



Estimating the Dynamic Margin of Voltage Stability in Power Systems Using Machine Learning

Mohammadali Alipour^{1*}, Mohmmadreza Jafari²

¹Faculty Member, Department of Electrical Engineering, Technical and Vocational University, Tehran, Iran.

²Faculty Member, Department of Electrical Engineering, Misagh Higher Education Institute, Rafsanjan, Iran.

ARTICLE INFO

ABSTRACT

Article Type:

Original Research

Received: 09.08.2021

Revised: 12.12.2021

Accepted: 01.17.2022

Keyword:

Dynamic Margin of Voltage Stability
Prediction of Voltage Stability
Perceptron Neural Network
Feature Selection Method
Mutual Information

*Corresponding Author:

Mohammadali Alipour

Email: maalipour@tvu.ac.ir

Frequent voltage instabilities in modern power systems are now a concern for power system operators. Voltage stability of power systems can be studied using static and dynamic analyses, based on which voltage stability margins including static boundaries such as maximum loadability and dynamic boundaries such as bifurcation points can be achieved. However, today, with the increasing consumption of electrical energy in power systems, the discussion of voltage stability prediction has become significant. In this paper, using the multilayer neural network of perceptron and a combination of time-domain simulation analyzes, bifurcation analysis, and modal analysis, the dynamic margin of voltage stability based on the Hopf bifurcation boundary was predicted. In this regard, in order to increase the accuracy and speed of training and testing the neural network in predicting the dynamic margin of voltage stability, a feature selection method called mutual information theory was used. The proposed algorithm was investigated on a standard 14-bus test system; and the effect of various static models of power system loads including constant power loads, constant current, and constant impedance were examined.



EXTENDED ABSTRACT

Introduction

Today, frequent voltage instabilities in modern power systems are a concern for power system operators. The voltage stability of power systems can be studied using static and dynamic analysis, and based on this, voltage stability limits can be obtained including static limits such as the maximum load capacity of the power system and dynamic limits such as bifurcation points. In the present research, by using a multi-layer perceptron neural network and combining time domain simulation analysis, bifurcation analysis, and modal analysis, the dynamic limit of voltage stability was predicted based on the Hopf bifurcation boundary. In this regard, in order to increase the accuracy and speed of training as well as test the neural network in predicting the dynamic limit of voltage stability, a feature selection method called mutual information theory was used

Methodology

The application of neural networks in voltage stability can be conventionally summarized into two types of studies. These two types include the prediction of the voltage stability state and the prediction of the voltage stability limit. In this study, in order to reduce the volume of used features and increase the accuracy and speed of the neural network in estimating the dynamic limit of voltage stability, the information theory method was used to select more effective features.

Results and discussion

The proposed algorithm for predicting the dynamic limit of voltage stability was tested on the IEEE 14-bus test system, commonly used in voltage stability studies. In addition, training and test samples were created using dynamic analysis in DIGSILENT software. Table 1 shows the candidate components of the IEEE 14-bus test system. In this table, V_i is the system bus voltage, δ_i is the system bus voltage angle, P_i and Q_{Li} are the active and reactive power of the system loads, and P_{Gi} and Q_{Gi} are the active and reactive power of the system generators, respectively.

Table 1. IEEE 14-bus system candidate components.

Variables	Bus
V	1,2,3,4,5,6,7,8,9,10,11,12,13,14
δ	1,2,3,4,5,6,7,8,9,10,11,12,13,14
PL, QL	2,3,4,5,6, 9,10,11,12,13,14
PG, QG	1,2,3,6,8

Case1

In this experiment, all system loads were considered constant power types. After calculating the correlation coefficient for all features, a limit based on trial and error was used as a feature selection criterion. It is noteworthy that the test and validation errors

were based on the difference between the actual values and predicted by the MLP neural network. In this study, out of a total of 1912 samples created, 312 samples were used for testing and 1600 samples were used for neural network training. Furthermore, out of a total of 1600 samples, 100 samples were used for neural network validation. Table 2 shows the accuracy of the model according to different MIths.

Table 2. Summarizing the results obtained for Case1.

MIth=0.001 - corresponds to not using the component selection method		
test error	Validation error	filtering ratio
4.49% (14 out of 312)	5% (5 out of 100)	60/60=1
MIth=0.396		
test error	Validation error	filtering ratio
2.56% (8 out of 312)	4% (4 out of 100)	60/25=2.4
MIth=0.566		
test error	Validation error	filtering ratio
1.6% (5 out of 312)	2% (2 out of 100)	60/13=4.69
MIth=0.671		
test error	Validation error	filtering ratio
3.2% (10 out of 312)	10% (10 out of 100)	60/11=5.45

According to Table 2, it is clear that the MIth=0.566 criterion with a lower validation error percentage was chosen as the preferred criterion. It can also be concluded from Table 2 that the change in the number of selected features also plays an important role in the accuracy of the model in testing and validation. By increasing the number of features due to the high volume of input, the model learning process was not carried out well. The accuracy of the model decreased and in contrast, by ignoring more features because much system information was lost, its learning was also not carried out well. Based on Table 2, it can be observed that from a total of 60 primary features, the number of features was reduced to 13 features for MIth=0.566. The number of 13 selected features is presented in Table 3.

Table 3. Selected features in Case 1.

MI	Feature	MI	Feature
1	δ6	0.714761	QG2
0.900203	V7	0.695834	QG1
0.842312	PG1	0.67109	δ8
0.828239	δ7	0.67109	V9
0.807421	V6	0.583158	δ9
0.756896	V1	0.566468	V12
0.740498	QG3	-----	-----

Case2

In this case, system loads were considered as a combination of constant power, constant current, and constant impedance loads.

Table 4. Summary of the results for Case2.

Mlth=0.001 - corresponds to not using the component selection method		
test error	Validation error	filtering ratio
3.53% (11 out of 312)	4% (4 out of 100)	60/60=1
Mlth=0.4		
test error	Validation error	filtering ratio
1.6% (5 out of 312)	4% (4 out of 100)	60/19=3.16
Mlth=0.55		
test error	Validation error	filtering ratio
1.6% (5 out of 312)	2% (2 out of 100)	60/16=3.75
Mlth=0.64		
test error	Validation error	filtering ratio
2.88% (9 out of 312)	9% (9 out of 100)	60/10=6

According to Table 4, it is clear that the $Mlth = 0.55$ criterion with a lower validation error percentage was chosen as the optimal criterion. By comparing the results obtained in this step and the results of the previous step, it can be observed that even with the complexity of the system characteristics, the presented algorithm determines the dynamic limit of voltage stability with acceptable accuracy.

Conclusion

In the current study, using a combined analysis, the dynamic limit of voltage stability corresponding to the HB boundary was predicted. In order to reduce the amount of information and increase the accuracy of the neural network, the component selection method based on the mutual information theory was used. The results of different simulation methods showed that the correct selection of the number of features increased the accuracy of the prediction model of the dynamic limit of system stability.

تخمین حد دینامیکی پایداری ولتاژ در سیستم‌های قدرت با استفاده از یادگیری ماشین

محمدعلی علیپور^{۱*}، محمدرضا جعفری^۲

- ۱- عضو هیات علمی، گروه مهندسی برق، دانشگاه فنی و حرفه‌ای، تهران، ایران.
- ۲- عضو هیات علمی، گروه مهندسی برق، موسسه آموزش عالی میثاق، رفسنجان، ایران.

چکیده

اطلاعات مقاله

امروزه ناپایداری‌های مکرر ولتاژ در سیستم‌های قدرت مدرن، یک نگرانی برای بهره‌برداران سیستم‌های قدرت محسوب می‌شود. پایداری ولتاژ سیستم‌های قدرت را می‌توان با استفاده از تحلیل‌های استاتیکی و دینامیکی مطالعه کرد و براساس آن به مرزهای پایداری ولتاژ شامل مرزهای استاتیکی مانند بیشینه بارپذیری سیستم قدرت و مرزهای دینامیکی مانند نقاط دوشاخگی دست یافت. با این حال، امروزه با افزایش مصرف انرژی الکتریکی در سیستم‌های قدرت، بحث پیش‌بینی به‌هنگام پایداری ولتاژ، اهمیت چشمگیری پیدا کرده است. در این مقاله، با استفاده از شبکه عصبی چندلایه پرسپترون و ترکیب تحلیل‌های شبیه‌سازی حوزه زمان، تحلیل دوشاخگی و تحلیل مدال، حد دینامیکی پایداری ولتاژ براساس مرز انشعاب هاپف پیش‌بینی شده است. در این راستا به‌منظور افزایش دقت و سرعت آموزش و نیز آزمون شبکه عصبی در پیش‌بینی حد دینامیکی پایداری ولتاژ از یک روش انتخاب مؤلفه تحت عنوان تئوری اطلاعات متقابل استفاده شده است. الگوریتم ارائه‌شده بر سیستم آزمون ۱۴ با سه استاندارد بررسی گردید و تأثیر انواع مدل‌های استاتیکی بارهای سیستم قدرت شامل بارهای توان ثابت، جریان ثابت و امپدانس ثابت بر قابلیت الگوریتم پیشنهادی بررسی شد.

