



Computational Intelligence in Electrical Engineering
Vol. 13, No. 1, 2022
Research Paper

Outage prediction of distribution network overhead lines using support vector machine to improve resilience

Mojtaba Mohseni¹, Gholam H. Riahy¹, Zahra Moravej²

¹ Dept. of Electrical Engineering, Amirkabir University of Technology (Tehran Polytechnic),
Tehran, Iran

² Faculty of Electrical & Computer Engineering, Semnan University, Semnan, Iran

Abstract:

Predicting the status of power grid components, especially overhead lines in response to extreme weather event, plays an important role in planning pre-resource allocation, as well as restoring loads more quickly at a faster time which can improve the power grid resilience. In this paper, a Multi-dimensional Support Vector Machine algorithm is proposed to predict outage overhead lines assuming storm paths. In this model, dimensions are based on five distinct features: the distance from building, distance from tree, distance from center of storm, storm speed and cable type. The result of the proposed model is the classification of overhead lines status into two out and operational statuses implemented on the 33-bus IEEE network. The results show that the proposed model predicts outage lines with high accuracy.

Keywords: extreme event, support vector machine, resiliency.



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



<http://dx.doi.org/10.22108/isee.2021.124588.1403>

پیش‌بینی قطعی خطوط شبکه توزیع با استفاده از الگوریتم ماشین بردار پشتیبان برای بهبود

تاب‌آوری

مجتبی محسنی^۱، غلامحسین ریاحی دهکردی^۲، زهرا مروج^{۳*}

۱- کارشناسی ارشد، دانشکده مهندسی برق- دانشگاه امیرکبیر-تهران- ایران

m-mohseni@aut.ac.ir

۲- دانشیار، دانشکده مهندسی برق- دانشگاه امیرکبیر-تهران- ایران

gholam@aut.ac.ir

۳- استاد، دانشکده مهندسی برق- دانشگاه سمنان- سمنان- ایران

zmoravej@semnan.ac.ir

چکیده: پیش‌بینی وضعیت قطعی اجزای شبکه قدرت، به‌ویژه خطوط هوایی در مقابل شرایط آب‌وهوایی شدید، نقش مهمی در برنامه‌ریزی تخصیص منابع پیش از رخداد واقعه و نیز بازبازی بارها در زمانی سریع‌تر دارد که باعث بهبود تاب‌آوری شبکه قدرت می‌شود. در این مقاله، یک الگوریتم ماشین بردار پشتیبان چندبُعدی برای پیش‌بینی خطوط هوایی معیوب شبکه قدرت با فرض دانستن مسیرهای طوفان ارائه شده است. در این مدل، ابعاد براساس پنج ویژگی متمایز، فاصله از ساختمان، فاصله از درخت، فاصله از مرکز طوفان، سرعت طوفان و نوع کابل ایجاد شده‌اند که از نوآوری‌های اصلی تحقیق به‌شمار می‌روند. نتیجه مدل ارائه‌شده، دسته‌بندی وضعیت خطوط هوایی به دو وضعیت قطع و عملیاتی است که روی شبکه ۳۳ باس IEEE پیاده شده است. نتایج نشان می‌دهند مدل پیشنهادی، خطوط قطع‌شده را با دقت بیشتری پیش‌بینی می‌کند.

واژه‌های کلیدی: شرایط شدید آب‌وهوایی، ماشین بردار پشتیبان، تاب‌آوری

۱- مقدمه

برخلاف روش‌های سنتی، ثابت شده است هنگامی که یادگیری ماشین در مطالعات طبقه‌بندی استفاده می‌شود، از نظر محاسباتی، قدرتمند، سیستماتیک و به‌شدت قابل اعتماداند.

همچنین، به‌طور فزاینده‌ای بلایای طبیعی مانند طوفان و حتی حملات مخرب انسانی، امنیت سیستم قدرت را تهدید می‌کنند. وقوع طوفان‌های شدید، هرچند احتمال رخداد پایینی دارند، خسارات شدیدی به دنبال دارند و امکان برآورد خسارات ناشی از آن نیز وجود دارد [۱]. تخمین مطلوب درباره خسارات احتمالی بخش‌های شبکه، گامی مهم در توسعه مدل شبکه، واکنشی مناسب و نیز بازبازی مطلوب شبکه و اقدامات پیشگیرانه صحیح برای به حداقل رساندن خسارات است که تاب‌آوری شبکه را افزایش می‌دهند [۲]. نیروگاهها و دولت‌های محلی، همیشه با چالش

در سال‌های اخیر بسیاری از روش‌های یادگیری ماشین (MLTs) در مدل‌سازی، مانیتورینگ و نظارت بر کاربردهای پیچیده استفاده شده است. روش‌های متعددی مانند شبکه عصبی مصنوعی (ANN)، درخت تصمیم (DT)، کاهش ابعاد با تحلیل مؤلفه اصلی (PCA)، روش‌های ترکیبی (Ensemble Learning) در پژوهش‌های مختلفی شامل ارزیابی امنیت سیستم قدرت و پایداری سیستم ارائه شده‌اند.

تاریخ ارسال مقاله: ۱۳۹۹/۰۶/۰۲

تاریخ پذیرش مقاله: ۱۳۹۹/۱۰/۱۶

نام نویسنده مسئول: زهرا مروج

نشانی نویسنده مسئول: ایران - سمنان - دانشکده برق و کامپیوتر سمنان

ویژگی‌ها برای پیش‌بینی اجزای سیستم در مقابل حادثه طوفان کافی نیستند.

یادگیری ماشین برای مسائلی مرتبط با شبکه قدرت مانند دسته‌بندی نوع خطا و محل خطا در خطوط انتقال استفاده شده است [۷]. همچنین در [۸] برای پیش‌بینی توان تولیدی فتوولتائیک از طریق تصاویر ماهواره‌ای از ماشین بردار پشتیبان، در [۹] ارزیابی امنیت از طریق درخت تصمیم، پرسپترون چندلایه و دسته‌بند نزدیک‌ترین همسایه، در [۱۰] پیش‌بینی بار کوتاه‌مدت بارهای خانگی از طریق شبکه عصبی بازگشتی و در [۱۱] از طریق طبقه‌بندی داده‌های تابش خورشید با ماشین بردار پشتیبان به دنبال حداکثرسازی توان تولیدی با PV هستند. در [۱۲] وضعیت اجزای شبکه قدرت پس از طوفان به‌عنوان آسیب‌دیده یا عملیاتی در نظر گرفته شده است. برای طبقه‌بندی وضعیت هر قطعه شبکه، سرعت طوفان و فاصله هر جزء از مرکز طوفان به‌وسیله الگوریتم رگرسیون لجستیک در نظر گرفته شده است.

