز ReLU به لایه BiGRU تحویل می‌دهند. در لایه BiGRU داده‌ها در دو جهت گذشته و آینده بررسی می‌شوند تا وابستگی زمانی داده‌ها برای دسته‌بندی استخراج شود.

روابط ریاضی مدل GRU عبارت‌اند از [25]:

$$h_t = (1 - z_t) \square h_{t-1} + z_t \square \tilde{h}_t \quad (1)$$

$$\tilde{h}_t = \tanh(W_h x_t + U_h (r_t \square h_{t-1}) + b_h) \quad (2)$$

دروازه‌های به‌روزرسانی و بازنشانی به ترتیب در روابط

(۳) و (۴) تعریف می‌شوند [25].

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (3)$$

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (4)$$

در این روابط $W_r, U_r, W_z, U_z, W_h, U_h$

بردارهای وزنی هستند. b_h, b_z, b_r بردارهای بایاس

برای ورودی x_t و حالت قبلی h_{t-1} هستند. σ تابع فعال‌ساز است که می‌تواند در شکل‌های مختلفی همچون \tanh باشد که در ادامه توضیح داده شده است. در این روابط \odot نشان از ضرب درایه‌ای هادامار (Hadamard product) است.


۲-۲- شبکه واحد بازگشتی دروازه‌ای دوسویه

(BiGRU)

شبکه GRU از ساختار بازگشتی برای ذخیره و بازیابی داده‌ها در دوره‌های بلندمدت استفاده می‌کند و عملکرد آن ممکن است رضایت‌بخش نباشد؛ زیرا تنها به اطلاعات گذشته دسترسی دارد. شبکه دوطرفه (BiGRU) GRU دارای یک لایه آینده است که در آن توالی داده‌ها در جهت مخالف است تا بر مشکل GRU غلبه کند؛ بنابراین، BiGRU از دو لایه پنهان برای استخراج اطلاعات از گذشته و آینده استفاده می‌کند (شکل (۲)) و هر دو در یک لایه خروجی به هم متصل می‌شوند. ویژگی‌های ساختار دوسویه برای استخراج اطلاعات بیشتر و در نتیجه، بهبود عملکرد فرآیند یادگیری به شبکه‌های عصبی بازگشتی کمک می‌کند [26].

۲-۳- شبکه عصبی پیشنهادی

در این مقاله با ارائه ساختار جدیدی از یادگیری عمیق مطابق شکل (۲) وضعیت STVS به‌صورت برخط پایش



الف: شبکه عصبی استاندارد
ب: بعد از اجرای Dropout

شکل (۳): عملکرد Dropout در شبکه عصبی [30]

$$y_{zi} = \frac{e^{zi}}{\sum_{k=1}^k e^{zk}} \quad (5)$$

$$L(y, \hat{y}) = -\frac{1}{N} \sum_{i=1}^N [y_i \log \hat{y}_i + (1-y_i) \log(1-\hat{y}_i)] \quad (6)$$

مدل پیشنهادی از طریق تابع هزینه آنتروپی (۶) بهینه شده است.

۱ یا ۰، یا y کلاس پیش‌بینی شده پایدار، هشدار یا ناپایدار (۰، ۱) یا (۲) است و p احتمال پیش‌بینی کلاس مربوطه است.

۲-۴- پارامترهای مدل و معیارهای عملکردی

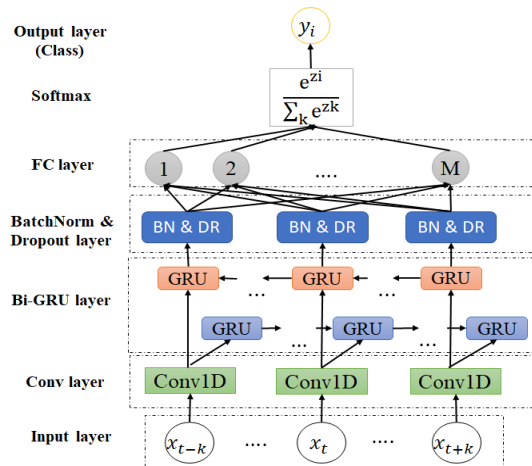
برخی از توابع فعال‌ساز عبارت‌اند از تابع سیگموئید (sigmoid)، تابع تانژانت هایپربولیک و تابع یکسوشده خطی (Rectified Linear Unit) ReLU که به ترتیب مطابق **Error! Reference source not found.** تا (۹) هستند.

$$\sigma(x) = 1/(1+e^{-x}) \quad (7)$$

$$\tanh(x) = \frac{2}{1+e^{-2x}} - 1 \quad (8)$$

$$\sigma(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ x & \text{for } x > 0 \end{cases} \quad (9)$$

تابع سیگموئید هر مقدار حقیقی را که به‌عنوان ورودی دریافت کند، به شکل یک مقدار پیوسته بین ۰ و یک تحویل می‌دهد؛ بنابراین، یک تغییر بزرگ در مقدار ورودی را به یک مقدار کوچک نگاشت می‌کند که این باعث گرادیان کم و بروز پدیده محو شدن گرادیان خواهد شد. تابع \tanh نیز مشکل مشابه را دارد و خروجی را بین (۱ و -۱) نمایش می‌دهد. به دلیل احتمال بروز محو شدن گرادیان، توابع




شکل (۲): معماری Conv-BiGRU

نرمال‌سازی دسته‌ای (Batch Normalization)

ورودی‌های لایه بعدی را استاندارد می‌کند که باعث تثبیت فرآیند یادگیری و کاهش چشمگیر تعداد دوره‌های آموزش و افزایش سرعت آموزش خواهد شد [29]. در این مقاله بعد از دو لایه کانولوشن و دو لایه BiGRU از تکنیک BN استفاده شده است و قبل از لایه FC، Dropout و BN با هم به کار رفته‌اند تا سرعت مدل پیشنهادی را بهبود بخشند. همان‌طور که شکل (۳) نشان می‌دهد با حذف تصادفی برخی گره‌ها توسط Dropout از پدیده بیش‌برازش در فرآیند یادگیری عمیق جلوگیری می‌شود. لایه FC قادر است روابط غیرخطی بین ورودی‌ها را با یک تابع فعال‌ساز، محاسبه و بردارهای ورودی را به فضایی تبدیل کند تا دسته‌بندی را آسان‌تر کند. در نهایت با تابع softmax خروجی دسته‌بندی (کلاس وضعیت STVS) مشخص می‌شود.

Softmax احتمال کلاس‌ها را محاسبه و کلاس با بیشترین احتمال را به‌عنوان کلاس خروجی معرفی می‌کند (رابطه **Error! Reference source not found.** k). تعداد کلاس‌های دسته‌بندی و y احتمال هر کلاس است که در این مقاله با سه کلاس پایدار، هشدار و ناپایدار سروکار داریم.

می‌کند.