نوع مقاله: مقاله پژوهشی

دریافت مقاله: ۱۴۰۰/۰۶/۱۷

بازنگری مقاله: ۱۴۰۰/۰۹/۲۱

پذیرش مقاله: ۱۴۰۰/۱۰/۲۷

کلید واژگان:

حد دینامیکی پایداری ولتاژ
پیش‌بینی پایداری ولتاژ
شبکه عصبی پرسپترون
روش انتخاب مؤلفه
اطلاعات متقابل

*نویسنده مسئول: محمدعلی علیپور

پست الکترونیکی:

maalipour@tvu.ac.ir

مقدمه

امروزه مدیریت و کنترل سیستم‌های قدرت به دلیل افزایش تولید و مصرف، یک معضل می‌باشد [۱]. مطالعات نشان می‌دهد که این پدیده می‌تواند بر روند پایداری سیستم‌های به هم پیوسته تأثیرگذار باشد؛ از این رو مطالعه پایداری ولتاژ در سیستم‌های قدرت مورد توجه بیشتر محققان این حوزه بوده است [۲-۸]. ناپایداری ولتاژ در سیستم‌های قدرت منجر به فروپاشی ولتاژ و در نهایت در صورتی که برطرف نشود باعث از هم گسیختگی سیستم‌های قدرت به هم پیوسته و خاموشی‌های پی‌درپی می‌شود [۲]. از این رو یکی از مهم‌ترین مباحث تحقیقات علمی در مورد مسئله پایداری ولتاژ، پیش‌بینی شاخص‌هایی برای وقوع فروپاشی ولتاژ می‌باشد [۹-۱۲]. این شاخص‌ها در نیروگاه‌ها معیاری برای تعیین میزان نزدیکی به نقطه شکست ولتاژ هستند که اندازه آنها با پارامترهای کنترلی سیستم، قابل تغییر می‌باشد [۱۳؛ ۱۴]. پایداری ولتاژ سیستم‌های قدرت را می‌توان با استفاده از تحلیل‌های استاتیکی یا دینامیکی بررسی کرد. تحلیل‌های استاتیکی، تحلیل‌هایی مبتنی بر پخش بار سیستم می‌باشد و با استفاده از این آنالیزها، حد استاتیکی پایداری ولتاژ یا همان بیشینه بارپذیری^۱ سیستم قدرت قابل دستیابی خواهد بود [۱۵-۱۷]. در تحلیل‌های دینامیکی که مبتنی بر شبیه‌سازی حوزه زمان^۲ و تئوری دوشاخگی^۳ می‌باشند تأثیر تجهیزات مختلف در نتایج به دست آمده از مطالعه سیستم به وضوح محسوس است. براساس تحلیل‌های دینامیکی، مرزهای دوشاخگی پایداری ولتاژ از قبیل^۴ SNB،^۵ HB و^۶ LIB که با استفاده از ژاکوبین جبری-دینامیکی سیستم قدرت قابل دستیابی می‌باشند، بررسی می‌شوند [۱۸-۲۱]. مهم‌ترین تفاوت آنالیز استاتیکی و دینامیکی، در کیفیت مطالعه این روش‌ها می‌باشد. به عبارتی بهتر، در آنالیزهای استاتیکی از دینامیک‌های سیستم قدرت مانند دینامیک سیستم‌های تحریک، پایداری سیستم قدرت و ...، صرف نظر می‌شود. این موضوع سبب می‌شود که رفتار واقعی سیستم با استفاده از این آنالیزها به خوبی بررسی نشود. این مورد به ویژه در حالتی که بارهای سیستم غیر توان ثابت باشند، مصداق بیشتری پیدا می‌کند [۱۵]. در نتیجه استفاده از تحلیل‌های دینامیکی که عموماً مبتنی بر تئوری دوشاخگی می‌باشند، در تحلیل پایداری ولتاژ سیستم‌های قدرت، کاربرد گسترده‌ای پیدا کرده است. در زمینه تحلیل دینامیکی پایداری ولتاژ، تحقیقات مختلفی ارائه شده است [۱۸-۲۱]. در این مقالات، مرزهای مختلف پایداری ولتاژ سیستم قدرت از قبیل HB و SNB بررسی شده است. امروزه به منظور بررسی دقیق و سریع وضعیت پایداری ولتاژ سیستم قدرت، استفاده از یادگیری ماشین، کاربرد گسترده‌ای در مطالعات سیستم‌های قدرت پیدا کرده است [۲۲-۲۴]. از طرفی با افزایش نفوذ منابع تولید پراکنده در سیستم‌های قدرت، استفاده از الگوریتم‌های فراابتکاری در کنترل و پایداری سیستم‌های قدرت، توسعه پیدا کرده است [۲۵]. در منابع [۲۶؛ ۲۷]، حد استاتیکی پایداری ولتاژ براساس شاخص استاتیکی PTSI^۷ و با استفاده از شبکه‌های عصبی MLP و SVM پیش‌بینی شده است. شاخص PTSI، مبتنی بر تحلیل پخش بار می‌باشد و در شرایطی که سیستم دچار فروپاشی شده باشد، مقدار این شاخص ۱ و در غیر این صورت کمتر از ۱ می‌باشد. در [۲۸] با استفاده از شبکه عصبی MLP و تحلیل استاتیکی پخش بار، حد توان اکتیو (Pmargin) پیش‌بینی شده است. در این مقاله حد توان اکتیو فاصله میان بار فعلی سیستم و سطح بار، منجر به فروپاشی ولتاژ (نقطه پیشانی منحنی P-V) در نظر گرفته شده است. مقدار شاخص استاتیکی L با استفاده از شبکه عصبی FFNN^۸ در منبع [۲۹] پیش‌بینی

¹ Maximum Loadability Point (MLP)

² Time Domain Simulation (TDS)

³ Bifurcation Theory

⁴ Saddle Node Bifurcation (SNB)

⁵ Hopf Bifurcation (HB)

⁶ Limit Induced Bifurcation (LIB)

⁷ Power Transfer Stability Index (PTSI)

⁸ Feed Forward Neural Network (FFNN)

شده است. در این راستا مؤلفه‌های به‌کاررفته شده برای آموزش شبکه عصبی شامل دامنه ولتاژ، توان اکتیو و توان راکتیو بارها و ژنراتورهای سیستم می‌باشد. بنابراین، براساس آنچه بیان شد ملاحظه می‌شود که بیشتر مقالاتی که در زمینه پیش‌بینی حد پایداری ولتاژ هستند، به دنبال پیش‌بینی حد استاتیکی پایداری^۱ ولتاژ می‌باشند و به عبارتی، مبتنی بر تحلیل‌های استاتیکی پایداری ولتاژ مانند روش پخش بار متوالی^۲ هستند [۲۶-۲۹]. بنابراین، برخلاف بیشتر مقالاتی که با استفاده از تحلیل‌های استاتیکی، حد پایداری ولتاژ را پیش‌بینی کرده‌اند و با توجه به معایبی که روش‌های استاتیکی در بررسی پایداری ولتاژ دارند، در این مقاله حد پایداری ولتاژ بر اساس مرز HB پیش‌بینی شده است. بدین منظور تولید نمونه‌های موردنیاز برای آموزش و آزمون شبکه عصبی با استفاده از شبیه‌سازی حوزه زمان و به عبارتی بهتر، در محیط دینامیکی صورت می‌گیرد. در نهایت با استفاده از روش انتخاب مؤلفه و شبکه عصبی MLP^۳، حد دینامیکی پایداری ولتاژ براساس مرز HB پیش‌بینی شده است. این موضوع، یکی از قابلیت‌های اصلی و برتری‌های این مقاله در مقایسه با مقالات دیگری است که در این زمینه وجود دارد. در این راستا، قابلیت روش ارائه‌شده با تغییر مدل بار سیستم ارزیابی شده است. حد دینامیکی پایداری ولتاژ^۴ فاصله میان نقطه کار سیستم و بارگذاری منجر به HB در سیستم می‌باشد [۲۱].

در ادامه، ساختار مقاله دسته‌بندی شده است طوری که در بخش ۲، شاخص منحنی P-V و در بخش ۳ مدل‌های بار و در بخش‌های ۴ و ۵ به ترتیب شرح الگوریتم پیشنهادی و نتایج شبیه‌سازی بیان شده و در نهایت در بخش ۶ نتیجه‌گیری صورت گرفته است.

شاخص منحنی P-V


منحنی P-V یکی از کاربردی‌ترین منحنی‌ها برای بررسی وضعیت پایداری ولتاژ سیستم‌های قدرت می‌باشد که در حقیقت به‌منظور تعیین حد بارگذاری سیستم قدرت به‌کار می‌رود. در ترسیم این منحنی، بار سیستم به‌صورت مرحله‌ای افزایش می‌یابد و به‌ازای هر سطح بار جدید، پخش بار سیستم صورت می‌گیرد و نقطه کار سیستم تعیین می‌شود. این وضعیت تا جایی ادامه پیدا می‌کند که منحنی به نقطه پیشانی خود برسد. فاصله میان نقطه کار سیستم و نقطه فروپاشی ولتاژ به‌عنوان حد بارگذاری سیستم در نظر گرفته می‌شود که معیاری برای تعیین وضعیت پایداری ولتاژ سیستم می‌باشد. شکل ۱ منحنی P-V را نشان می‌دهد [۳۰].

¹ Static Voltage Stability Margin (SVSM)

² Continuation Power Flow (CPF)

³ Multilayer perceptron

⁴ Dynamic Loading Margin (DLM) or Dynamic Voltage Stability Margin (DVSM)



شکل ۱. منحنی P-V.

مدل‌های بار در سیستم‌های قدرت

در سیستم‌های قدرت، به‌طور مرسوم بارها به دو دسته بارهای استاتیکی و بارهای دینامیکی تقسیم می‌شوند [۳۰].