در [۱۳] یک مدل پیش‌بینی دوبخشی از مقدار توان خارج‌شده از شبکه توزیع در مقابل طوفان یخی ارائه شده است. در ابتدا با یادگیری ماشین، بخشی از شبکه، پیش‌بینی و در مرحله دوم با مدل خطی تعمیم‌یافته کل شبکه پیش‌بینی می‌شود. در [۱۴] یک مدل درخت رگرسیون براساس پنج داده پیش‌بینی هوا، اطلاعات مکانی خاک، پوشش گیاهی، واحدهای تولیدی و مقدار توان خارج‌شده ارائه شده است که تعداد و توزیع مکانی خاموشی‌ها را در شبکه توزیع برق پیش‌بینی می‌کند. تعیین سریع‌تر امنیت سیستم قدرت با استفاده از داده‌های زمان واقعی امکان‌پذیر است؛ اما زمان محاسباتی طولانی‌تر و تولید داده‌های حجیم با برنامه‌های شبیه‌سازی امنیتی، یکی از بزرگ‌ترین مشکلات برای دستیابی سریع‌تر به ارزیابی امنیتی است [۱۵]. در [۱۵] یک ماشین بردار پشتیبان چندکلاسه برای ارزیابی امنیت استاتیک سیستم قدرت ارائه شده است که زمان مورد نیاز ارزیابی سیستم را کاهش می‌دهد.

در این مقاله یک مدل ماشین بردار پشتیبان خطی با پنج ویژگی متمایز فاصله از ساختمان، فاصله از درخت، فاصله از مرکز طوفان، سرعت طوفان و نوع کابل و نیز پیش‌بینی مسیرهای طوفان، قطعی خطوط شبکه توزیع قدرت تعیین

افزایش انتظارات مصرف‌کننده‌های برق، برای سرویس بدون وقفه به آنها رویارو هستند که حوادثی از قبیل طوفان، شرایط را وخیم‌تر می‌کند [۳].

همچنین، با افزایش نفوذ منابع تولید پراکنده در شبکه‌های قدرت و با در نظر داشتن فن‌آوری‌های مختلف تولیدات پراکنده مانند باد، سلول خورشیدی و عدم قطعیت‌های انواع تولیدات تجدیدپذیر و تبدیل شدن شبکه‌های توزیع غیرفعال به شبکه‌های توزیع فعال، مدل‌سازی و تحلیل خطا به روش‌های سنتی در شرایط بحرانی را پیچیده می‌کند [۴]. هرچند تکنیک‌های شبیه‌سازی سنتی مبتنی بر مدل‌های قطعی در سیستم قدرت هنوز در بیشتر موارد دقیق‌تر و مطمئن‌تر از الگوریتم‌های هوش مصنوعی و یادگیری ماشین عمل می‌کنند، با پیچیده‌شدن شبکه قدرت و وابسته‌بودن زیرساخت‌ها تکنیک‌های سنتی راه‌حل‌های امیدوارکننده محاسباتی نیستند؛ زیرا ظرفیت محدودی برای مدیریت حجم انبوه داده‌های دریافت‌شده از کتورهای هوشمند و نیز واحدهای اندازه‌گیری فازور (PMU) دارند و این مشکل دوجندان می‌شود، اگر مقدار زیادی از دیاست‌ها ناهمگن باشند [۵]. شبکه توزیع فعال دارای مانیتورینگ و نظارت، تشخیص و عکس‌العمل هوشمند است که مقدار زیادی داده‌های شبکه را در ثبات‌ها ذخیره می‌کند؛ بنابراین، می‌توان از تاریخچه سیستم قدرت برای تخمین یا پیش‌بینی وضعیت آن در هنگام رخداد پیشامدی سود برد. با توجه به کاربردهای ماشین لرنینگ، انتظار می‌رود تا حدودی این چالش‌های پیچیده را برطرف کند. همچنین، با افزایش حجم داده‌های دریافت‌شده از سنسورهای هوشمند در شبکه توزیع فعال، به‌نسبت آموزش تکنیک‌های ماشین لرنینگ کارایی بهتری خواهد داشت که برای پیش‌بینی‌های کوتاه‌مدت و میان‌مدت وضعیت شبکه قدرت، با سرعت محاسباتی و مقیاس‌پذیری بالا سودمند است.

یکی از فاکتورهای مهم تاب‌آوری در شبکه قدرت، پیش‌بینی و واکنش سریع در مقابل حوادث غیرمترقبه است [۶]. هرچند در [۶] نویسنده به دنبال ارائه یک مدل ماشین بردار پشتیبان سه‌بعدی برای بالابردن دقت در پیش‌بینی آسیب اجزای سیستم قدرت در مقابل طوفان است، همچنان

(۱) فاصله از ساختمان بلند: ساختمان بلند می‌تواند نقش مانع را در برابر طوفان برای شبکه داشته باشد. هرچه ساختمان بلندتر و عریض‌تر باشد یا به نقطه مدنظر نزدیک‌تر باشد، احتمال آسیب کاهش می‌یابد.

(۲) فاصله از درخت: درخت برعکس ساختمان می‌تواند عامل ویرانی شبکه باشد؛ به طوری که در صورتی که طوفان توانایی آسیب به درخت را داشته باشد و در حالتی که درخت به اندازه کافی بزرگ و نزدیک خطوط شبکه قرار گرفته باشد، می‌تواند به شبکه آسیب برساند.

(۳) فاصله از مرکز طوفان: هر طوفانی یک دامنه محدود دارد و در آن دامنه حرکت می‌کند؛ اما در همین دامنه نیز در مسیرهایی شدت آن بیشتر است که به این مسیرها به اصطلاح کانال طوفان اطلاق می‌شود. طوفان بسته به جنس آن می‌تواند تک یا چندکاناله باشد. هرچه نقطه انتخابی به مرکز یا کانال طوفان نزدیک‌تر باشد، احتمال آسیب دیدگی آن بیشتر می‌شود.

(۴) سرعت طوفان: در کنار فاصله از مرکز طوفان، سرعت طوفان نیز در آسیب دیدگی شبکه مؤثر است؛ به طوری که سرعت از حد مشخص کمتر باشد، عملاً توانایی آسیب به شبکه را نخواهد داشت و هرچه سرعت بالاتر رود، احتمال آسیب تقویت می‌شود.