شکل (۴): نمودار مشخصه عملکرد (ROC)

۳- شاخص دینامیکی پایداری ولتاژ

در این مقاله، رفتار دینامیکی ولتاژ برای ارزیابی STVS لحاظ شده و این موضوع منجر به ایجاد پایگاه داده‌ای مبتنی بر سری زمانی شده است. شاخص‌های استاتیک تعیین پایداری ولتاژ تنها براساس یک نقطه کاری معین کار می‌کنند. چون موضوع دینامیک ولتاژ به شاخصی منطبق بر داده‌های سری زمانی نیاز دارد، با ملاحظه دستورالعمل ولتاژ بهره‌برداری NERC [31] و تابع لپانوف [32] یک شاخص پایدار ولتاژ دینامیکی تعریف شده است. طبق معیار NERC ولتاژ بعد از رفع خطا باید حداقل ۷۰ درصد ولتاژ نامی باشد و همچنین، ولتاژ هر شینه نباید به مقدار کمتر از ۸۰ درصد نامی بعد از ۲۰ سیکل افت کند. رابطه (۱۲) افت ولتاژ شین‌ها را بعد از رفع خطا محاسبه می‌کند که V_i^0 مقدار ولتاژ پیش از وقوع خطا و V_i^t مقدار ولتاژ بعد از رفع خطا است.

$$\Delta V_i^t = \frac{V_i^0 - V_i^t}{V_i^0}, i \in [1, N_b], t \in [t_{cl}, t_a] \quad (12)$$

$$VD_i = \min \{ \Delta V_i^t \} \quad (13)$$

که t_{cl} زمان رفع خطا و t_a دوره تحلیل رفتار ولتاژ (۲۰ سیکل بعد از رفع خطا) است. چنانچه حداقل افت ولتاژ در هر شینه (VD) بیش از ۲۰ درصد مقدار نامی

سیگموئید و \tanh برای شبکه‌هایی با تعداد لایه بالا مناسب نیستند. این مقاله از تابع ReLU در لایه‌های کانولوشن و BiGRU و در لایه FC از تابع \tanh استفاده کرده است.

یکی از ابزارهای مقایسه عملکرد الگوریتم‌های یادگیری ماشین، ماتریس درهم‌ریختگی در جدول (۱) است. معیار دقت (Accuracy) را می‌توان همچون (۱۰) از ماتریس درهم‌ریختگی استخراج کرد. یکی دیگر از روش‌های بررسی عملکرد دسته‌بندی داده‌ها، نمودار مشخصه عملکرد (ROC) است که از ترسیم نرخ مثبت صحیح (True Positive Rate) بر حسب نرخ مثبت نادرست (False Positive Rate) ایجاد می‌شود. نرخ مثبت صحیح یا حساسیت برای کلاس پایدار در (۱۱) تعیین شده است و FPR از طریق (حساسیت-۱) محاسبه می‌شود.

جدول (۱): ماتریس درهم‌ریختگی مسئله سه کلاس

کلاس‌های پیش‌بینی شده				
ناپایدار	هشدار	پایدار		
ناپایدار غلط	هشدار غلط	پایدار درست	پایدار	کلاس‌های واقعی
ناپایدار غلط	هشدار درست	پایدار غلط	هشدار	
ناپایدار درست	هشدار غلط	پایدار غلط	ناپایدار	

$$(10) \quad \text{دقت} = \frac{\text{تعداد کل پیش‌بینی‌ها}}{\text{جمع پیش‌بینی‌های درست}}$$

$$(11) \quad \text{حساسیت} = \frac{\text{پایدار درست}}{\text{پایدار درست} + \text{هشدار غلط} + \text{ناپایدار غلط}}$$

ROC غالباً در دسته‌بندی دوتایی استفاده می‌شود؛ اما در این مقاله ROC برای هر کلاس نسبت به دو کلاس دیگر محاسبه شده است. شکل (۴) رفتار ROC نسبت به میزان پیش‌بینی‌های درست و نادرست نشان می‌دهد؛ به طوری که با افزایش پیش‌بینی‌های درست سطح زیر منحنی ROC افزایش می‌یابد و برعکس، هرچه عملکرد یادگیری ضعیف باشد، منحنی ROC به خط قطری نزدیک می‌شود و مساحت زیر منحنی کاهش می‌یابد. سطح زیر منحنی ROC را AUC می‌نامند که یک معیار کلی از مدل یادگیری فراهم

پیش از خطا) باشد $(VD > 0.2 \text{ p.u.})$ ، به دلیل ماهیت دینامیکی سیستم قدرت و رفتار نوسانی ولتاژ بعد از وقوع خطا، دستورالعمل NERC به تنهایی قادر به پایش وضعیت پایداری ولتاژ نخواهد بود.

در این مقاله از تابع لیاپانوف برای پایش نوسانات ولتاژ استفاده شده است. مفهوم پایداری از نظریه ارگودیک سیستم دینامیکی، اقتباس و با نمای لیاپانوف ضبط شده است. برای یک سیستم دینامیکی پیوسته، اگر نمای لیاپانوف سیستم منفی باشد، دینامیک حالت ماندگار سیستم از یک نقطه تعادل پایدار تشکیل می شود. تعریف ریاضی بیان کننده حد اکثر نمای لیاپانوف به شرح زیر است [32].

یک سیستم دینامیکی پیوسته فرض شود $\dot{x} = f(x), x \in X \subset R^N$ اگر $\phi(t, x)$ پاسخ معادلات دیفرانسیل باشد، ماتریس محدود شده زیر تعریف می شود:

$$\varepsilon_1 < \|V_{m\Delta t} - V_{(m-1)\Delta t}\| < \varepsilon_2, m = 1, 2, \dots, N \quad (16)$$

به ازای $\lambda_i > 0$ نوسانات ولتاژ واگرا خواهند بود.

جدول (۲): خلاصه دسته بندی پایگاه داده بر اساس

شاخص دینامیکی و نمای لیاپانوف

STVS	کلاس	λ	VD
ناپایدار		$0 <$	$0, 2 <$
هشدار		$0 >$	$0, 2 <$
هشدار		$0 <$	$0, 2 >$
پایدار		$0 >$	$0, 2 >$

با ترکیب VD و λ دسته بندی وضعیت ولتاژ به حالت های پایدار، هشدار و ناپایدار مطابق جدول (۲) انجام می شود. چنانچه رفتار ولتاژ نوسانی واگرا و با افت ولتاژ غیرمجاز همراه باشد، ناپایداری ولتاژ رخ داده است. حال اگر ولتاژ بعد از رفع خطا نوسانی همگرا اما دچار افت ولتاژ غیرمجاز $(VD > 0.2 \text{ p.u.})$ شود یا اینکه ولتاژ قبل از ۲۰ سیکل بعد از خطا به محدوده پذیرفتنی برگردد، اما نوسانی واگرا باشد، این دو حالت به عنوان وضعیت هشدار تعریف شده اند. در نهایت، اگر هیچ یک از موارد نوسانی واگرا یا افت ولتاژ غیر مجاز ایجاد نشود، وضعیت پایدار خواهد بود. شکل (۵) و شکل (۶) روند تغییرات ولتاژ و نمای لیاپانوف را به ترتیب برای حالت های هشدار و ناپایدار نشان می دهند. در حالت هشدار ولتاژ بعد از رفع خطا به محدوده پذیرفتنی برگشته است؛ اما رفتار نوسانی منجر به مثبت شدن نمای لیاپانوف شده است. در حالت ناپایدار هم VD بزرگ تر از ۰,۲ پریونیت است و هم لیاپانوف مثبت است. نکته بسیار مهم اینکه وقوع خطا در نزدیکی شین های متصل به ماشین سنکرون می تواند منجر به ناپایداری گذرا و نوسانی شدن زاویه روتور ماشین سنکرون شود.