مدل‌های بار استاتیکی

یکی از انواع مرسوم بارهای سیستم‌های قدرت، بارهای استاتیکی هستند که شامل انواع بارهای توان ثابت (P)، جریان ثابت (I) و امپدانس ثابت (Z) می‌باشند. این نوع از بارها می‌توانند به‌صورت مجزا یا ترکیبی (مثلاً مدل ZIP) مدل شوند. وابستگی توان‌های اکتیو و راکتیو بارهای استاتیکی به فرکانس و ولتاژ معمولاً به‌صورت معادلات جبری نمایش داده می‌شوند که این معادلات در رابطه (۱) و (۲) بیان شده‌اند [۳۰].

$$P = P_0 \left(\frac{V}{V_0} \right)^{\alpha_V} \left(\frac{\omega}{\omega_0} \right)^{\alpha_\omega} \quad (1)$$

$$Q = Q_0 \left(\frac{V}{V_0} \right)^{\beta_V} \left(\frac{\omega}{\omega_0} \right)^{\beta_\omega} \quad (2)$$

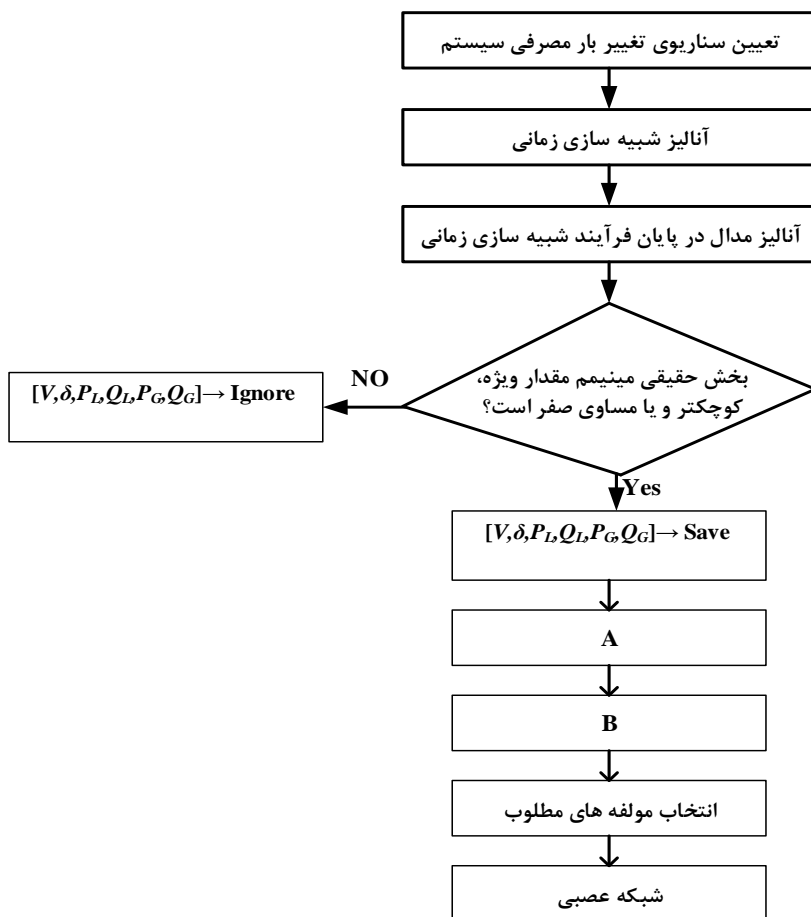
البته در مطالعات پایداری ولتاژ معمولاً وابستگی توان‌های اکتیو و راکتیو به فرکانس قابل صرف‌نظر کردن است $(\alpha_\omega, \beta_\omega)$. مقادیر (α_V, β_V) برای انواع بارها متفاوت می‌باشد.

مدل بارهای دینامیکی

امروزه بخش گسترده‌ای از مصرف توان الکتریکی در سیستم قدرت را موتورهای الکتریکی تشکیل می‌دهند؛ از این رو مدل کردن دقیق موتورها برای مطالعات سیستم، امری لازم و اصلی اساسی در مطالعات پایداری ولتاژ می‌باشد؛ در واقع موتورهای الکتریکی مانند موتورهای القایی نمونه‌ای از بارهای دینامیکی هستند [۳۰].

تشریح مسئله پیش‌بینی حد دینامیکی پایداری ولتاژ و الگوریتم پیشنهادی

کاربرد شبکه‌های عصبی در پایداری ولتاژ را می‌توان به‌طور مرسوم در دو نوع مطالعه خلاصه کرد. این دو نوع شامل پیش‌بینی وضعیت پایداری ولتاژ و پیش‌بینی حد پایداری ولتاژ می‌باشد. در پیش‌بینی وضعیت پایداری ولتاژ، به دنبال این موضع می‌باشیم که آیا به‌ازای نقطه کار احتمالی سیستم، پایداری ولتاژ در سیستم برقرار است یا نه. نمونه‌ای از این نوع مطالعات را می‌توان در [۲۳] مشاهده کرد. به عبارتی بهتر، با فرض اینکه $\{y_1, y_2, \dots, y_m\}$ ورودی‌های منتخب به شبکه عصبی به‌منظور پیش‌بینی پایداری ولتاژ باشند و Z خروجی شبکه عصبی آموزش‌دیده باشد آن‌گاه برحسب مقداری که اختیار می‌کند وضعیت سیستم را از حیث پایداری مشخص می‌کند؛ برای مثال اگر مقدار Z یک باشد؛ سیستم پایدار و اگر مقدار آن دو باشد، سیستم ناپایدار است. در نقطه مقابل، در پیش‌بینی حد پایداری ولتاژ، به دنبال این حقیقت می‌باشیم که فاصله میان نقطه کار موجود (Li) تا مرز ناپایداری ($L_{critical}$) به چه میزان است. بنابراین، شبکه عصبی باید این مقدار را پیش‌بینی کند. این موضوع در اصطلاح رگرسیون نامیده می‌شود. این مرز می‌تواند مرز استاتیکی مانند MLP یا مرز دینامیکی مانند SNB یا HB باشد. در این مقاله، مرز ناپایداری ولتاژ، مرز HB در نظر گرفته می‌شود. نقطه دوشاخگی HB، متناظر با حالتی است که یک زوج مد مختلط سیستم بر محور موهومی صفحه اعداد مختلط قرار می‌گیرد [۲۱-۱۸]. در این حالت، نسبت میرایی زوج مدی که روی محور موهومی واقع شده است، صفر می‌شود و به عبارتی بهتر، قسمت حقیقی زوج مد بحرانی سیستم که بر روی محور موهومی واقع شده است، صفر می‌شود. در این مقاله، حد دینامیکی پایداری ولتاژ با استفاده از یک تحلیل ترکیبی شامل شبیه‌سازی حوزه زمان، تحلیل مدال، تئوری دوشاخگی، روش انتخاب مؤلفه و شبکه عصبی پیش‌بینی شده است. به عبارتی بهتر، خروجی شبکه عصبی MLP، مقدار DLM برای هر نقطه کار سیستم خواهد بود. فلوجارت الگوریتم پیشنهادی در شکل ۲ آورده شده است.



شکل ۲. الگوریتم پیشنهادی به منظور پیش‌بینی حد دینامیکی پایداری ولتاژ براساس مرز HB.

A, B از روابط زیر تعیین می‌شوند:

$$\begin{array}{cc}
 \text{FEATURE} & \text{TARGET} \\
 \left[\begin{array}{c} (V, \delta, P_G, Q_G, P_L, Q_L)_1 \\ (V, \delta, P_G, Q_G, P_L, Q_L)_2 \\ \vdots \\ (V, \delta, P_G, Q_G, P_L, Q_L)_{n-1} \\ (V, \delta, P_G, Q_G, P_L, Q_L)_n \end{array} \right] & \rightarrow \left[\begin{array}{c} DLM_1 \\ DLM_2 \\ \vdots \\ DLM_{n-1} \\ DLM_n \end{array} \right] \quad (3)
 \end{array}$$

$$B = \begin{bmatrix} MI\{V, \delta, P_G, Q_G, P_L, Q_L\}_1, DLM_1\} > MI_{Th} \\ MI\{V, \delta, P_G, Q_G, P_L, Q_L\}_2, DLM_2\} > MI_{Th} \\ \vdots \\ MI\{V, \delta, P_G, Q_G, P_L, Q_L\}_{n-1}, DLM_{n-1}\} > MI_{Th} \\ MI\{V, \delta, P_G, Q_G, P_L, Q_L\}_n, DLM_n\} > MI_{Th} \end{bmatrix} \quad (۴)$$

در شکل ۲، چگونگی پیش‌بینی حد دینامیکی پایداری ولتاژ براساس الگوریتم پیشنهادی تشریح شده است. بر این اساس ملاحظه می‌شود که اختلاف هر بارگذاری سیستم و بار منجر به HB به‌عنوان یک حد بارگذاری دینامیکی (DLM) تعریف شده که این حد بارگذاری همان ستون هدف^۱ می‌باشد که شبکه عصبی باید مقادیر این ستون را به‌ازای نمونه‌های آزمون^۲ تشخیص دهد. همچنین، تولید هر کدام از نمونه‌های بیان شده در شکل ۲ $([V, \delta, P_L, Q_L, P_G, Q_G])$ ، با استفاده از شبیه‌سازی حوزه زمان و به‌ازای تغییرات بار هر باس یا مجموعه‌ای از باس‌ها به‌صورت تصادفی و از مقدار پایه تا بارگذاری منجر به HB صورت می‌گیرد. در شکل ۲، دامنه ولتاژ باس‌های سیستم، δ زاویه ولتاژ باس‌های سیستم، PL و QL به‌ترتیب توان اکتیو و راکتیو بارهای سیستم و PG و QG توان اکتیو و راکتیو ژنراتورهای سیستم می‌باشند. این مؤلفه‌ها^۳ به‌عنوان مؤلفه‌های اصلی در آموزش شبکه عصبی مورد استفاده قرار خواهد گرفت. اگر Ln مجموع توان ظاهری (MVA) بارهای سیستم در nامین نقطه کار و LHB مجموع توان ظاهری بارهای سیستم در نقطه وقوع HB باشد برای یک سیستم با تعداد L باس بار حد دینامیکی پایداری ولتاژ برای nامین نقطه کار سیستم براساس رابطه (۳) تعریف می‌گردد.