(۵) حالت کابل‌ها: به تازگی کابل‌های شبکه توزیع به صورت تینده درهم یا خودنگهدار در شبکه پیاده‌سازی می‌شوند که از نظر آسیب دیدگی از جانب طوفان مفید واقع می‌شوند.

شده‌اند که از نوآوری‌های اصلی مقاله است. درحقیقت در کارهای گذشته تنها از دو ویژگی سرعت طوفان و فاصله از مرکز طوفان برای پیش‌بینی استفاده شده است که دقت لازم را در مواجهه با طوفان ندارد؛ زیرا ممکن است طوفانی با سرعت کمتر، با شکسته شدن شاخه درخت، خطوط هوایی قطع یا باعث اتصال کوتاه شود. همچنین، ممکن است طوفان شدید باشد؛ اما مانعی مانند ساختمان عریض در مقابل خطوط قرار گرفته باشد که باعث قطعی خطوط نمی‌شود. همچنین، کابل‌های خودنگهدار در شبکه می‌توانند مقاومت بیشتری در مقابل قطعی طوفان داشته باشند. همچنین، پژوهش‌های گذشته، تنها به دنبال نشان دادن کارایی روش ماشین بردار پشتیبان در سیستم قدرت بودند و روی شبکه توزیع پیاده نشدند؛ به همین منظور، در بخش دوم، ویژگی‌ها تعیین و تعریف شده‌اند و در ادامه، تأثیر این ویژگی‌ها بر خرابی خطوط به صورت آماری نشان داده شده است. در بخش سوم، ماشین بردار پشتیبان با توجه به شرایط استاتیکی و دینامیکی هر کدام از نقاط شبکه، مدلسازی شده است. شرایط استاتیکی شرایطی است که برای هر نقطه شبکه در گذر زمان و مواقع مختلف ثابت است. دسته دینامیکی شرایطی از شبکه است که ممکن است در مواقع مختلف وضعیت‌های متفاوتی به خود بگیرد. در بخش چهارم، طبقه‌بندی روی شبکه ۳۳ باس IEEE پیاده‌سازی شده است. در پایان، نتیجه‌گیری و پیشنهادهایی برای انجام کارهای آتی مطرح شده‌اند.

۲- ویژگی‌های استفاده شده

لازم است ویژگی‌های استفاده شده درباره نقاط مختلف شبکه برای کلاس بندی مکان‌های آسیب دیده و سالم پس از وقوع طوفان تعیین شوند. ویژگی‌های بسیاری را برای هر کدام از نقاط شبکه می‌توان برگزید؛ اما تعداد محدودی برای کلاس بندی مدنظر مؤثر واقع می‌شوند. در واقع، بهترین حالت انتخاب ویژگی، کمترین تعداد آنهاست؛ به نحوی که دقت مطلوب از کلاس بندی حاصل شود. در ادامه، ویژگی‌هایی معرفی می‌شوند که در این پژوهش برای طبقه بندی انتخاب شده‌اند.

۲-۱- مصورسازی و اطلاعات آماری داده‌ها

با اجرای مجموعه داده در نرم افزار اطلاعات آماری، خصوصیات داده به شرح زیرند.

اطلاعات در ۲۵۶ نمونه خط شبکه بدون داده از دست رفته تعریف شده‌اند. میانگین ویژگی فاصله از ساختمان در ۰,۲۹۲ متر و بیشترین فاصله از ساختمان ۱ متر تعیین شده است. میانگین فاصله از درخت ۰,۲۵۳ متر و بیشترین فاصله از درخت ۱ متر تعیین شده است. میانگین فاصله از مرکز طوفان ۰,۲۷۲ کیلومتر و بیشترین فاصله از

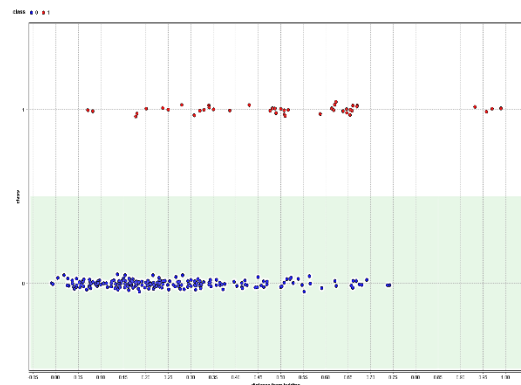
پیش‌بینی قطعی خطوط شبکه توزیع با استفاده از الگوریتم ماشین بردار پشتیبان برای بهبود تاب‌آوری

مرکز ۱ کیلومتر تعیین شده است.

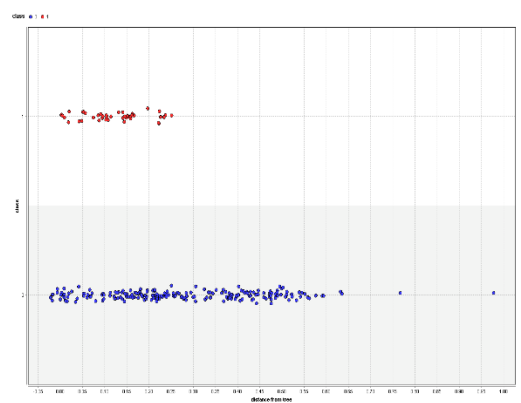
درخت دارند، قطعی بیشتری دارند و نقاط با فاصله زیاد از درخت قطعی کمتری در آنها گزارش شده است. در شکل ۳، فاصله از مرکز طوفان نسبت به نقاط قطع شده (قرمز) و نقاط غیرقطعی (آبی) نشان داده شده است که نتایج مشخص می‌کنند به طور نسبی، نقاطی قطعی بیشتری دارند که به طور میانگین به مرکز طوفان نزدیک‌ترند؛ اما با توجه به اینکه در برخی شاخه‌ها قطع بودن خطوط حتی برای نقاط نزدیک به ساختمان و دور از مرکز طوفان و درخت نیز وجود دارد، دریافت آمار و نمودارهای آماری نمی‌توانند رابطه بین شاخص‌ها و نقاط قطعی را به طور دقیق تشخیص دهند؛ از این رو از یادگیری ماشین با SVM در بخش دسته‌بندی استفاده خواهد شد.