رفتار زاویه فاز شین مرتبط با شکل (۶) در شکل (۷)

رابطه (۱۵) نمای لیاپانوف شین i را به ازای تغییرات دامنه ولتاژ نشان می دهد؛ به طوری که $\Lambda_i(x)$ مقادیر ویژه ماتریس محدود شده $\Lambda(x)$ است. نمای لیاپانوف $\lambda_i(x)$ به شکل $\lambda_i(x) = \log \Lambda_i(x)$ تعریف می شود. در این مقاله نمای لیاپانوف برای یک دوره زمانی محدود محاسبه می شود؛ بنابراین، به جای استفاده از مدل سیستم برای محاسبه نمای لیاپانوف، داده های سری زمانی به کار گرفته شده اند. بدین ترتیب نمای لیاپانوف برای هر شینه به صورت رابطه (۱۵) بیان می شود. برای تعیین مقدار λ در پنجره زمانی متحرک k ، از میانگین مقادیر استفاده می شود تا مثبت یا منفی بودن این پارامتر تعیین شود و همگرایی یا واگرایی نوسانات مشخص شود.

$$\Lambda(x) = \lim_{t \rightarrow \infty} \left[\frac{\partial \Phi(t, x)^T}{\partial x} \frac{\partial \Phi(t, x)}{\partial x} \right]^{1/2t} \quad (14)$$


$$\lambda_i(k\Delta t) := \frac{1}{Nk\Delta t} \times \sum_{m=1}^N \log \frac{|V_{(k+m)\Delta t} - V_{(k+m-1)\Delta t}|}{|V_{m\Delta t} - V_{(m-1)\Delta t}|}, k > N \quad (15)$$

$$\forall i = 1, 2, \dots, N_b$$


Δt نرخ نمونه برداری داده های اندازه گیری،

۸ پیش‌بینی وضعیت پایداری ولتاژ کوتاه‌مدت مبتنی بر یک شبکه عصبی بازگشتی دوسویه با استفاده از داده‌های اندازه‌گیری فازوری در سیستم‌های قدرت


آورده شده است؛ بنابراین، برخی از ناپایداری‌های ولتاژ می‌تواند نتیجه ناپایداری گذرا باشد که در این مقاله از مجزاکردن این حالت‌ها چشم‌پوشی شده است.



شکل (۵): منحنی دامنه ولتاژ و نمای لیاپانوف در یک مورد هشدار



شکل (۶): منحنی دامنه ولتاژ و نمای لیاپانوف در یک مورد ناپایدار



شکل (۷): رفتار زاویه فاز و نمای لیاپانوف متناظر در وضعیت ناپایدار

۴- ساختار الگوریتم پیشنهادی

ارزیابی STVS مبتنی بر داده‌های اندازه‌گیری نیازمند آموزش یک الگوریتم یادگیری ماشین است. چارچوب اجرای یادگیری عمیق روی پایگاه داده در شکل (۸) نشان داده شده است. الگوریتم در دو مرحله برون خط (آفلاین) و برخط (آنلاین) انجام می‌شود. در مرحله آفلاین تشکیل پایگاه داده و آموزش آن توسط شبکه پیشنهادی و در مرحله آنلاین ارزیابی برخط STVS اجرا خواهد شد.

۴-۱- تشکیل پایگاه داده

پایگاه داده را می‌توان براساس داده‌های بهره‌برداری گذشته ایجاد کرد. از آنجایی که ممکن است داده‌ها به هر دلیلی از دست رفته باشند و نیز برخی از موارد بهره‌برداری محتمل در گذشته اتفاق نیافته باشند و همچنین، نیاز است طرح‌های توسعه و تغییر ساختار شبکه نیز در پایگاه داده لحاظ شود، از شبیه‌سازی حوزه زمان برای در نظر گرفتن موارد مذکور استفاده می‌شود. با ایجاد شرایط مختلف بهره‌برداری شامل پیشامد N-1 خروج خط یا ماشین سنکرون به علاوه خطای اتصال کوتاه سه فاز روی نقاط مختلف خطوط در سطوح مختلف بار شبکه پایگاه داده جامع تولید می‌شود. پایگاه داده شامل سری زمانی دامنه ولتاژ و زاویه فاز به صورت $X^{m \times n}$ است (رابطه ۱۷). تعداد سطرها برابر است با $m = N_b \times s$ ، که N_b تعداد شین‌های متصل به PMU و s تعداد کل سناریوهای

بهره‌برداری است. ستون‌های پایگاه داده شامل نمونه‌های ولتاژ و زاویه فاز است.

$$X = [x_i^1, x_i^2, \dots, x_i^T], i = 1, 2, \dots, N_b \quad (17)$$

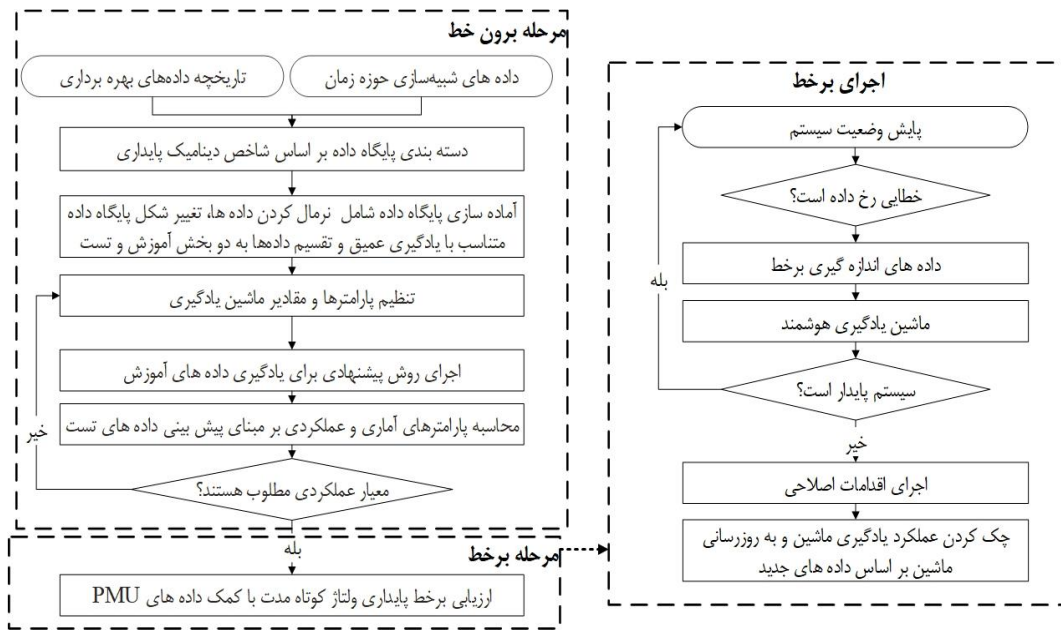
بعد از ایجاد پایگاه داده مطابق روندنمای پیشنهادی در شکل (۸) با استفاده از شاخص دینامیکی پیشنهاد شده در این مقاله، داده‌های هر شین (هر سطر) به یکی از کلاس‌های پایدار، هشدار و ناپایدار دسته‌بندی می‌شوند. برای آموزش از طریق یادگیری عمیق باید لایه ورودی به شکل سه‌بعدی تبدیل شود؛ بنابراین، نمونه‌های ولتاژ و زاویه فاز به شکل