$$DLM_n = L_{HB} - L_n \quad (۵)$$

$$L_n = \sqrt{\left(\sum_1^L P_i\right)^2_n + \left(\sum_1^L Q_i\right)^2_n} \quad (۶)$$

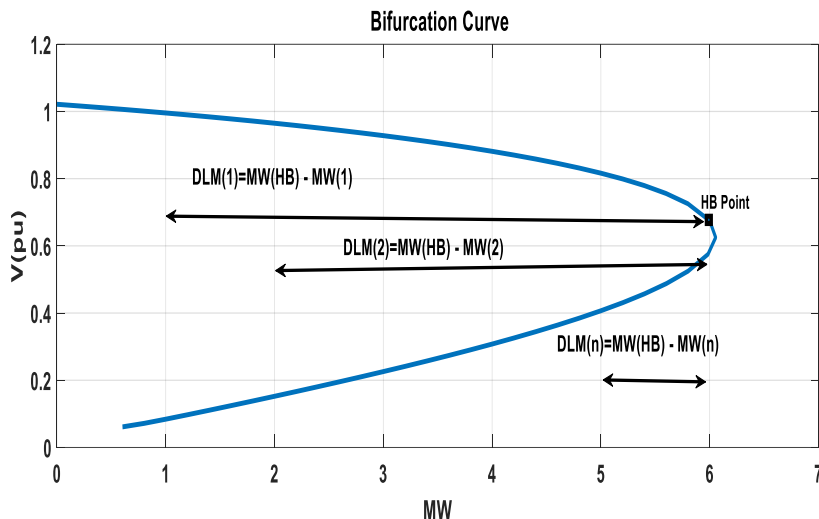
$$L_{HB} = \sqrt{\left(\sum_1^L P_i\right)^2_{HB} + \left(\sum_1^L Q_i\right)^2_{HB}} \quad (۷)$$

شایان ذکر است که هر سناریوی تغییر بار در سیستم دارای HB متناظر با خود می‌باشد. برای مثال، بار باس i از مقدار پایه تا مقدار متناظر با وقوع HB تغییر می‌کند. بنابراین در طول این تغییرات، فاصله بین هر نقطه کار و نقطه وقوع HB به‌عنوان یک DLM برای آن سناریوی تغییر بار لحاظ می‌شود.

¹ Target

² Test Samples

³ Features



شکل ۳. چگونگی تعیین DLM برای هر سناریوی بار و هر نقطه کار سیستم.

از سویی دیگر، برحسب اندازه سیستم مورد مطالعه تعداد مؤلفه‌ها نیز تغییر می‌کند. برای مثال، در سیستم ۱۴ باسه IEEE تعداد کل مؤلفه‌ها براساس مؤلفه‌های بیان شده $[V, \delta, P_L, Q_L, P_G, Q_G]$ ، ۶۰ مؤلفه شامل ۲۲ مؤلفه توان اکتیو و راکتیو بارها، ۱۰ مؤلفه توان اکتیو و راکتیو ژنراتورها و ۲۸ مؤلفه اندازه و زاویه ولتاژ باس‌ها می‌باشد. بدیهی است که در سیستم‌های بزرگ‌تر، حجم این اطلاعات افزایش می‌یابد. افزایش حجم مؤلفه‌ها، علاوه بر افزایش زمان آموزش و آزمون شبکه عصبی، بر دقت شبکه نیز تأثیرگذار است و در نتیجه، استفاده از تمامی مؤلفه‌های مذکور به‌منظور آموزش یا آزمون شبکه‌های عصبی چندان مطلوب نیست؛ بنابراین از روش انتخاب ویژگی برای انتخاب مؤلفه‌های مؤثرتر بهره برده شده است.

انتخاب ویژگی بر مبنای تئوری اطلاعات

در این مقاله به‌منظور کاهش حجم مؤلفه‌های مورد استفاده و افزایش دقت و سرعت شبکه عصبی در پیش‌بینی حد دینامیکی پایداری ولتاژ، از روش تئوری اطلاعات^۱ (MI) برای انتخاب مؤلفه‌های مؤثرتر استفاده شده است. براساس این قضیه می‌توان مؤلفه‌هایی که بیشترین همبستگی با خروجی مدل را دارند انتخاب کرد و از آنها برای اعمال به شبکه عصبی استفاده کرد. از رابطه ریاضی (۸) برای محاسبه MI بین دو متغیر x, y استفاده می‌شود.

$$I(x; y) = \iint p(x, y) \cdot \log \frac{p(x, y)}{p(x)p(y)} dx dy \quad (۸)$$


در رابطه (۸) $p(x), p(y)$ به ترتیب توابع احتمال متغیرهای x, y و $p(x, y)$ نیز تابع احتمال توأم متغیرهای x, y می‌باشد. فرض کنید $\{x_{j1}, x_{j2}, \dots, x_{jn}\}$ ماتریس اولیه سیستم است. در این ماتریس j تعداد نمونه‌های ایجاد شده و n تعداد مؤلفه‌های هر نمونه است. از سویی دیگر، هر مجموعه نمونه ایجاد شده دارای یک مقدار j DLM می‌باشد.

¹ Mutual information

بر اساس الگوریتم تئوری اطلاعات، هرچه همبستگی میان هر مؤلفه هر نمونه $(x_{ji}; i=1:m)$ و حد دینامیکی متناظر با آن نمونه (DLM_i) بیشتر باشد، آن مؤلفه، مؤلفه‌ای مطلوب شناخته می‌شود و به شبکه عصبی به منظور آموزش و آزمون اعمال می‌شود. به عبارتی، مؤلفه‌ای مطلوب است که شرط رابطه (۹) را برآورده کند.

$$MI(x_{ji}, DLM_i) > MI_{th} \quad (9)$$

در رابطه ۹، MI_{th} مقدار آستانه‌ای است که کاربر تعیین می‌شود ($MI < 1 > 0$). بدیهی است که اگر میزان همبستگی هر مؤلفه کمتر از مقدار MI_{th} باشد، آن مؤلفه حذف خواهد شد. در نهایت، ماتریس مؤلفه‌های مطلوب به شبکه عصبی MLP برای پیش‌بینی حد دینامیکی پایداری ولتاژ اعمال می‌شود. معماری شبکه عصبی MLP در شکل ۴ آورده شده است.



شکل ۴. ساختار یک شبکه عصبی MLP با دو لایه میانی.

در شکل ۴، ساختار شبکه عصبی MLP نشان داده شده است. با توجه به این شکل، ماتریس ورودی به شبکه عصبی همان مؤلفه‌های پیش‌گفته $([V, \delta, P_L, Q_L, P_G, Q_G])$ می‌باشد و ماتریس خروجی شبکه عصبی نیز میزان پیش‌بینی MDL به‌ازای هر ورودی می‌باشند. در اینجا ماتریس خروجی همان DLM سیستم می‌باشد. میزان دقت شبکه عصبی براساس رابطه (۱۰) تعیین می‌شود.

$$\Delta DLM_j = (\text{Predicted DLM})_j - (\text{Real DLM})_j \quad (10)$$

در رابطه ۱۰، $(\text{Real DLM})_j$ مقدار واقعی حد دینامیکی پایداری ولتاژ برای نمونه ژام است که براساس تحلیل‌های شبیه‌سازی حوزه زمان، مدال و تئوری دوشاخگی و با استفاده از نرم‌افزار DigSILENT به‌دست آمده است. همچنین، $(\text{Predicted DLM})_j$ مقدار پیش‌بینی شده حد دینامیکی پایداری ولتاژ برای نمونه ژام است که براساس خروجی شبکه عصبی آموزش دیده به‌دست آمده است. حال اگر مقدار ΔDLM_j از یک مقدار آستانه Th بیشتر باشد، خطا در نظر گرفته خواهد شد.

نتایج شبیه‌سازی

الگوریتم ارائه شده برای پیش‌بینی حد دینامیکی پایداری ولتاژ، روی سیستم آزمون ۱۴ باسه IEEE که به‌طور مرسوم در مطالعات پایداری ولتاژ استفاده می‌شود [۲۳]، آزمایش خواهد شد. همچنین، اطلاعات استاتیکی و دینامیکی سیستم آزمون مذکور را می‌توان از منبع، برداشت کرد. علاوه بر این، نمونه‌های آموزش و آزمون با استفاده از تحلیل دینامیکی در نرم‌افزار DigSILENT ایجاد شده است.

در جدول ۱، مؤلفه‌های کاندید سیستم آزمون ۱۴ باسه IEEE، نشان داده شده است. در این جدول، V_i ولتاژ باس‌های سیستم، δ_i زاویه ولتاژ باس‌های سیستم، P_{Li} و Q_{Li} به ترتیب توان اکتیو و راکتیو بارهای سیستم و P_{Gi} و Q_{Gi} به ترتیب توان اکتیو و راکتیو ژنراتورهای سیستم می‌باشند.

جدول ۱. مؤلفه‌های کاندید سیستم ۱۴ باسه IEEE.