۳- مدل پیشنهادی

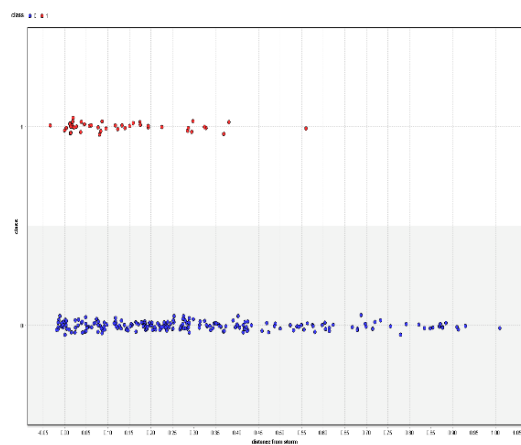
استفاده از بردارهای پشتیبان خطی در مسایل دسته‌بندی، روشی قدرتمند است که توجه بسیاری را به خود جلب است. رویکرد آن به این صورت است که در مرحله آموزش، سعی دارد مرز تصمیم‌گیری را به گونه‌ای انتخاب کند که حداقل فاصله آن را با هر یک از دسته‌های مدنظر بیشینه کند. در این روش، با استفاده از یک الگوریتم بهینه‌سازی، نمونه‌هایی به دست می‌آیند که مرز کلاس‌ها را تشکیل می‌دهند. این نمونه‌ها را بردارهای پشتیبان گویند. تعدادی از نقاط آموزشی که کمترین فاصله را با مرز تصمیم‌گیری دارند، بردار پشتیبان در نظر گرفته می‌شود. در شکل ۴، بردارها مشخص شده‌اند. فضای ویژگی ورودی از دو کلاس تشکیل شده است. برای محاسبه مرز تصمیم‌گیری دو کلاس کاملاً جدا از هم، از روش حاشیه بهینه استفاده می‌شود.



شکل (۱): نمودار پراکندگی فاصله در ساختمان



شکل (۲): نمودار پراکندگی فاصله از درخت



شکل (۳): نمودار پراکندگی فاصله از مرکز طوفان

با توجه به شکل ۱، نقاطی که فاصله بیشتری از ساختمان دارند، قطعی بیشتری در آنها گزارش شده است و برعکس، با توجه به شکل ۲، نقاطی که فاصله کمی از

می شود [۳].

$$\min_{w,b} \Omega(\omega, \lambda) = \frac{1}{\nu} \|\omega\|^2 + c \sum_{i=1}^n \lambda_i \quad (۳)$$

$$s.t \quad y_i (\omega^T x + b) \geq 1 - \lambda_i, \quad \forall i$$

$$\lambda_i > 0, \quad \forall i$$

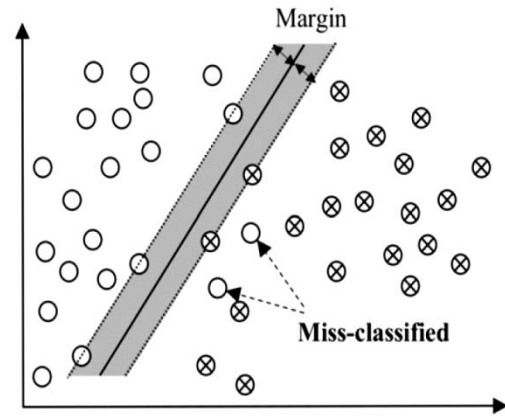
پارامتر c ضریب جریمه‌ای است که امکان جداکردن نمونه‌های غیرخطی را فراهم می‌کند و λ ضریب تنظیم وزن‌های نمونه‌های اشتباه طبقه‌بندی شده در ناحیه بین دو مرز است. هنگامی که $c \rightarrow \infty$ ، مرزها طوری تنظیم می‌شوند که هیچ نمونه‌ای به صورت خطا دسته‌بندی نشود که به اصطلاح به آن حاشیه سخت گفته می‌شود. هنگامی که $0 < c < \infty$ باشد، درحقیقت مدل ما تعدادی خطا را پذیرفته است که حاشیه نرم گفته می‌شود. مسئله (۵) یک مسئله برنامه‌ریزی درجه دوم است که با استفاده از لانگ‌رایزین می‌تواند به فرم دوگان تبدیل شود که تنها به یک ضریب وابسته است [۳].

$$\min \Psi(\alpha) = \frac{1}{\nu} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) - \sum_{i=1}^n \alpha_i \quad (۴)$$

$$s.t \quad 0 < \alpha_i < c, \quad \forall i$$

$$\sum_{i=1}^n \alpha_i y_i = 0$$

در اینجا α_i ها ضرایب معادله لانگ‌رایزین است و α_i های بردار پشتیبان، غیر صفر و برای نقاط دیگر صفر خواهد بود. همین نکته، حجم محاسبات را به شدت کاهش می‌دهد و ما تنها به ضرایبی نیاز داریم که غیر صفر است. هنگامی که به دلیل قرارگیری نقاط در فضا نمونه‌های متعلق به رده‌های مختلف را با یک خط نتوان جدا کرد، به منحنی برای جداسازی نیاز است که از حقه کرنل استفاده می‌کنیم. در این حالت، داده‌ها را از فضای اولیه R^m با استفاده از یک تبدیل خطی به فضای با ابعاد بیشتر R^p منتقل می‌کند تا در فضای جدید کلاس‌ها تا داخل کمتری با هم داشته باشند. در این حالت، مرز تصمیم‌گیری بهینه به یک مسئله بهینه‌سازی به فرم رابطه (۵) تبدیل می‌شود [۳].



شکل (۴): ماشین بردار پشتیبان [۶].

برای این منظور، در ادامه شبیه‌سازی کلاس‌بندی به کمک ویژگی‌های معرفی شده برای نقاط مهم شبکه و استفاده از کلاس‌بند SVM ارائه خواهد شد. مدل ریاضی به صورت زیر بیان می‌شود. یک دیتاست m بعدی با n داده آموزشی به فرم زیر است.

$$\{(x_n, y_n) | x_n \in R^m, y_n \in \{+1, -1\}, m \in \{1, 2, \dots, M\}\} \quad (۱)$$

x^n یک بردار M بعدی که M تعداد ویژگی‌های مدنظر است. y^n نیز برچسب کلاس هر نمونه x^n است که تعداد کلاس‌ها را برای دسته‌بندی نشان می‌دهد. در حالت کلی، یک مرز تصمیم‌گیری خطی به صورت رابطه (۲) نوشته می‌شود.