$$x_i^1 = \{v^1, \delta^1\}$$

تبدیل می‌شوند تا ابعاد پایگاه داده از (m, n) به (m, n/2, 2) تغییر شکل داده شود. پیش از فرآیند آموزش می‌توان از نرمال‌سازی داده‌ها استفاده کرد تا عملکرد ارزیابی STVS را بهبود بخشد. رابطه (۱۸) روش نرمال‌سازی داده‌ها از طریق تابع MinMaxScaler را نشان می‌دهد.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (18)$$

بعد از نرمال‌سازی، پایگاه داده به صورت تصادفی به دو بخش داده‌های آموزش و آزمون با نسبت ۷۰ و ۳۰ درصد تقسیم شده است. برای شروع فرآیند آموزش نیاز است پارامترهای مدل اعم از تعداد دوره‌ها (Epoch) و اندازه بسته (Batch size) و ... تنظیم شوند تا بهترین عملکرد به دست آید.



شکل (۸): روندنمای ارزیابی برخط STVS با استفاده از داده‌های اندازه‌گیری و یادگیری ماشین

از میلی ثانیه، وضعیت پایداری را برای بهره‌بردار مشخص می‌کند تا در صورت لزوم اقدامی انجام شود.

۵- شبیه‌سازی

شبکه ۳۹ و ۱۱۸ شین IEEE [35] نمونه‌های مطالعاتی متداول در ارزیابی STVS هستند. مطابق [36] و [37] در شبکه ۳۹ و ۱۱۸ شین به ترتیب ۸ و ۲۱ شین (جدول (۳)) به‌عنوان شین‌های متصل به PMU انتخاب شده‌اند. با توجه به فرکانس شبکه ۳۹ شین (۶۰ هرتز) و شبکه ۱۱۸ شین (۵۰ هرتز) نرخ نمونه‌برداری داده‌ها به ترتیب ۳۰ و ۲۰ میلی‌ثانیه در نظر گرفته شده است. شبیه‌سازی حوزه زمان برای تولید سناریوهای بهره‌برداری و ایجاد پایگاه داده در محیط نرم‌افزار DIgSILENT 15.1.7 و حالت RMS انجام شده است. دسته‌بندی داده‌های به کمک شاخص دینامیکی در محیط MATLAB 2019b و اجرای فرآیند یادگیری و ارزیابی از طریق محیط Python اجرا شده است.

جدول (۳): شین‌های منتخب متصل به PMU


مورد مطالعاتی	شین‌های متصل به PMU
IEEE 39bus	۲۹، ۲۵، ۲۳، ۲۰، ۱۶، ۱۰، ۸، ۳
IEEE 18bus	۷۵، ۶۹، ۶۳، ۶۲، ۵۸، ۵۵، ۴۷، ۴۳، ۳۵، ۲۹، ۱۳، ۳ ۱۱۵، ۱۱۳، ۱۰۷، ۱۰۶، ۱۰۴، ۹۳، ۹۱، ۸۲، ۸۱

مقایسه بین کلاس‌های واقعی داده‌های آزمون و کلاس‌های پیش‌بینی شده، عملکرد الگوریتم را مشخص می‌کند. چنانچه عملکرد الگوریتم مناسب نباشد، از روش Grid Search [33] استفاده شده است تا پارامترهایی با بهترین دقت یادگیری انتخاب شوند. همه مدل‌ها از طریق بهینه‌ساز Adam [34] با نرخ یادگیری اولیه ۰،۰۰۱ و نرخ پایانی ۰،۰۰۰۰۱ آموزش داده شده‌اند.

۴-۲- ارزیابی مدل و اجرای برخط


با هدف ارزیابی مدل پیشنهادشده از داده‌های جدید استفاده شده است تا عملکرد مدل در مقابل رفتارهای جدید داده‌های اندازه‌گیری بررسی شود. داده‌های جدید تحت شرایط مختلف بهره‌برداری اعم از تغییر سطح بار، تغییر نسبت بار دینامیکی و موتورهای القایی شبکه به بار استاتیکی، تغییر محل خطا در خطوط یا ایجاد شرایط بهره‌برداری N-2 حاصل شده‌اند؛ به طوری که هریک از این موارد یا ترکیب آنها می‌تواند منجر به نقاط کاری جدید نیز شود. مطابق شکل (۸) در مرحله برخط پایداری ولتاژ سیستم قدرت بر مبنای داده‌های اندازه‌گیری پیش می‌شود. چنانچه خطایی در سیستم رخ دهد، ماشین یادگیری پیشنهادی با استفاده از داده‌های اندازه‌گیری قبل و بعد خطا و در کسری

نشان داده شده است. روند یادگیری داده‌های آموزش (Training) و پیش‌بینی داده‌های آزمون در هر دو شبکه نشان می‌دهد شبکه Conv-BiGRU بعد از ۲۰ تکرار به بالای ۹۶ درصد دقت رسیده است. در تعداد دوره کمی به دقت ۹۶ درصد رسیده است؛ یعنی اینکه شبکه پیشنهادی به‌خوبی وابستگی زمانی داده‌های گذشته و آینده را استخراج کرده و مرز بین کلاس‌های پایدار، هشدار، و ناپایدار را تشخیص داده است.



شکل (۹): دقت یادگیری داده‌های آموزش و پیش‌بینی داده‌های آزمون در شبکه ۳۹ شین

شکل (۹) و شکل (۱۰) تأیید می‌کنند تنظیم پارامترهای مدل Conv-BiGRU به‌درستی انجام شده است؛ به طوری که بیش‌برازش (Overfitting) و کم‌برازش (Underfitting) رخ نداده است و هر دو منحنی آموزش و اعتبارسنجی در یک راستا و با کمترین نوسان شدیدی همراه‌اند. همچنین، این دو شکل نشان می‌دهند دقت یادگیری و پیش‌بینی در هر دو شبکه بالای ۹۹ درصد است که یک نتیجه قابل اعتماد برای بهره‌بردار سیستم قدرت است.