متغیر	باس
V	۱-۲-۳-۴-۵-۶-۷-۸-۹-۱۰-۱۱-۱۲-۱۳-۱۴
Δ	۱-۲-۳-۴-۵-۶-۷-۸-۹-۱۰-۱۱-۱۲-۱۳-۱۴
P_Load, Q_Load	۲-۳-۴-۵-۶-۹-۱۰-۱۱-۱۲-۱۳-۱۴
P_G, Q_G	۱-۲-۳-۶-۸

به‌منظور آموزش و آزمون شبکه عصبی MLP، از مجموع ۱۹۱۲ نمونه تولیدشده، ۳۱۲ نمونه برای آزمون و ۱۶۰۰ نمونه برای آموزش شبکه عصبی استفاده شد. این انتخاب‌ها به‌صورت کاملاً تصادفی صورت گرفته است. به‌منظور تولید ۱۹۱۲ نمونه یاد شده، بارهای سیستم در سناریوهای مختلفی تغییر یافته‌اند. برخی از سناریوهای اعمالی در جدول ۲ بیان شده است.

جدول ۲. سناریوهای مختلف تولید نمونه در سیستم ۱۴ باسه IEEE.

تغییر تمام بارهای سیستم به‌صورت هم‌زمان	تغییر بار باس ۲	تغییر بار باس‌های ۲، ۳ و ۴
تغییر بار باس‌های ۲، ۵، ۹ و ۱۲	تغییر بار باس‌های ۲ و ۱۴	تغییر بار باس ۳
تغییر بار باس ۴	تغییر بار باس‌های ۵، ۹ و ۱۲	تغییر بار باس‌های ۵، ۱۰، ۱۱ و ۱۴
تغییر بار باس ۶	تغییر بار باس‌های ۶ و ۱۱	تغییر بار باس‌های ۶ و ۱۳
تغییر بار باس ۹	تغییر بار باس ۱۰	تغییر بار باس ۱۱
تغییر بار باس ۱۲	تغییر بار باس ۱۳	تغییر بار باس ۱۴

آزمایش حالت ۱

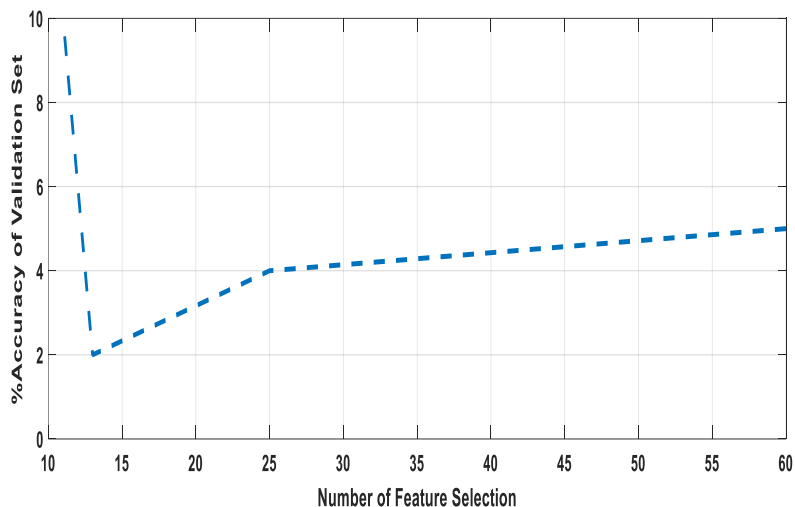
در این آزمایش، تمام بارهای سیستم از نوع توان ثابت در نظر گرفته شدند. در بررسی‌های این مرحله، تعداد کل نمونه‌های ایجادشده ۱۹۱۲ است که از این تعداد ۳۱۲ نمونه به‌منظور آزمون شبکه عصبی استفاده شد. پس از محاسبه ضریب همبستگی برای تمام ویژگی‌ها، یک حد براساس سعی و خطا به‌عنوان معیار انتخاب ویژگی‌ها استفاده شده است. برای دستیابی به بهترین پاسخ، لازم است که پارامتر MI به بهترین شکل تنظیم گردد. بدین منظور از روش ۱۰-Fold Cross-validation استفاده گردید. بر این اساس، به‌صورت تصادفی، مجموعه آموزش به ۱۰ زیرمجموعه تقسیم شد. هر زیرمجموعه، یک Validation Set در نظر گرفته شد و بقیه مجموعه‌ها، مجموعه آموزش انتخاب شدند. بر این اساس، شبکه را آموزش می‌دهیم و خطای هر Validation Set را می‌یابیم. مجموعه مقادیر به‌دست‌آمده برای پارامترهای بیان‌شده که کمترین خطای Validation را بدهد، در نهایت انتخاب می‌شود. شایان ذکر است که خطای

آزمون و خطای ولیدیشن براساس اختلاف میان مقادیر واقعی و پیش‌بینی شده توسط شبکه عصبی MLP تعیین می‌شود. اگر مقدار این اختلاف از Th که با سعی و خطا تعریف شده (در اینجا ۰/۱۵) بیشتر باشد، یک خطا رخ داده است. در این مطالعه، از مجموع ۱۹۱۲ نمونه ایجاد شده، ۳۱۲ نمونه به منظور آزمون و ۱۶۰۰ نمونه به منظور آموزش شبکه عصبی استفاده می‌گردد. همچنین، از مجموع ۱۶۰۰ نمونه، ۱۰۰ نمونه به منظور ولیدیشن شبکه عصبی استفاده خواهد شد. جدول ۳ دقت مدل را به‌ازای MIth‌های مختلف نشان می‌دهد.

جدول ۳. جمع‌بندی نتایج به‌دست آمده از نسبت فیلترینگ و خطای پیش‌بینی وضعیت دینامیکی پایداری ولتاژ به‌ازای MI‌های مختلف برای بارهای توان ثابت.

MI _{th} =0.001 - متناظر با استفاده نکردن از روش انتخاب مؤلفه		
نسبت فیلترینگ	خطای اعتبارسنجی	خطای آزمون
۶۰/۶۰=۱	۵% (۵ out of ۱۰۰)	۴.۴۹% (۱۴ out of ۳۱۲)
MI _{th} =۰.۳۹۶		
نسبت فیلترینگ	خطای اعتبارسنجی	خطای تست
۶۰/۲۵=۲.۴	۴% (۴ out of ۱۰۰)	۲.۵۶% (۸ out of ۳۱۲)
MI _{th} =۰.۵۶۶		
نسبت فیلترینگ	خطای اعتبارسنجی	خطای آزمون
۶۰/۱۳=۴.۶۹	۲% (۲ out of ۱۰۰)	۱.۶% (۵ out of ۳۱۲)
MI _{th} =۰.۶۷۱		
نسبت فیلترینگ	خطای اعتبارسنجی	خطای آزمون
۶۰/۱=۶۰	۱۰% (۱۰ out of ۱۰۰)	۳.۲% (۱۰ out of ۳۱۲)

طبق جدول ۳ مشخص می‌شود که معیار MI_{th}=۰/۵۶۶ با درصد خطای اعتبارسنجی کمتر به‌عنوان معیار مطلوب انتخاب می‌شود. همچنین از جدول ۳ می‌توان استنباط کرد که تغییر در تعداد ویژگی‌های انتخابی نیز بر دقت مدل در آزمون و اعتبارسنجی نقش مهمی دارد. با افزایش تعداد ویژگی‌ها به علت حجم بالای ورودی چون عمل یادگیری مدل به‌خوبی انجام نمی‌شود دقت مدل کاهش می‌یابد و برعکس با نادیده‌گرفتن ویژگی‌های بیشتر، چون بسیاری از اطلاعات سیستم از دست می‌رود یادگیری آن نیز به‌خوبی انجام نمی‌شود. همان‌گونه که در شکل ۵ نیز آورده شده برای آزمایش ۱ با تعداد ویژگی ۱۳، مدل از اعتبار بیشتری برخوردار است؛ زیرا دقت داده‌های اعتبارسنجی آن حدود ۲ درصد می‌باشد. شکل ۵ تأثیر تعداد ویژگی‌ها بر دقت مدل نشان داده شده است.



شکل ۵. تأثیر تعداد ویژگی‌ها بر دقت مدل.

بر اساس آنچه در جدول ۴ بیان شده است ملاحظه می‌شود که از مجموع ۶۰ مؤلفه اولیه، با استفاده از روش انتخاب مؤلفه ارائه‌شده به‌ازای معیار $MI_{th}=0/566$ تعداد نمونه‌ها به ۱۳ مؤلفه کاهش یافت که در جدول (۵) آورده شده است. با استفاده از این مؤلفه‌ها، شبکه عصبی آموزش می‌بیند و آزمون می‌شود.

جدول ۴. همبستگی میان مؤلفه‌های سیستم و مقدار Target در آزمایش حالت ۱.