$$f = \omega^T x + b \quad (۲)$$

که ω بردار n بعدی ضرایب صفحه جداکننده عمود بر مرز تصمیم‌گیری و x بردار ورودی و b بایاس است. هدف این است که اگر برچسب $y_i = 1$ باشد، $f_i = 1$ و اگر $y_i = -1$ باشد، $f_i = -1$ باشد، صفحه به‌درستی داده‌ها را دسته‌بندی می‌کند. درحقیقت صفحه، داده‌های با برچسب ۱ را به صورت خروجی ۱ و برچسب -۱ را به صورت -۱ پیش‌بینی می‌کند. می‌دانیم که معادله صفحه جداکننده با $f = 0$ برابر است. پارامترهای بهینه صفحه جداکننده با بیشترین حاشیه از مسئله بهینه‌سازی زیر یافت

پیش‌بینی قطعی خطوط شبکه توزیع با استفاده از الگوریتم ماشین بردار پشتیبان برای بهبود تاب‌آوری

طوفان‌اند - بین یک تا ۵۰ متر در نظر گرفته شده است؛ البته فاصله بالاتر از حدود ۱۰ متر تأثیر چندانی بر جلوگیری از تأثیر طوفان نخواهد داشت؛ بنابراین، تنها نقاطی که فاصله‌ای کمتر از ۱۰ متر دارند، به‌عنوان پارامتر مؤثر در تعیین میزان خسارت لحاظ می‌شوند. بازه فاصله از درخت یا هر شیء مشابه دیگر که احتمال آسیب به شبکه را دارد نیز بین ۰/۵ تا ۳۰ متر تا نقاط تعیین شده در نظر گرفته می‌شود؛ اما تنها تا فاصله ۵ متر در تعیین خسارت مؤثرند. همچنین، فاصله از مرکز طوفان بین صفر تا ۲ کیلومتر در نظر گرفته می‌شود. ویژگی چهارم، سرعت طوفان است. سرعت طوفان بین ۱۰ تا ۱۰۰ کیلومتر بر ساعت فرض می‌شود. آخرین ویژگی نیز نوع کابل به‌کاررفته در شبکه است که در دو حالت باز یا پیچیده استفاده می‌شود. برخلاف ویژگی‌های قبلی، این ویژگی یک ویژگی باینری در نظر گرفته شده است. به‌ازای کابل انتقال باز، عدد صفر و به‌ازای کابل انتقال پیچشی، عدد ۰/۲۵ برای ویژگی مدنظر فرض می‌شود. درنهایت، تمامی مقادیر در نظر گرفته شده برای ویژگی‌ها در بازه مدنظر نرمالیزه می‌شوند. اگر پنج ویژگی فاصله از ساختمان، فاصله از درخت، فاصله از مرکز طوفان، سرعت باد و نوع کابل به‌کاررفته به‌ترتیب با متغیرهای A, B, C, D و E نشان داده شوند، پس از نرمالیزه‌کردن آنها خواهیم داشت

$$A \in (0, 50) \rightarrow \begin{cases} A_1 \in (0, 1) \\ A_2 \in (10, 50) \end{cases} \rightarrow \bar{A}_1 \in (0, 1) \quad (6)$$

$$B \in (0, 5, 30) \rightarrow \begin{cases} B_1 \in (0, 5, 5) \\ B_2 \in (5, 30) \end{cases} \rightarrow \bar{B}_1 \in (0, 1) \quad (7)$$

$$C \in (0, 2000) \rightarrow \bar{C} \in (0, 1) \quad (8)$$

$$D \in (10, 100) \rightarrow \bar{D} \in (0, 1) \quad (9)$$

$$E \in (0, 25) \quad (10)$$

اکنون می‌توان مقدار احتمال خرابی نقاط مشخص شده مطابق با توجه به مقدار ویژگی فاصله از ساختمان و درخت با یکی از تساوی‌های زیر مشخص می‌شود.

$$P_i = (\bar{A}_1 + \bar{D}) - (\bar{B}_1 + \bar{C} + \bar{E}), i \in \bar{A}_1, i \in \bar{B}_1 \quad (11)$$

$$P_i = (\bar{A}_1 + \bar{D}) - (\bar{C} + \bar{E}), i \in \bar{A}_1, i \notin \bar{B}_1 \quad (12)$$

$$P_i = (\bar{D}) - (\bar{B}_1 + \bar{C} + \bar{E}), i \notin \bar{A}_1, i \in \bar{B}_1 \quad (13)$$

$$P_i = (\bar{D}) - (\bar{C} + \bar{E}), i \notin \bar{A}_1, i \notin \bar{B}_1 \quad (14)$$

$$\begin{aligned} \min \Psi(\alpha) &= \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) - \sum_{i=1}^n \alpha_i \\ s.t \quad K(x_i, x_j) &= \phi(x_i) \phi(x_j) \\ 0 < \alpha_i < c, \forall i \\ \sum_{i=1}^n \alpha_i y_i &= 0 \end{aligned} \quad (5)$$

منظور از ϕ یک تابع هسته (کرنل) است. درحقیقت ما نقاط x_i, x_j را با استفاده از تابع ϕ به یک صفحه جدید نگاشت داده‌ایم. انواع کرنل‌هایی که عموماً استفاده می‌شوند، در جدول (۱) آورده شده‌اند.