شکل (۱۰): دقت یادگیری داده‌های آموزش و پیش‌بینی داده‌های آزمون در شبکه ۱۱۸ شین

با تعریف شرایط مختلف بهره‌برداری و با فرض پیشامد N-1 (خروج یک خط انتقال یا یک ماشین سنکرون) و شبیه‌سازی خطای اتصال کوتاه سه‌فاز روی ۵، ۱۰، ۵۰، ۹۰ و ۹۵ درصد خطوط، ۱۰۷۶۰ سناریو در شبکه ۳۹ شین و ۱۰۰۰۰ سناریو در شبکه ۱۱۸ شین تولید شده است. زمان وقوع خط $t=0.5$ sec و طول دوره خطا ۱۰۰ و ۲۰۰ میلی‌ثانیه فرض شده است. همچنین، فرض بر این است که با رفع خطا خط انتقال مورد خطا از شبکه خارج می‌شود. پایگاه داده در شبکه ۳۹ شین ۸۶۰۸۰ سطر و در شبکه ۱۱۸ شین ۲۱۰۰۰۰ سطر دارد. در هر دو شبکه ۲۵۰ نمونه دامنه ولتاژ و ۲۵۰ نمونه زاویه فاز استخراج شده است. جدول (۴) دسته‌بندی داده‌ها را مبتنی بر شاخص دینامیکی نشان می‌دهد. در شبکه ۳۹ شین موارد بیشتری از خطاها منجر به ناپایداری در شبکه شده که یک دلیل آن کوچک بودن شبکه و همبستگی بیشتر تجهیزات با یکدیگر است. پارامترهای اصلی مدل Conv-BiGRU در جدول (۵) آورده شده‌اند. با توجه به تعداد داده‌های ورودی (نمونه‌های دامنه ولتاژ و زاویه فاز) ۶۴ بسته (Batch) و ۲۰۰ تکرار انتخاب شده‌اند.

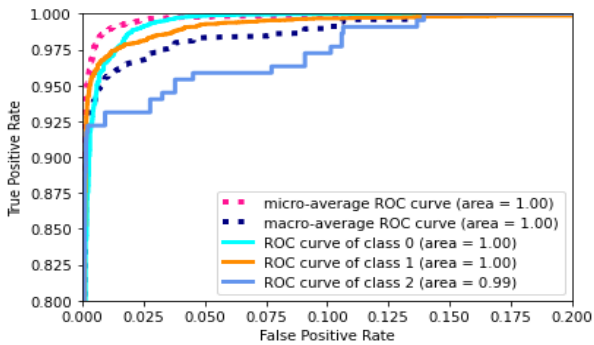
جدول (۴): نتایج دسته‌بندی پایگاه داده در شبکه‌های مورد مطالعه

شبکه	پایدار	هشدار	ناپایدار
IEEE 39bus	٪ ۱۹,۳۳	٪ ۲۴,۵۲	٪ ۵۶,۱۵
IEEE 18bus	٪ ۵۱,۲۵	٪ ۲۱,۳۲	٪ ۲۷,۴۳


جدول (۵): تنظیم پارامترهای اصلی مدل Conv-BiGRU

پارامترها	مقدار / نوع
لایه کانولوشن	فیلترها: ۳۲ و ۱۶
	تعداد هسته‌ها: ۵ و ۴
تابع فعالساز کانولوشن و BiGRU	ReLU و tanh
نرخ یادگیری	۰,۰۰۰۰۱
تعداد دوره	۲۰۰
اندازه بسته	۶۴
Dropout	۰,۴

با اجرای مدل پیشنهادی روی دامنه ولتاژ و زاویه فاز قبل و بعد از خطا در شبکه‌های ۳۹ و ۱۱۸ شین IEEE روند دقت یادگیری به‌ترتیب در شکل (۹) و شکل (۱۰)



شکل (۱۲): منحنی مشخصه عملکرد در شبکه ۳۹ شین




شکل (۱۳): منحنی مشخصه عملکرد در شبکه ۱۱۸ شین

۵-۱- پنجره زمانی

مزیت اصلی روش‌های مبتنی بر داده، به‌کارگیری این روش‌ها به صورت برخط یا به‌هنگام است؛ بنابراین، زمان تعیین وضعیت STVS در حین بهره‌برداری به‌شدت مهم است. اگر زمان پردازش داده‌ها و طول پنجره زمانی داده‌ها برای تصمیم‌گیری زیاد باشد، ممکن است دقت پیش‌بینی افزایش یابد؛ اما زمان برای اقدامات بعد از تعیین وضعیت پایداری محدود خواهد بود. برعکس، چنانچه پنجره زمانی خیلی کوچک انتخاب شود، دقت پیش‌بینی کاهش خواهد یافت؛ بنابراین، یک مصالحه بین پنجره زمانی و دقت یادگیری نیاز است تا پنجره بهینه به دست آید.

با اجرای آنالیز حساسیت روی پنجره زمانی، مطابق شکل (۱۴) و شکل (۱۵) پنجره زمانی بهینه در شبکه ۳۹ و ۱۱۸ شین به ترتیب ۹۰ و ۶۰ میلی‌ثانیه بعد از رفع خطا است. دقت یادگیری بعد از این پنجره زمانی تغییر چشمگیری در مقابل افزایش زمان نمی‌کند. به دلیل تفاوت نرخ نمونه‌برداری داده‌ها و سرعت پایش شبکه، پنجره زمانی شبکه ۱۱۸ شین کوچک‌تر است. وضعیت STVS در شبکه

برای بررسی عملکرد Conv-BiGRU تلفات تابع هزینه روی داده‌های آموزش و اعتبارسنجی (آزمون) در شبکه ۱۱۸ شین به‌عنوان نمونه در شکل (۱۱) نشان داده شده است. در این شکل، با افزایش زمان آموزش، مقدار تلفات به تدریج، کاهش و دقت آموزش افزایش می‌یابد. دامنه نوسان مقدار تلفات و دقت آموزش نیز به تدریج کاهش می‌یابد. در نهایت، مقدار تلفات نزدیک به صفر و دقت آموزش و آزمون در بالای ۹۹٪ تثبیت می‌شود. چنین فرایند آموزشی نشان می‌دهد آموزش مؤثر است و مدل در جهت درست در حال توسعه است.



شکل (۱۱): خطای تابع هزینه داده‌های آزمون در شبکه

۱۱۸ شین

برای ارزیابی الگوریتم پیشنهادی علاوه بر دقت و تابع هزینه، نمودار مشخصه عملکرد هر یک از کلاس‌های پایداری ولتاژ نسبت به دو کلاس دیگر ارائه شده است. شکل (۱۲) عملکرد این نمودار را برای شبکه ۳۹ شین نشان می‌دهد. این نمودار نشان می‌دهد در کلاس ناپایدار وضعیت پیش‌بینی‌های درست با سرعت رشد کمتری نسبت به کلاس‌های دیگر بهبود داشته است. سطح زیر منحنی مشخصه عملکرد کلاس ناپایدار نسبت به دو کلاس دیگر کمتر است و مقدار ۰٫۹۹ محاسبه شده است. شبکه ۱۱۸ شین به دلیل پیچیدگی بیشتر و نسبت بین کلاس‌های دسته‌بندی، شناسایی مرزهای بین کلاس‌ها کمی پیچیده‌تر است؛ به همین دلیل، مشخصه عملکرد آن در شکل (۱۳) متفاوت شده است. سطح زیر منحنی همه کلاس‌ها نزدیک به هم و بالاتر از ۹۹٫۸۶ درصد است.