مؤلفه	MI	مؤلفه	MI	مؤلفه	MI
V ₄	۰.۴۳۳۵۴۱	V ₉	۰.۶۷۱۰۹	δ ₆	۱
V ₅	۰.۴۲۸۸۳۶	δ ₉	۰.۵۸۳۱۵۸	V ₇	۰.۹۰۰۲۰۳
V ₈	۰.۴۲۴۱۶	V ₁₂	۰.۵۶۶۴۶۸	P _{G1}	۰.۸۴۲۳۱۲
V ₃	۰.۴۲۴۱۶	δ ₁₂	۰.۵۳۹۲۸۳	δ ₇	۰.۸۲۸۲۳۹
δ ₄	۰.۳۹۶۷۱۱	V ₁₄	۰.۵۲۳۳۴۶	V ₆	۰.۸۰۷۴۲۱
P _{L10}	۰.۳۲۸۵۰۶	δ ₅	۰.۵۲۳۳۴۶	V ₁	۰.۷۵۶۸۹۶
Q _{L10}	۰.۳۲۸۵۰۶	V ₁₃	۰.۵۱۲۸۸۱	Q _{G3}	۰.۷۴۰۴۹۸
P _{L3}	۰.۳۱۶۵۰۷	δ ₃	۰.۴۹۷۴۱۵	Q _{G2}	۰.۷۱۴۷۶۱
Q _{L3}	۰.۳۱۲۵۶۲	V ₂	۰.۴۷۴۷۳۹	Q _{G1}	۰.۶۹۵۸۳۴
V ₁₁	۰.۲۹۲۲۴۲	δ ₁₃	۰.۴۵۲۶۵۷	δ ₈	۰.۶۷۱۰۹
δ ₁	۰.۰۶۷۳۰۸	Q _{L13}	۰.۱۹۴۱۶۷	P _{L6}	۰.۲۶۰۱۵۱
P _{L14}	۰.۰۵۷۹۸۶	Q _{G8}	۰.۱۹۴۱۶۷	P _{L11}	۰.۲۶۰۱۴۹
Q _{L14}	۰.۰۵۷۹۸۶	Q _{G6}	۰.۱۷۹۲۶۳	Q _{L11}	۰.۲۶۰۱۴۹
V ₁₀	۰.۰۵۵۵۶۶	P _{L12}	۰.۱۷۳۴۷۷	Q _{L6}	۰.۲۵۸۳۷۴

مؤلفه	MI	مؤلفه	MI	مؤلفه	MI
P _{L2}	۰.۰۴۷۱۴	Q _{L12}	۰.۱۷۲۰۴۷	δ_{10}	۰.۲۴۹۵۹۳
Q _{L2}	۰.۰۴۴۹۶۶	P _{L5}	۰.۱۷۰۶۲۲	δ_{11}	۰.۲۴۶۱۲۶
P _{G6}	۰.۰۱۸۰۸۱	Q _{L5}	۰.۱۷۰۶۲۲	P _{L4}	۰.۲۳۹۲۷۱
P _{G3}	۰.۰۱۶۳۱۵	Q _{L9}	۰.۱۳۷۰۱۲	Q _{L4}	۰.۲۳۷۵۷۴
P _{G8}	۰.۰۰۷۶۳۲	P _{L9}	۰.۱۳۵۷۴۸	δ_{14}	۰.۲۱۲۸۸۴
P _{G2}	۰.۰۰۲۸۸۹	δ_2	۰.۰۹۸۴۷۴	P _{L13}	۰.۱۹۴۱۶۷

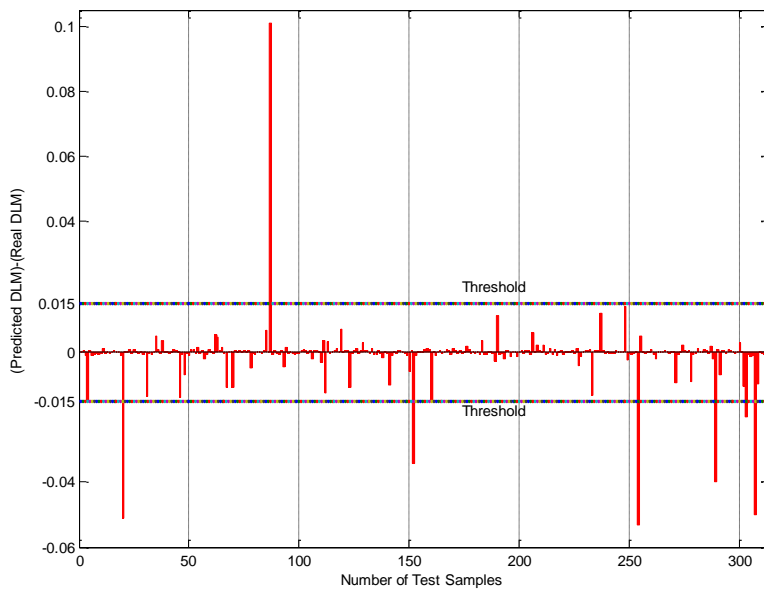
جدول ۵. مؤلفه‌های انتخابی در حالت ۱.

مؤلفه	MI	مؤلفه	MI
Q _{G2}	۰.۷۱۴۷۶۱	δ_6	۱
Q _{G1}	۰.۶۹۵۸۳۴	V ₇	۰.۹۰۰۲۰۳
δ_8	۰.۶۷۱۰۹	P _{G1}	۰.۸۴۲۲۱۲
V ₉	۰.۶۷۱۰۹	δ_7	۰.۸۲۸۲۳۹
δ_9	۰.۵۸۳۱۵۸	V ₆	۰.۸۰۷۴۲۱
V ₁₂	۰.۵۶۶۴۶۸	V ₁	۰.۷۵۶۸۹۶
---	---	Q _{G3}	۰.۷۴۰۴۹۸

برای نمونه، مشخصه عملکرد شبکه عصبی به‌ازای معیار $MI_{III}=0.396$ برای داده‌های اعتبارسنجی و آزمون در شکل‌های ۶ و ۷ نمایش داده شده است. همان‌گونه که در جدول ۳ نیز برای این معیار نشان داده شده است تعداد خطاهای شبکه عصبی برای داده‌های اعتبارسنجی چهار نمونه از ۱۰۰ نمونه و برای داده‌های آزمون ۸ نمونه از ۳۱۲ نمونه می‌باشد. پس مدل شبکه عصبی پیشنهادی برای این داده‌ها از اعتبار مطلوبی برخوردار می‌باشد.



شکل ۶. نمایش گرافیکی اختلاف میان مقادیر واقعی و پیش‌بینی شده DLM به‌ازای $MI_{Th}=0/396$ در حالت اعتبارسنجی.



شکل ۷. نمایش گرافیکی مقادیر واقعی و پیش‌بینی شده DLM به‌ازای $MI_{Th}=0/396$ در حالت آزمون.

در جدول ۶، کمترین خطای آزمون شبکه عصبی به‌ازای دو حالت مختلف نشان داده شده است. بر این اساس، ملاحظه می‌شود که خطای آزمون در حالتی که از روش انتخاب مؤلفه استفاده شده، کمتر از حالتی است که از روش انتخاب مؤلفه استفاده نشده است. در حقیقت، زمانی که از هیچ روش انتخاب مؤلفه‌ای استفاده نشود، تمام مؤلفه‌های در نظر گرفته‌شده به عنوان ورودی به شبکه عصبی اعمال می‌شوند. این موضوع علاوه بر اینکه احتمال کاهش دقت

شبکه عصبی را به همراه دارد، سرعت آموزش شبکه عصبی را به دلیل حجم بالای داده‌ها افزایش می‌دهد. در نقطه مقابل، براساس روش پیشنهادی، تعداد مؤلفه‌های کمتری به‌عنوان ورودی شبکه عصبی اعمال می‌شود که این موضوع دقت و سرعت شبکه عصبی را بالا می‌برد.

جدول ۶. نتایج به‌دست‌آمده در آزمایش حالت ۱.

روش با انتخاب مؤلفه (روش پیشنهادی)		روش بدون انتخاب مؤلفه	
مدت‌زمان آموزش (ثانیه)	درصد خطای آزمون	مدت‌زمان آموزش (ثانیه)	درصد خطای آزمون
۷۵	۱.۶	۱۸۰	۴.۴۹

آزمایش حالت ۲

در این حالت، بارهای سیستم به‌صورت ترکیبی از بارهای توان ثابت، جریان ثابت و امپدانس ثابت در نظر گرفته شده است. در جدول ۶، ترکیب بارهای سیستم براساس مدل بار بیان شده است. برای مثال، بار باس ۲، ۱۰۰ درصد توان ثابت است همچنین بار باس ۳، ۵۰ درصد توان ثابت و ۵۰ درصد دیگر این بار امپدانس ثابت می‌باشد. در حقیقت هدف از این مرحله، بررسی قابلیت روش ارائه‌شده در پیش‌بینی حد دینامیکی پایداری ولتاژ در شرایط پیچیده‌تری از مدل‌های بار می‌باشد. همچنین، در این حالت تعداد کل نمونه‌های تولیدشده ۱۸۱۲ است که از این تعداد ۱۵۰۰ نمونه برای آموزش و ۳۱۲ نمونه برای آزمون شبکه عصبی استفاده شده است.

جدول ۷. ترکیب بارهای سیستم در آزمایش ۲.

شماره باس	توان ثابت	جریان ثابت	امپدانس ثابت
۲	۱۰۰%	۰	۰
۳	۵۰%	۰	۵۰%
۴	۱۰۰%	۰	۰
۵	۱۰۰%	۰	۰
۶	۱۰۰%	۰	۰
۹	۵۰%	۵۰%	۰
۱۰	۰	۱۰۰%	۰
۱۱	۱۰۰%	۰	۰
۱۲	۰	۰	۱۰۰%
۱۳	۰	۰	۱۰۰%
۱۴	۱۰۰%	۰	۰

مطابق آنچه در جدول ۸ آمده است با توجه به میزان همبستگی هر متغیر و $MI_{in}=0.55$ تعداد مؤلفه‌های برجسته که بیشترین تأثیر را بر متغیر هدف دارند انتخاب و در جدول ۹ آورده شده است.

جدول ۸. جمع‌بندی نتایج به‌دست آمده از نسبت فیلترینگ و خطای پیش‌بینی وضعیت دینامیکی پایداری و لتناژ به‌ازای MIهای مختلف برای بارهای با ترکیبی از توان ثابت، جریان ثابت و امیدانس ثابت.