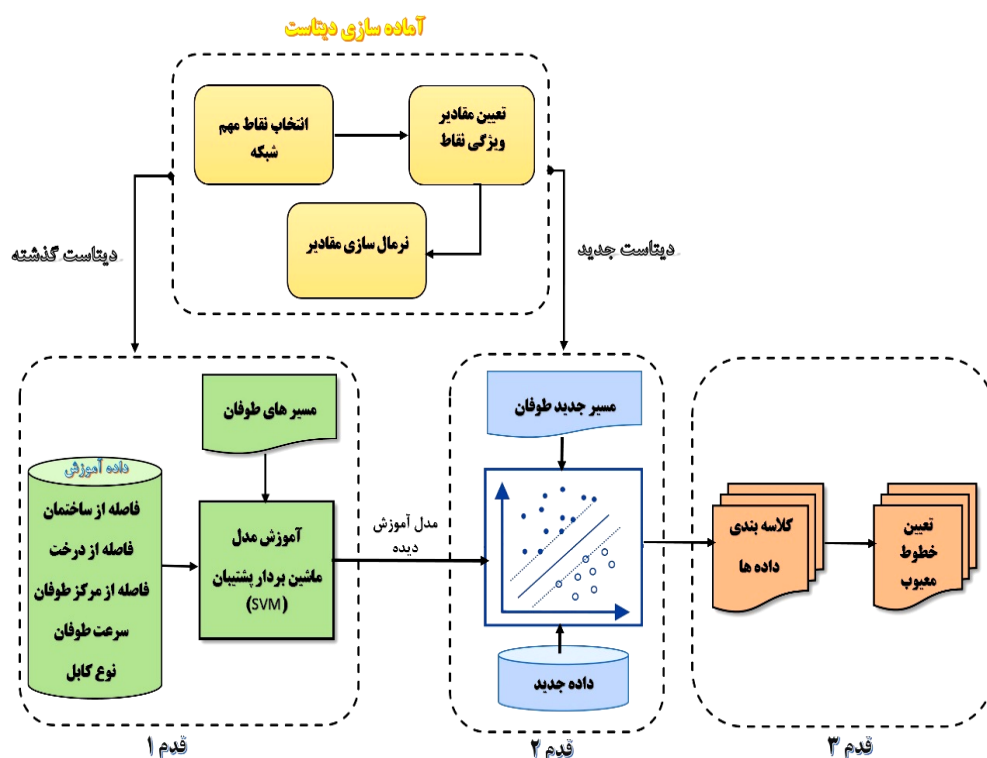
جدول (۱): چهار کرنل عمومی

پارامتر	رابطه	کرنل
-	$K(x_i, x_j) = x_i \cdot x_j$	خطی
d	$K(x_i, x_j) = (1 + x_i \cdot x_j)^d$	چندجمله‌ای
σ	$K(x_i, x_j) = e^{-\frac{\ x_i - x_j\ ^2}{2\sigma^2}}$	گوسین
k, c	$K(x_i, x_j) = \tanh(kx_i \cdot x_j + c)$	تانژانت هیپربولیک

برای این منظور، شبیه‌سازی در دو قسمت مختلف انجام می‌شود. قسمت اول مربوط به ارزیابی و تعیین کیفیت کلاس‌بند مدنظر است؛ به همین دلیل، تعدادی نقطه به‌عنوان داده‌های آموزشی و تعدادی نقطه به‌عنوان داده آزمایشی در نظر گرفته شده‌اند و دقت کلاس‌بند با توجه به آنها سنجیده می‌شود. برای این منظور، ۲۵۶ نقطه مهم برای شبکه فرضی، انتخاب و ویژگی‌های معرفی شده در قسمت قبل برای آن تعیین می‌شود. سپس به کمک کلاس‌بند ماشین بردار پشتیبان، وضعیت نقاط از لحاظ «سالم» یا «معیوب» پس از طوفان مشخص می‌شود. در ابتدا لازم است پنج ویژگی معرفی شده برای نقاط تعیین شود. تمامی مقادیر تعیین شده به‌عنوان ویژگی به‌صورت رندم یکنواخت انتخاب می‌شوند. در ویژگی اول، فرض می‌شود با توجه به مطالعه‌شدن شبکه توزیع، بازه فاصله هر نقطه مهم شبکه - که همان فاصله خطوط هوایی شبکه توزیع از ساختمان بلند در هنگام

مشخص می‌کند و برای کمتر از این مقدار، حکم به سلامت آن می‌دهد. به این ترتیب، وضعیت سلامت و آسیب‌دیدگی نقاط فرض می‌شود. این پیش‌بینی با مدل نشان داده شده در شکل (۵) انجام می‌شود.

مقدار P محاسبه شده برای هر نقطه در روابط بالا بین ۲- تا ۲+ است. در اینجا فرض می‌شود مقادیر بالاتر از ۰/۵ برای پارامتر P به‌ازای هر نقطه، آسیب‌دیدگی آن نقطه را



شکل (۵): شماتیک مدل پیشنهادی

می‌شوند. از روش اعتبارسنجی متقابل (Cross Validation) برای ارزیابی داده استفاده شده است. سپس کلاس‌بندی نقاط به کمک طبقه‌بند SVM مبتنی بر ویژگی‌های مشخص شده تعیین می‌شود. با شبیه‌سازی روش بیان شده نتایج طبق جدول ۲ به دست می‌آیند. همان‌گونه که مشخص است، کلاس‌بند با ۲۵۶ داده مشخص شده آموزش و ارزیابی شده است.

مسئله در سه مرحله متوالی حل می‌شود. در قدم نخست، مدل با داده و مسیرهای قبلی طوفان برای دسته‌بندی خطوط شبکه توزیع به دو دسته سالم یا معیوب آموزش داده می‌شود. در قدم دوم، داده‌های جدید به همراه کانال‌های جدید طوفان پیش‌بینی شده از ایستگاههای هواشناسی به مدل داده می‌شوند. در قدم سوم، خروجی شبیه‌سازی، دسته‌بندی داده‌ها را انجام می‌دهد که می‌توان خطوط معیوب و قطع شده را مشخص کرد. فلوچارت آموزش و پیش‌بینی مدل در شکل ۶ انجام می‌شود.

۴- طبقه‌بندی کننده

اکنون داده‌ها به دو دسته آموزشی و آزمایشی، تقسیم و به کمک کلاس‌بند SVM وضعیت نقاط تست تخمین زده

پیش‌بینی قطعی خطوط شبکه توزیع با استفاده از الگوریتم ماشین بردار پشتیبان برای بهبود تاب‌آوری

تشخیص داده است؛ ۳ نقطه.

بر طبق جدول ۲، از تعداد ۲۱۳ نقطه سالم، ۲۱۰ نقطه به‌درستی تشخیص داده شده و به‌ازای ۴۳ نقطه ناسالم نیز ۳۸ نقطه صحیح تخمین زده شده است.

پارامتر ارزیابی در نظر گرفته شده دقت کل است که با توجه به مقادیر ماتریس درهم‌ریختگی به شرح زیر تعریف شده و برای هر کرنل SVM در جدول ۲ گزارش شده است:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (15)$$