۱۱۸ شین و با پنجره زمانی ۶۰ میلی ثانیه بعد از رفع خطا اجرا و نتایج آن در جدول (۶) آورده شده‌اند. همان‌طور که مشخص است روش پیشنهادی حتی نسبت به BiGRU عملکرد بهتری دارد. دلیل آن، استفاده از لایه کانولوشن برای استخراج دقیق‌تر وابستگی عمیق بین داده‌های سری زمانی است.

جدول (۶): مقایسه پارامترهای آماری الگوریتم‌های یادگیری

عمیق دوسویه با روش پیشنهادی

AUC	دقت آزمون	روش
۹۸,۹۶	۹۸,۸۱	BiLSTM
۹۸,۳۵	۹۸,۱۳	BiRNN
۹۹,۴۶	۹۹,۱۶	BiGRU
۹۹,۹۴	۹۹,۴	پیشنهادی


برای بررسی بیشتر و صحت‌سنجی، روش پیشنهادی این مقاله با روش مرجع [17] مقایسه شده است. برای این کار، شرایط یکسانی شامل پایگاه داده با نرخ نمونه‌برداری ۲۰ میلی ثانیه و پنجره زمانی ۶۰ میلی ثانیه بعد از خطا در شبکه ۱۱۸ شینه لحاظ شده است و ضرایب و پارامترهای مربوطه هریک از مقالات حفظ شده‌اند. با توجه به شکل (۱۶)، روش پیشنهادی این مقاله در مقایسه با مرجع [17] دقت بیشتری دارد؛ به طوری که بعد از چند سیکل، دقت پیش‌بینی روش پیشنهادی همواره بیشتر از روش مرجع مذکور است.

۵-۳- عملکرد مدل در مقابل تغییر ساختار

شبکه


یکی از چالش‌های مهم روش‌های مبتنی بر داده تغییر ساختار شبکه و داده‌های اندازه‌گیری است. به منظور آزمایش مدل Conv-BiGRU در مقابل تغییرات ساختار شبکه قدرت، ۲۰۰ مورد بهره‌برداری با تنظیم تغییر ساختار شبکه شامل تغییر نسبت بار دنیامیکی و زمان رفع خطا ایجاد شده است. با ملاحظه شبکه ۱۱۸ شین و بهره‌برداری شبکه در شرایط N-2، تغییرات ساختار جدی نسبت به شبکه اولیه لحاظ شده است.

۳۹ شین براساس داده‌های قبل خطا و پنجره زمانی ۹۰ میلی ثانیه بعد از رفع خطا با دقت ۹۹,۴۷ درصد قابل ارزیابی است و در شبکه ۱۱۸ شین به‌ازای پنجره زمانی ۶۰ میلی ثانیه، دقت ۹۹,۴ درصد است.



شکل (۱۴): تغییرات دقت به‌ازای پنجره زمانی در شبکه ۳۹

شین



شکل (۱۵): تغییرات دقت به‌ازای پنجره زمانی در شبکه ۱۱۸

شین

مدل Conv-BiGRU در شبکه ۳۹ و ۱۱۸ شین تنها به ۰,۰۸۳ و ۰,۰۹۱ میلی ثانیه، به ترتیب نیاز دارد تا در حین پایش برخط سیستم قدرت ارزیابی STVS را انجام دهد که سرعت مناسبی هست. با فرض ۵۰ میلی ثانیه تأخیر در ارسال داده‌های مخابراتی [38]، حداکثر زمان پاسخگویی این الگوریتم در شبکه ۳۹ و ۱۱۸ شین به ترتیب ۱۴۰ و ۱۱۰ میلی ثانیه است. بدین ترتیب تا قبل از عمل کردن رله‌های حفاظتی در زون دوم (۳۰۰ میلی ثانیه) می‌توان اقدامات اصلاحی فوری را برای پیشگیری از سرایت ناپایداری اجرا کرد.

۵-۲- عملکرد روش پیشنهادی در مقایسه با

روش‌های دیگر

الگوریتم‌های یادگیری عمیق روی پایگاه داده شبکه


است. در تمام موارد، شبکه BiGRU عملکرد بهتری از دو روش یادگیری عمیق دوسویه دیگر دارد که این به دلیل ساده‌تر بودن مدل BiGRU و دروازه‌های به‌روزرسانی و بازنشانی در آن است که باعث شده است انطباق‌پذیری بیشتری با رفتار داده‌ها داشته باشد.

جدول (۸): مقایسه عملکرد الگوریتم‌های دیگر با روش پیشنهادی تحت نقاط بهره‌برداری مختلف

روش	دقت آزمون
BiLSTM	۹۷,۱۱
BiRNN	۹۵,۲۸
BiGRU	۹۷,۶۸
Conv-BiGRU	۹۹,۱۲

۶- نتیجه‌گیری

حضور واحدهای اندازه‌گیری فازوری (PMU) در سیستم قدرت و توسعه روش‌های یادگیری ماشین، امکان به‌کارگیری روش‌های مبتنی بر داده در تعیین وضعیت برخط پایداری ولتاژ کوتاه‌مدت (STVS) را فراهم کرده است. این مقاله یک روش یادگیری عمیق ترکیبی از لایه‌های کانولوشن با شبکه عصبی بازگشتی دوسویه ارائه داده است تا براساس داده‌های اندازه‌گیری قبل و بعد از خطا وضعیت STVS را تعیین کند. با استفاده از شاخص دینامیکی ولتاژ یک مسئله سه کلاسه تعریف شده است تا براساس هر یک از کلاس‌ها اقدامات متناسب اصلاحی صورت گیرد. نتایج آزمایش روی شبکه‌های چندماشینه IEEE نشان می‌دهد الگوریتم پیشنهادی در این مقاله در مقایسه با روش‌های بازگشتی دیگر دقت بالاتر (بالای ۹۹ درصد) دارد. همچنین، روش پیشنهادی با تغییر ساختار شبکه و تغییر نقاط بهره‌برداری سازگار است؛ به طوری که در مقایسه با دیگر روش‌ها دقت بیشتری در تعیین وضعیت STVS به‌ازای داده‌های جدید داشته است. دقت بالای ۹۸ و ۹۹ درصد به‌ترتیب برای داده‌های جدید ناشی از تغییر ساختار شبکه و تغییر نقاط بهره‌برداری نشان می‌دهد از روش پیشنهادی می‌توان در شبکه‌های واقعی استفاده کرد و روش یادگیری ماشین با داده‌های جدید تطبیق‌پذیر است. برای کارهای آینده، بررسی داده‌های ازدست‌رفته PMUs و ارزیابی



شکل (۱۶): مقایسه عملکرد روش پیشنهادی با مرجع [15]

نتایج عملکرد این مدل نسبت به روش‌های یادگیری عمیق و مدل‌های استفاده‌شده دیگر در جدول (۷) آورده شده‌اند. مطابق جدول (۷)، Conv-BiGRU بیشترین دقت را نسبت به روش‌های دیگر دارد؛ زیرا استفاده از داده‌های ولتاژ و زاویه فاز باعث شده است تغییرات توپولوژی سیستم به‌خوبی در پایگاه داده منعکس شوند و ماشین یادگیری با دقت بیشتری در ساختار جدید شبکه عمل کند.