MI _{th} =۰.۰۰۱ - متناظر با استفاده نکردن از روش انتخاب مؤلفه		
خطای آزمون	خطای ولیدیشن	نسبت فیلترینگ
۳.۵۳% (۱۱ out of ۳۱۲)	۴% (۴ out of ۱۰۰)	۶۰/۶۰=۱
MI _{th} =۰.۰۴		
خطای آزمون	خطای ولیدیشن	نسبت فیلترینگ
۱.۶% (۵ out of ۳۱۲)	۴% (۴ out of ۱۰۰)	۶۰/۱۹=۳.۱۶
MI _{th} =۰.۵۵		
خطای آزمون	خطای ولیدیشن	نسبت فیلترینگ
۱.۶% (۵ out of ۳۱۲)	۲% (۲ out of ۱۰۰)	۶۰/۱۶=۳.۷۵
MI _{th} =۰.۶۴		
خطای آزمون	خطای ولیدیشن	نسبت فیلترینگ
۲.۸۸% (۹ out of ۳۱۲)	۹% (۹ out of ۱۰۰)	۶۰/۱۰=۶

طبق جدول ۸ مشخص می‌شود که معیار MI_{th}=۰/۵۵ با درصد خطای اعتبارسنجی کمتر به‌عنوان معیار مطلوب انتخاب می‌شود. همچنین از جدول ۸ می‌توان استنباط کرد که تغییر در تعداد ویژگی‌های انتخابی نیز بر دقت مدل در آزمون و اعتبارسنجی نقش مهمی دارد که در اینجا ۱۶ ویژگی از ۶۰ ویژگی، تعداد ویژگی مطلوب انتخاب شده است.

جدول ۹. همبستگی میان مؤلفه‌های سیستم و مقدار Target در آزمایش حالت ۲.

MI	مؤلفه	MI	مؤلفه	MI	مؤلفه
۱	P _{G6}	۰.۶۲۳۰۵۴	Q _{G1}	۰.۳۸۵۴۱۱	P _{G8}
۰.۸۲۷۸۳۵	δ ₆	۰.۶۱۶۶۱۸	δ ₅	۰.۲۸۱۷۰۳	δ ₁₀
۰.۷۹۷۴۱۶	V ₇	۰.۵۹۷۵۵	V ₆	۰.۲۶۹۴۶۸	δ ₁₄
۰.۷۵۳۱۳۲	δ ₇	۰.۵۹۱۲۷۳	V ₄	۰.۲۴۲۰۵۱	V ₁₁
۰.۷۴۵۹۰۶	δ ₈	۰.۵۸۸۱۶۲	V ₁	۰.۲۳۴۵۰۵	P _{L2}
۰.۷۴۵۹۰۶	V ₉	۰.۵۵۴۴۲۹	V ₈	۰.۲۳۴۵۰۵	Q _{L2}
۰.۷۱۰۴۱۹	δ ₉	۰.۵۴۲۴۵۶	V ₅	۰.۲۲۵۲۵۵	V ₁₂
۰.۶۵۵۸۳۵	δ ₁₃	۰.۵۲۴۷۸۱	δ ₄	۰.۱۹۵۲۶۲	δ ₁₂
۰.۶۵۵۸۳۵	V ₁₄	۰.۴۶۲۸۴	P _{G2}	۰.۱۸۵۲۱۴	δ ₁₁
۰.۶۴۹۱۹۸	δ ₃	۰.۳۹۵۲۷۷	P _{G3}	۰.۱۶۲۸۵	V ₃
۰.۱۵۳۷۲۵	Q _{G6}	۰.۱۱۲۱۷۶	P _{L13}	۰.۰۹۵۰۸۵	δ ₁
۰.۱۲۷۷۰۵	V ₁₄	۰.۱۱۲۱۷۶	Q _{L13}	۰.۰۹۰۴۶۷	Q _{L14}
۰.۱۳۶۲۹۳	V ₂	۰.۱۱۲۱۷۶	Q _{G2}	۰.۰۸۹۳۳۱	P _{L14}


مؤلفه	MI	مؤلفه	MI	مؤلفه	MI
P_{L10}	۰.۰۶۵۲۲۲	P_{L3}	۰.۱۰۹۶۴۶	P_{L5}	۰.۱۲۲۵۹۶
Q_{L10}	۰.۰۶۵۲۲۲	Q_{L3}	۰.۱۰۹۶۴۶	Q_{L5}	۰.۱۲۲۵۹۶
V_{10}	۰.۰۵۴۱۶۹	Q_{G8}	۰.۱۰۹۶۴۶	P_{L11}	۰.۱۱۷۳۲۶
P_{L9}	۰.۰۵۲۴۲۸	P_{L6}	۰.۱۰۴۶۷۴	Q_{L11}	۰.۱۱۴۷۳۶
Q_{L9}	۰.۰۵۲۴۲۸	Q_{L6}	۰.۱۰۲۲۳۲	P_{L12}	۰.۱۱۴۷۳۶
P_{G1}	۰.۰۴۵۷۵۱	P_{L4}	۰.۰۹۹۸۲	Q_{L12}	۰.۱۱۴۷۳۶
Q_{G3}	۰.۰۱۲۶۳۸	Q_{L4}	۰.۰۹۹۸۲	δ_2	۰.۱۱۲۱۷۶

همان‌طور که از جدول ۱۰ مشخص است تعداد ۱۶ مؤلفه از ۶۰ مؤلفه کلی انتخاب شده است. شایان ذکر است که ضریب MI_{th} به صورت سعی و خطا تعیین شده است.


جدول ۱۰. مؤلفه‌های انتخاب شده به ازای $MI_{th}=0.55$ - آزمایش ۲.

مؤلفه	MI	مؤلفه	MI
V_{14}	۰.۶۵۵۸۳۵	P_{G6}	۱
δ_3	۰.۶۴۹۱۹۸	δ_6	۰.۸۲۷۸۳۵
Q_{G1}	۰.۶۲۳۰۵۴	V_7	۰.۷۹۷۴۱۶
δ_5	۰.۶۱۶۶۱۸	δ_7	۰.۷۵۳۱۳۲
V_6	۰.۵۹۷۵۵	δ_8	۰.۷۴۵۹۰۶
V_4	۰.۵۹۱۲۷۳	V_9	۰.۷۴۵۹۰۶
V_1	۰.۵۸۸۱۶۲	δ_9	۰.۷۱۰۴۱۹
V_8	۰.۵۵۴۴۲۹	δ_{13}	۰.۶۵۵۸۳۵

در جدول ۱۰، مؤلفه‌های مطلوب انتخاب شده به ازای $MI_{th}=0.55$ نشان داده شده است. با مقایسه نتایج به دست آمده در این مرحله و نتایج مرحله قبل، ملاحظه می‌شود که حتی با پیچیده شدن ویژگی‌های سیستم (تغییر مدل بار سیستم)، الگوریتم ارائه شده با دقت قابل قبولی حد دینامیکی پایداری ولتاژ را تعیین می‌کند. در حقیقت، زمانی که بارهای سیستم از توان ثابت به مدل‌های دیگر مانند جریان ثابت و امپدانس ثابت تغییر وضعیت می‌دهند، به دلیل وابستگی توان‌های این گونه بارها به ولتاژ باس متصل به آن بار، رفتاری غیرخطی در سیستم بروز می‌دهد. این موضع علاوه بر اینکه تحلیل دینامیکی پایداری ولتاژ را پیچیده می‌کند، پیش‌بینی حد دینامیکی پایداری ولتاژ را نیز تحت تأثیر قرار می‌دهد. مشخصه عملکرد شبکه عصبی به ازای معیار $MI_{th}=0.55$ برای داده‌های اعتبارسنجی و آزمون در شکل‌های ۸ و ۹ نمایش داده شده است. همان‌گونه که در جدول ۷ نیز برای این معیار نشان داده شده است تعداد خطاهای شبکه عصبی برای داده‌های اعتبارسنجی ۲ نمونه از ۱۰ نمونه و برای داده‌های آزمون ۵ نمونه از ۳۱۲ نمونه می‌باشد. پس مدل شبکه عصبی پیشنهادی برای این داده‌ها از اعتبار مطلوبی برخوردار می‌باشد.



شکل ۸. نمایش گرافیکی اختلاف میان مقادیر واقعی و پیش‌بینی شده DLM به‌ازای $MI_{Th}=0/55$ در حالت اعتبارسنجی.



شکل ۹. نمایش گرافیکی اختلاف میان مقادیر واقعی و پیش‌بینی شده DLM به‌ازای $MI_{Th}=0/55$ در حالت آزمون.

در جدول ۱۱، خطای آزمون شبکه عصبی براساس نتایج به‌دست‌آمده با استفاده از روش انتخاب مؤلفه و بدون استفاده از آن بیان شده است.

جدول ۱۱. نتایج به‌دست‌آمده در آزمایش حالت ۲.

روش بدون انتخاب مؤلفه		روش با انتخاب مؤلفه (روش پیشنهادی)	
مدت‌زمان آموزش	درصد خطای آزمون	مدت‌زمان آموزش (ثانیه)	درصد خطای آزمون
۲۰	۳.۵۳	۲۱۰	۱.۶

نتیجه‌گیری

در این مقاله، با استفاده از یک تحلیل ترکیبی، حد دینامیکی پایداری ولتاژ متناظر با مرز HB پیش‌بینی شده است. در این راستا به‌منظور ایجاد نمونه‌های موردنیاز برای آزمون و آموزش شبکه عصبی از ترکیب شبیه‌سازی حوزه زمان، تئوری دوشاخگی و تحلیل مدل در محیط نرم‌افزار DiGSILENT استفاده شد و به‌منظور کاهش حجم اطلاعات و افزایش دقت شبکه عصبی، از روش انتخاب مؤلفه مبتنی بر تئوری اطلاعات متقابل بهره برده شد. در این راستا به‌منظور بررسی قابلیت الگوریتم پیشنهادی، نمونه‌های ایجادشده یک‌بار در حالتی که تمام بارهای سیستم ۱۴ باسه IEEE توان ثابت بوده‌اند و یک‌بار در حالتی که بارهای سیستم آزمون مذکور ترکیبی از مدل‌های توان ثابت، جریان ثابت و امیدانس ثابت بوده‌اند تولید شد و براساس آن شبکه عصبی مورد آموزش و تست قرار گرفت. براساس نتایج به‌دست‌آمده، خطای آزمون و نیز سرعت آموزش و آزمون شبکه عصبی در حالی که از الگوریتم پیشنهادی استفاده شده است، به‌مراتب کمتر از زمانی است که از هیچ روش انتخاب مؤلفه‌ای استفاده نمی‌شود. علاوه بر این، با پیچیده شدن نوع بارهای سیستم در آزمایش حالت ۲، قابلیت الگوریتم ارائه‌شده در پیش‌بینی دقیق حد دینامیکی پایداری ولتاژ همانند آزمایش شماره ۱ که در آن بارهای سیستم از نوع توان ثابت بوده‌اند، در حد قابل‌قبولی بود.