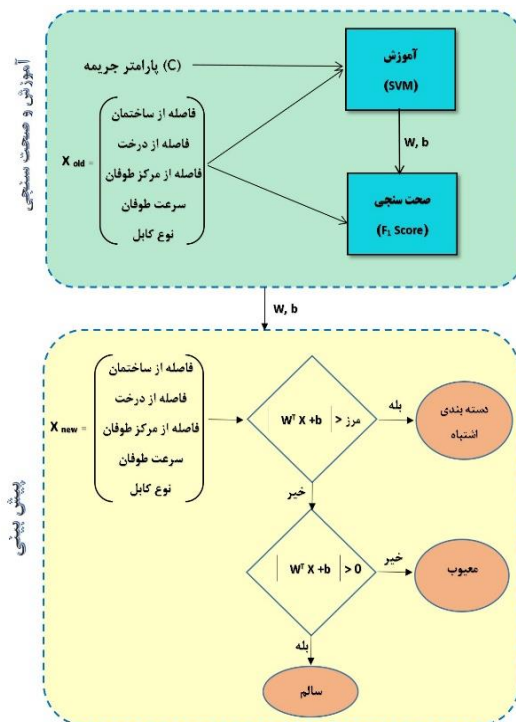
برای مقایسه بهتر تأثیرگذاری ویژگی‌ها روی شبیه‌سازی، دو معیار حساسیت و رده‌بند نیز معرفی می‌شوند. معیار اول، حساسیت است که در رابطه (۱۶) نشان داده شده است.

$$Sensitivity = \frac{TP}{TP + FN} \quad (16)$$

که در آن TP (مثبت درست) تعداد تشخیص‌های درست قطعی خطوط و FN+TP (مثبت درست + منفی غلط) کل خطوط قطع را گزارش می‌دهد. دیگر معیار ارزیابی، معیار مختصات رده‌بند است. در رابطه (۱۷)، TN منفی درست است و معیار بیان‌کننده توانایی رده‌بند برای انتخاب درست خطوطی است که سالم‌اند (منفی) و TN+FP خطوطی کاملاً سالم را گزارش می‌دهد.

$$Specificity = \frac{TN}{TN + FP} \quad (17)$$

برای اینکه در جدول ۳ نشان داده شود اگر از پنج ویژگی به‌طور هم‌زمان برای شبیه‌سازی استفاده شود، پیش‌بینی دقیق‌تری خواهیم داشت، ویژگی‌ها به دسته‌های دوتایی و سه‌تایی تقسیم شده‌اند. سرعت طوفان، فاکتور بسیار مهمی در هنگام طوفان است؛ بنابراین، هر بار این ویژگی با بقیه ویژگی‌ها یک دسته ویژگی تشکیل داده است. همچنین، مدلی موفق است که در هر سه پارامتر نتایج خوبی داشته باشد. در مقایسه دسته ویژگی‌ها، ماشین بردار پشتیبان خطی با پنج ویژگی، نتایج خیلی بهتر و بالاتری در هر سه معیار گزارش داد؛ بنابراین، تابع کرنل به‌کاررفته در کلاس‌بند SVM از نوع خطی با پنج ویژگی به کار برده شده است؛ زیرا هم از لحاظ سادگی و هم از لحاظ سرعت کلاس‌بندی




شکل (۶): فلوچارت پیش‌بینی وضعیت نقاط

جدول (۲): ماتریس درهم‌ریختگی کلاس‌بند نقاط شبکه

		نقاط پیش‌بینی	
		ناسالم (+)	سالم (-)
نقاط واقعی	ناسالم (-)	FP=۵	TN=۲۱۰
	سالم (+)	TP=۳۸	FN=۳

- مثبت درست TP: این مقدار بیان‌کننده تعداد نقاطی است که ناسالم بوده و با مدل کاملاً ناسالم تشخیص داده شده است؛ ۳۸ نقطه.
- مثبت غلط FP: این مقدار بیان‌کننده تعداد نقاطی است که کاملاً سالم بوده و دسته‌بند به اشتباه آنها را ناسالم تشخیص داده است؛ ۵ نقطه.
- منفی درست TN: این مقدار بیان‌کننده تعداد نقاطی است که سالم بوده و با مدل کاملاً سالم تشخیص داده شده است؛ ۲۱۰ نقطه.
- منفی غلط FN: این مقدار بیان‌کننده تعداد نقاطی است که کاملاً ناسالم بوده و دسته‌بند به اشتباه آنها را سالم



شکل (۷): شبکه ۳۳ باس استاندارد IEEE با پوشش جنگلی یا مسکونی اطراف خطوط و کانال‌های طوفان

همان‌گونه که در این شماتیک نیز مشخص است شبکه شامل ۳۲ خط بین باس‌ها است. هر خط یا باس می‌تواند شامل چندین نقطه مهم باشد. نقاط مهم پیش‌تر توضیح داده شدند. در این شماتیک، نقاط مهم با دایره‌های قرمز رنگ روی خطوط مشخص شده‌اند که هر خط بین دو تا هفت نقطه پر اهمیت دارد. بدین ترتیب برای این شبکه ۳۳ باس، ۱۲۸ نقطه استراتژیک در نظر گرفته شده است. همچنین به‌طور ساده شرایط فیزیکی اطراف خط نیز مشخص شده است. خط بین باس‌های یک تا ۸ و ۱۹ تا ۲۲ پوشش عموماً مسکونی دارد؛ بنابراین، شامل ساختمان‌های بلند است و کمتر درخت بلند در آن دیده می‌شود. همچنین، حد فاصل بین باس ۸ تا ۱۲ و ۲۳ تا ۲۵ نیز غالباً پوشش جنگلی دارد؛ بنابراین، شامل درخت‌های بلند است که امکان آسیب‌رساندن به تجهیزات شبکه از سوی درخت‌ها در هنگام طوفان وجود دارد. مابقی خطوط نیز محیطی مابین جنگلی و مسکونی دارد. همچنین، برای این شبکه فرض می‌شود دو طوفان پیش‌تر رخ داده و اطلاعات کامل آن در دسترس است. هر دو این طوفان سه کاناله‌اند که کانال‌های اصلی آنها با فلش‌های آبی و زرد رنگ در شکل (۷) نمایان است. با توجه به در نظر گرفتن ۱۲۸ نقطه مهم در این شبکه و نیز در اختیار داشتن اطلاعات دو طوفان، امکان آموزش کلاس‌بند SVM که پیش‌تر معرفی شد، با ۲۵۶ داده وجود دارد. در ادامه، نتایج حاصل از تعیین وضعیت شبکه ۳۳ باس با وقوع

بر دو تابع دیگر ترجیح داده می‌شود. اکنون با محرز شدن مطلوبیت عملکرد و دقت کلاس‌بند، می‌توان در قسمت دوم شبیه‌سازی، تخمین وضعیت شبکه قدرت نمونه را پس از وقوع طوفان انجام داد. برای این منظور، شبکه استاندارد ۳۳ باس IEEE در نظر گرفته شده است. نقاط مهم شبکه روی آن مشخص شده و ویژگی متناسب با هر نقطه نیز به دست آمده است. شبکه مدنظر به همراه شرایط محیطی و نقاط پر اهمیت آن در شماتیک (۳) مشخص شده است.