جدول (۷): مقایسه عملکرد الگوریتم‌های دیگر با روش پیشنهادی تحت تغییر ساختار شبکه

روش	دقت آزمون
BiLSTM	۹۶,۵۱
BiRNN	۹۴,۸۶
BiGRU	۹۷,۲۸
Conv-BiGRU	۹۸,۱

۵-۴- عملکرد مدل پیشنهادی در مقابل تغییر نقاط بهره‌برداری

با هدف ارزیابی مدل پیشنهادی در نقاط بهره‌برداری متفاوت، ۱۰۰۰ سناریوی بهره‌برداری با تغییر سطح بار و ایجاد خطا در محل‌های متفاوت خطوط و تغییر نسبت بار دینامیکی شبکه در شبکه ۱۱۸ شین ایجاد شده است. نتایج آزمایش عملکرد مدل پیشنهادی و مدل‌های دیگر در جدول (۸) نشان می‌دهند مدل Conv-BiGRU در این مقاله می‌تواند در نقاط بهره‌برداری مختلف نیز با دقت بیشتری نسبت به دیگر روش‌ها کار کند. دلیل این موضوع، استخراج وابستگی‌های زمانی در دو جهت گذشته و آینده از طریق BiGRU و همچنین، استخراج ویژگی‌های عمیق هم‌زمان داده‌های دامنه ولتاژ و زاویه فاز از طریق لایه کانولوشن

Temporal-Adaptive Voltage Stability Assessment of Power Systems,” *IEEE Trans. Ind. Informatics*, Vol. 16, No. 6, pp. 3672–3684, Jun. 2020, doi: 10.1109/TII.2019.2940098.

- [12] M.Lashgari, S. M. Shahrtash, “Concurrent Prediction of Transient and Short-term Voltage Instability in Power Systems Employing Intelligent Wide Area Measurement System,” *Computational Intelligence in Electrical Engineering (ISEE)*, Vol. 12, No. 3, pp. 1–18, Sep. 2021, doi: 10.22108/ISEE.2020.123780.1395.
- [13] J. J. Q. Yu, D. J. Hill, A. Y. S. Lam, J. Gu, and V. O. K. Li, “Intelligent Time-Adaptive Transient Stability Assessment System,” *IEEE Trans. Power Syst.*, Vol. 33, No. 1, pp. 1049–1058, Jan. 2018, doi: 10.1109/TPWRS.2017.2707501.
- [14] Z. Shi *et al.*, “Convolutional neural network-based power system transient stability assessment and instability mode prediction,” *Appl. Energy*, Vol. 263, p. 114586, Apr. 2020, doi: 10.1016/j.apenergy.2020.114586.
- [15] Y. Luo, C. Lu, L. Zhu, and J. Song, “Data-driven short-term voltage stability assessment based on spatial-temporal graph convolutional network,” *Int. J. Electr. Power Energy Syst.*, Vol. 130, p. 106753, Sep. 2021, doi: 10.1016/j.ijepes.2020.106753.
- [16] M. Zhang, J. Li, Y. Li, and R. Xu, “Deep Learning for Short-Term Voltage Stability Assessment of Power Systems,” *IEEE Access*, Vol. 9, pp. 29711–29718, 2021, doi: 10.1109/ACCESS.2021.3057659.
- [17] Y. Li, M. Zhang, and C. Chen, “A Deep-Learning intelligent system incorporating data augmentation for Short-Term voltage stability assessment of power systems,” *Appl. Energy*, Vol. 308, p. 118347, 2022, doi: <https://doi.org/10.1016/j.apenergy.2021.118347>.
- [18] L. Zhu, D. J. Hill, and C. Lu, “Intelligent Short-Term Voltage Stability Assessment via Spatial Attention Rectified RNN Learning,” *IEEE Trans. Ind. Informatics*, Vol. 17, No. 10, pp. 7005–7016, Oct. 2021, doi: 10.1109/TII.2020.3041300.
- [19] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, “Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling,” Dec. 2014, doi: 10.48550/arxiv.1412.3555.
- [20] K. Greff, R. K. Srivastava, J. Koutnik, B. R. Steunebrink, and J. Schmidhuber, “LSTM: A Search Space Odyssey,” *IEEE Trans. Neural Networks Learn. Syst.*, Vol. 28, No. 10, pp. 2222–2232, Oct. 2017, doi: 10.1109/TNNLS.2016.2582924.
- [21] L. Zhu, C. Lu, I. Kamwa, and H. Zeng, “Spatial-Temporal Feature Learning in Smart Grids: A Case Study on Short-Term Voltage Stability Assessment,” *IEEE Trans. Ind. Informatics*, p. 1, 2018, doi: 10.1109/TII.2018.2873605.
- [22] K. Cho, B. van Merriënboer, D. Bahdanau, and Y. Bengio, “On the Properties of Neural Machine Translation: Encoder-Decoder Approaches,” Sep. 2014, [Online]. Available: <http://arxiv.org/abs/1409.1259>
- [23] Y. Wang, W. Liao, and Y. Chang, “Gated

وضعیت پایداری گذرا توأم با پایداری ولتاژ در قالب روش‌های یادگیری عمیق در دستور کار قرار دارد.