References

- [1] Isaac, S., Adebola, S., Ayokunle, A., Katende, J., & Claudius, A. (2021). Voltage collapse prediction using artificial neural network. *International Journal of Electrical and Computer Engineering*, 11(1), 124-132. <https://doi.org/10.11591/ijece.v11i1.pp124-132>
- [2] Alipour, M. (2017). Optimal allocation of SVC and TCSC in power system by means of fuzzy estimator with the approach of increasing the static stability of the voltage. *Karafan Quarterly Scientific Journal*, 14(2), 95-121. https://karafan.tvu.ac.ir/article_100507.html?lang=en
- [3] Ibe, O. G., & Onyema, A. I. (2013). Concepts of reactive power control and voltage stability methods in power system network. *International Organization Of Scientific Research Journal of Computer Engineering*, 11(2), 15-25. <https://doi.org/10.9790/0661-1121525>
- [4] Larik, R. M., Mustafa, M. W., & Panjwani, M. K. (2019). A statistical jacobian application for power system optimization of voltage stability. *Indonesian Journal of Electrical Engineering and Computer Science*, 13(1), 331-338. <https://doi.org/10.11591/ijeecs.v13.i1.pp331-338>
- [5] Mobarak, Y. A. (2015). Voltage collapse prediction for Egyptian interconnected electrical grid EIEG. *International Journal on Electrical Engineering and Informatics*, 7(1), 79-88. <https://doi.org/10.15676/ijeeci.2015.7.1.6>
- [6] Saha, G., Chakraborty, K., & Das, P. (2018). Voltage Stability Prediction on Power Networks using Artificial Neural Networks. *Indonesian Journal of Electrical Engineering and Computer Science*, 10(1), 1-9. <https://doi.org/10.11591/ijeecs.v10.i1.pp1-9>
- [7] Sridhar, J., & Prakash, R. (2019). Multi-objective whale optimization based minimization of loss, maximization of voltage stability considering cost of DG for optimal sizing

- and placement of DG. *International Journal of Electrical and Computer Engineering* 9(2), 835-839. <https://doi.org/10.11591/ijece.v9i2.pp.835-839>
- [8] Zamani, M. K. M., Musirin, I., Mustafa, S. A. S., & Suliman, S. I. (2019). Optimal SVC allocation via symbiotic organisms search for voltage security improvement. *Telecommunication Computing Electronics and Control*, 17(3), 1267-1274. <https://doi.org/10.12928/telkonnika.v17i3.9905>
- [9] Acevedo, L. F., Bothia-Vargas, G., & Candelo, J. E. (2018). Dynamic voltage stability comparison of thermal and wind power generation with different static and dynamic load models. *International Journal of Electrical and Computer Engineering*, 8(3), 1401-14011. <https://doi.org/10.11591/ijece.v8i3.pp1401-1411>
- [10] Danish, M. S. S., Yona, A., & Senjyu, T. (2015). A review of voltage stability assessment techniques with an improved voltage stability indicator. *International Journal of Emerging Electric Power Systems*, 16(2), 107-115. <https://doi.org/10.1515/ijeeps-2014-0167>
- [11] Lee, D. H. A. (2016). Voltage Stability Assessment Using Equivalent Nodal Analysis. *IEEE Transactions on Power Systems*, 31(1), 454-463. <https://doi.org/10.1109/TPWRS.2015.2402436>
- [12] Pérez-Londoño, S., Rodríguez, L. F., & Olivar, G. (2014). A Simplified Voltage Stability Index (SVSI). *International Journal of Electrical Power & Energy Systems*, 63, 806-813. <https://doi.org/10.1016/j.ijepes.2014.06.044>
- [13] Canizares, C. A. (2002). Voltage stability assessment: concepts, practices and tools. *IEEE/PES power system stability subcommittee special publication*, (SP101PSS). https://scholar.google.ca/citations?view_op=view_citation&hl=en&user=NqIpnMkAAAAJ&citation_for_view=NqIpnMkAAAAJ:9yKSN-GCB0IC
- [14] Nor, A. M., Sulaiman, M., Kadir, A. F. A., & Omar, R. (2016). Voltage instability analysis for electrical power system using voltage stability margin and modal analysis. *Indonesian Journal of Electrical Engineering and Computer Science*, 3(3), 655-662. <https://doi.org/10.11591/ijeecs.v3.i3.pp655-662>
- [15] Amjady, N., & Velayati, M. H. (2009). Evaluation of the maximum loadability point of power systems considering the effect of static load models. *Energy Conversion and Management*, 50(12), 3202-3210. <https://doi.org/10.1016/j.enconman.2009.08.026>
- [16] Chen, H., Wang, Y., & Zhou, R. (2001). Transient and voltage stability enhancement via co-ordinated excitation and UPFC control. *IEE Proceedings - Generation, Transmission and Distribution*, 148(3), 201-208. <https://doi.org/10.1049/ip-gtd:20010189>
- [17] Zhihong, F. (1992). The static voltage stability analysis methods for many generators power system—singularity decoupled method. *Proceedings of CSEE*, 12(3), 10-18.
- [18] Jiang, T., Wan, K., & Feng, Z. (2019). Boundary-derivative direct method for computing saddle node bifurcation points in voltage stability analysis. *International Journal of Electrical Power & Energy Systems*, 112(3), 199-208. <https://doi.org/10.1016/j.ijepes.2019.04.039>
- [19] Neves, L. S., Alberto, L. F. C., & Chiang, H-D. (2020). A fast method for detecting limit-induced bifurcation in electric power systems. *Electric Power Systems Research*, 180, 106101. <https://doi.org/10.1016/j.eprsr.2019.106101>
- [20] Rao, S. D., Tylavsky, D. J., & Feng, Y. (2017). Estimating the saddle-node bifurcation point of static power systems using the holomorphic embedding method. *International Journal of Electrical Power & Energy Systems*, 84, 1-12. <https://doi.org/10.1016/j.ijepes.2016.04.045>

- [21] Roque, M. M., & Pessanha, J. E. O. (2020). Methodology for Voltage Stability Analysis Using Hopf Bifurcation and Continuation Power Flow Simulator. *Electric Power Components and Systems*, 48(12-13), 1211-1220. <https://doi.org/10.1080/15325008.2020.1854382>
- [22] Amroune, M., Bouktir, T., & Musirin, I. (2018). Power System Voltage Stability Assessment Using a Hybrid Approach Combining Dragonfly Optimization Algorithm and Support Vector Regression. *Arabian Journal for Science and Engineering*, 43(6), 3023-3036. <https://doi.org/10.1007/s13369-017-3046-5>
- [23] Naganathan, G. S., & Babulal, C. K. (2019). Optimization of support vector machine parameters for voltage stability margin assessment in the deregulated power system. *Soft Computing*, 23(20), 10495-10507. <https://doi.org/10.1007/s00500-018-3615-x>
- [24] Villa-Acevedo, W. M., López-Lezama, J. M., & Colomé, D. G. (2020). Voltage Stability Margin Index Estimation Using a Hybrid Kernel Extreme Learning Machine Approach. *Energies*, 13(4), 1-19. <https://doi.org/10.3390/en13040857>
- [25] Sabri, M. (2017). Stabilization and control of the power system using meta-heuristic algorithms. *Karafan Quarterly Scientific Journal*, 14(2), 33-55. https://karafan.tvu.ac.ir/article_100504.html?lang=en
- [26] Nizam, M., Mohamed, A., & Hussain, A. (2010). Dynamic voltage collapse prediction in power systems using support vector regression. *Expert Systems with Applications*, 37(5), 3730-3736. <https://doi.org/10.1016/j.eswa.2009.11.052>
- [27] Zhou, D. Q., Annakkage, U. D., & Rajapakse, A. D. (2010). Online Monitoring of Voltage Stability Margin Using an Artificial Neural Network. *IEEE Transactions on Power Systems*, 25(3), 1566-1574. <https://doi.org/10.1109/TPWRS.2009.2038059>
- [28] Kamalasan, S., Thukaram, D., & Srivastava, A. K. (2009). A new intelligent algorithm for online voltage stability assessment and monitoring. *International Journal of Electrical Power & Energy Systems*, 31(2-3), 100-110. <https://doi.org/10.1016/j.ijepes.2008.10.011>
- [29] Sanchez, Z., González - Cueto Cruz, J., Sánchez, G., Hernandez Herrera, H., & Silva, J. (2020). Voltage collapse point evaluation considering the load dependence in a power system stability problem. *International Journal of Electrical and Computer Engineering*, 10(1), 61-71. <https://doi.org/10.11591/ijece.v10i1.pp61-71>
- [30] Hanchuan, P., Fuhui, L., & Ding, C. (2005). Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(8), 1226-1238. <https://doi.org/10.1109/TPAMI.2005.159>