مراجع

- [1] H. Bai and V. Ajjarapu, “A Novel Online Load Shedding Strategy for Mitigating Fault-Induced Delayed Voltage Recovery,” *IEEE Trans. Power Syst.*, Vol. 26, No. 1, pp. 294–304, Feb. 2011, doi: 10.1109/TPWRS.2010.2047279.
- [2] Y. Li, B. Feng, G. Li, J. Qi, D. Zhao, and Y. Mu, “Optimal distributed generation planning in active distribution networks considering integration of energy storage,” *Appl. Energy*, Vol. 210, pp. 1073–1081, 2018, doi: <https://doi.org/10.1016/j.apenergy.2017.08.008>.
- [3] Y. Li, C. Wang, G. Li, J. Wang, D. Zhao, and C. Chen, “Improving operational flexibility of integrated energy system with uncertain renewable generations considering thermal inertia of buildings,” *Energy Convers. Manag.*, Vol. 207, p. 112526, 2020, doi: <https://doi.org/10.1016/j.enconman.2020.112526>.
- [4] K. Kawabe and K. Tanaka, “Impact of Dynamic Behavior of Photovoltaic Power Generation Systems on Short-Term Voltage Stability,” *IEEE Trans. Power Syst.*, Vol. 30, No. 6, pp. 3416–3424, 2015, doi: 10.1109/TPWRS.2015.2390649.
- [5] M. A. Pai, *Energy function analysis for power system stability*. Springer Science & Business Media, 2012.
- [6] K. Kawabe, K. T.-I. T. on P. Systems, and undefined 2014, “Analytical method for short-term voltage stability using the stability boundary in the PV plane,” *ieeexplore.ieee.org*, Accessed: Nov. 30, 2018. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/6783691/>
- [7] Y. Xu *et al.*, “Assessing Short-Term Voltage Stability of Electric Power Systems by a Hierarchical Intelligent System,” *IEEE Trans. Neural Networks Learn. Syst.*, Vol. 27, No. 8, pp. 1686–1696, Aug. 2016, doi: 10.1109/TNNLS.2015.2441706.
- [8] L. Zhu, C. Lu, and Y. Sun, “Time Series Shapelet Classification Based Online Short-Term Voltage Stability Assessment,” *IEEE Trans. Power Syst.*, Vol. 31, No. 2, pp. 1430–1439, Mar. 2016, doi: 10.1109/TPWRS.2015.2413895.
- [9] Y. Zhang, Y. Xu, Z. Y. Dong, and R. Zhang, “A Hierarchical Self-Adaptive Data-Analytics Method for Real-Time Power System Short-Term Voltage Stability Assessment,” *IEEE Trans. Ind. Informatics*, Vol. 15, No. 1, pp. 74–84, 2019, doi: 10.1109/TII.2018.2829818.
- [10] A. H. Babaali and M. T. Ameli, “Weighted ensemble learning for real-time short-term voltage stability assessment with phasor measurements data,” *IET Gener. Transm. Distrib.*, Mar. 2023, doi: 10.1049/gtd2.12809.
- [11] C. Ren, Y. Xu, Y. Zhang, and R. Zhang, “A Hybrid Randomized Learning System for

- Power Syst.*, Vol. 28, No. 4, pp. 3702–3711, Nov. 2013, doi: 10.1109/TPWRS.2013.2258946.
- [33] “Hyper Parameter Tuning Using Grid search and Random search.” <https://www.numpyninja.com/post/hyper-parameter-tuning-using-grid-search-and-random-search/> (accessed Jul. 27, 2022).
- [34] D. P. Kingma and J. Ba, “Adam: A Method for Stochastic Optimization,” Dec. 2014, [Online]. Available: <http://arxiv.org/abs/1412.6980>
- [35] “IEEE 118-bus modified test system – Dynamic IEEE Test Systems.” <https://www2.kios.ucy.ac.cy/testsystems/index.php/ieee-118-bus-modified-test-system/> (accessed Aug. 31, 2021).
- [36] Y. Zhang, Y. Xu, R. Zhang, and Z. Y. Dong, “A Missing-Data Tolerant Method for Data-Driven Short-Term Voltage Stability Assessment of Power Systems,” *IEEE Trans. Smart Grid*, Vol. 10, No. 5, pp. 5663–5674, Sep. 2019, doi: 10.1109/TSG.2018.2889788.
- [37] T. Kim and S. J. Wright, “PMU placement for line outage identification via multinomial logistic regression,” *IEEE Trans. Smart Grid*, Vol. 9, No. 1, pp. 122–131, Jan. 2018, doi: 10.1109/TSG.2016.2546339.
- [38] “IEEE Standard for Synchrophasor Data Transfer for Power Systems,” *IEEE Std C37.118.2-2011 (Revision of IEEE Std C37.118-2005)*, pp. 1–53, 2011. doi: 10.1109/IEEESTD.2011.6111222.
- Recurrent Unit Network-Based Short-Term Photovoltaic Forecasting,” *Energies*, Vol. 11, No. 8, p. 2163, Aug. 2018, doi: 10.3390/en11082163.
- [24] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, “Empirical evaluation of gated recurrent neural networks on sequence modeling,” *arXiv Prepr. arXiv1412.3555*, 2014.
- [25] R. Dey and F. M. Salem, “Gate-variants of Gated Recurrent Unit (GRU) neural networks,” in *2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS)*, Aug. 2017, pp. 1597–1600. doi: 10.1109/MWSCAS.2017.8053243.
- [26] D. Zhang, L. Tian, M. Hong, F. Han, Y. Ren, and Y. Chen, “Combining Convolution Neural Network and Bidirectional Gated Recurrent Unit for Sentence Semantic Classification,” *IEEE Access*, Vol. 6, pp. 73750–73759, 2018, doi: 10.1109/ACCESS.2018.2882878.
- [27] M. Sajjad *et al.*, “A Novel CNN-GRU-Based Hybrid Approach for Short-Term Residential Load Forecasting,” *IEEE Access*, Vol. 8, pp. 143759–143768, 2020, doi: 10.1109/ACCESS.2020.3009537.
- [28] L. D. Soares and E. M. C. Franco, “BiGRU-CNN neural network applied to short-term electric load forecasting,” *Production*, Vol. 32, 2022, doi: 10.1590/0103-6513.20210087.
- [29] S. Ioffe and C. Szegedy, “Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift,” Feb. 2015, [Online]. Available: <http://arxiv.org/abs/1502.03167>
- [30] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, “Dropout: a simple way to prevent neural networks from overfitting,” *J. Mach. Learn. Res.*, Vol. 15, No. 1, pp. 1929–1958, 2014.
- [31] “Guidelines for Developing an Under Voltage Load Shedding (UVLS) Evaluation Program,” 2006. [Online]. Available: http://www.nerc.com/pa/Stand/Project_200802_Undervoltage_Load_Shedding_DL/UVLS_Guidelines_approved_by_PC_1.pdf
- [32] S. Dasgupta, M. Paramasivam, U. Vaidya, and V. Ajjarapu, “Real-Time Monitoring of Short-Term Voltage Stability Using PMU Data,” *IEEE Trans.*

پارامتر	معرفی
y_i	کلاس پیش‌بینی شده
p	احتمال پیش‌بینی کلاس
$\sigma(x)$	تابع فعال‌ساز
V_i^p	مقدار ولتاژ شینه i پیش از وقوع خطا
V_i^f	مقدار ولتاژ شینه i بعد از رفع خطا
VD_i	حداقل انحراف ولتاژ در شینه i
N_b	تعداد شینه‌های متصل به PMU
M	پنجره زمانی متحرک
λ	نمای لیاپانوف
Δt	نرخ نمونه‌برداری داده‌های اندازه‌گیری

- ¹ Short-term voltage stability
- ² Extreme learning machines
- ³ Random vector functional link
- ⁴ Recurrent neural network
- ⁵ Convolutional neural network
- ⁶ Graph convolutional network
- ⁷ Long short-term memory
- ⁸ Generative Adversarial Network
- ⁹ Bi-directional gated recurrent unit
- ¹⁰ Updated gate
- ¹¹ Reset gate
- ¹² Convolutional Neural Network