جدول (۳): مقایسه دقت کلاس‌بند با کرنل و دسته ویژگی‌های مختلف

ویژگی‌ها	تابع کرنل SVM	دقت	حساسیت	رده‌بند
فاصله از ساختمان	خطی	۹۶٪/۸۳	۸۷٪/۶۷	۹۸٪/۶۱
	شعاعی	۸۳٪/۲۳	۰٪/۵	٪۱۰۰
فاصله از درخت	چندجمله‌ای	۹۱٪/۳۷	۴۸٪/۵۰	۹۹٪/۵۲
		خطی	۸۳٪/۱۳	۴۲٪/۸۳
فاصله از مرکز طوفان	شعاعی	۸۳٪/۲۳	۱٪/۴	۹۸٪/۸۱
	چندجمله‌ای	۸۱٪/۳۲	۳٪/۱۰	۹۹٪/۳
سرعت طوفان	خطی	۸۹٪/۴۰	۴۳٪/۵۰	۹۸٪/۱۴
	شعاعی	۸۲٪/۲۳	۰	٪۱۰۰
فاصله از مرکز طوفان	چندجمله‌ای	۸۶٪/۳۲	٪۱۷	۹۹٪/۹۵
	خطی	۸۲٪/۰۳	۴٪/۶۵	۹۷٪/۶۵
فاصله از ساختمان	شعاعی	۸۳٪/۲۳	۰	٪۱۰۰
	چندجمله‌ای	۸۳٪/۲۳	۲٪/۱۵	٪۱۰۰
سرعت طوفان	خطی	۸۹٪/۴۰	۳۹٪/۵۰	۹۹٪/۰۷
	شعاعی	۸۳٪/۴۳	۰	٪۱۰۰
فاصله از ساختمان	چندجمله‌ای	۸۴٪/۷۷	۸٪/۵۰	۹۸٪/۶۳


پیش‌بینی قطعی خطوط شبکه توزیع با استفاده از الگوریتم ماشین بردار پشتیبان برای بهبود تاب‌آوری

وضعیت شبکه پیش از وقوع طوفان است. در نهایت، خطوط ۱۰۸، ۱۴ و ۲۷ به‌عنوان خط‌های قطع شده مشخص شده‌اند که با دانستن وضعیت خطوط شبکه، اقدامات پیشگیرانه همچون آماده‌بودن تیم تعمیر در محل‌های آسیب‌دیده و بازآرایی شبکه برای حذف بار کمتر صورت گیرد. نکته مهم در این شبیه‌سازی این است لزوماً سرعت باد یا نزدیکی به مرکز طوفان یا ترکیبی از ویژگی‌ها علت قطعی خطوط نخواهد بود. ممکن است سرعت باد زیاد نباشد؛ اما به دلیل وجود درخت در کنار خط باعث قطعی خط شود. در مقابل ممکن است طوفان، شدید باشد؛ اما در مسیرهایی که ساختمان بلند و عریض قرار دارند، خطر کمتری خطوط را تهدید کند.

مراجع

- [1] Gengfeng, L., et al., "Component importance assessment of power systems for improving resilience under wind storms", *Journal of Modern Power Systems and Clean Energy*, Vol.7, No.4, pp. 676-687, 2019.
- [2] Eskandarpour, R. and A. Khodaei, "Machine learning based power grid outage prediction in response to extreme events". *IEEE Transactions on Power Systems*, Vol.32, No.4, pp. 3315-3316, 2016.
- [3] Eskandarpour, R. , A. Khodaei, Ali Arab, "Improving Power Grid Resilience Through Predictive Outage Estimation", *North American Power Symposium (NAPS)*, 2017.
- [4] Ke Yan, Yang Du, Zixiao Ren, "MPPT Perturbation Optimization of Photovoltaic Power Systems Based on Solar Irradiance Data Classification", *IEEE Transactions on Sustainable Energy*, Vol.10, No.2, pp.514-521, 2018.
- [5] Seyed Mahdi Miraftebzadeh, Federica Foidelli, Michela Longo, Marco Pasetti, "A Survey of Machine Learning Applications for Power System Analytics", *IEEE International Conference on Environment and Electrical Engineering*, 2019.
- [6] RozhinEskandarpour, and AminKhodaei, "Leveraging Accuracy-Uncertainty Tradeoff in SVM to Achieve Highly Accurate Outage Predictions", *IEEE Transactions on Power Systems*, Vol. 33, No. 1, pp.1139-1141, 2018.
- [7] Papia Ray , Debani Prasad Mishra, "Support Vector Machine Based Fault Classification and Location of a Long Transmission line", *Engineering Science and Technology, an International Journal*, Vol.19, No.3, pp. 1368-1380, 2016.
- [8] Han Seung Jang, , Kuk Yeol Bae, Hong-Shik Park, and Dan Keun Sung, "Solar Power Prediction Based on Satellite Images and Support Vector Machine", *IEEE Transactions on Sustainable Energy*, Vol.105, No.7, pp.1202-1213, 2016.

طوفان جدید برای آن بیان خواهد شد. درخور ذکر است کانال‌های اصلی طوفان جدید مطابق با فلش‌های قرمز رنگ شکل ۸ در نظر گرفته می‌شوند.



شکل (۸): مسیر کانال‌های طوفان جدید روی شبکه مطالعه شده

پس از تعیین مقادیر ویژگی‌ها برای خطوط شبکه فوق و اعمال آن به کلاس‌بند آموزش دیده، مشخص شد خطوط ۱۰۸، ۱۴ و ۲۷ در حین طوفان جدید، قطع و از شبکه خارج می‌شوند.

۵- نتیجه‌گیری

پیش‌بینی وضعیت یک جزء در پاسخ به یک رویداد شدید در عمل چالش‌برانگیز است. در این مقاله، نتایج حاصل از وقوع طوفان روی شبکه قدرت و تخمین خسارات حاصل از آن بررسی شده‌اند. هدف اصلی، پیش‌بینی خطوط هوایی شبکه توزیع است؛ این پیش‌بینی در کنترل خسارات مؤثر است. ویژگی‌های مؤثر در تشخیص معرفی شدند و از کلاس‌بند SVM خطی نیز به‌عنوان طبقه‌بند داده‌ها در دو کلاس «عملیاتی» و «قطع» استفاده شد. همان‌طور که می‌دانیم داده‌های واقعی درباره تأثیر طوفان بر اجزای شبکه قدرت محدود است؛ بنابراین، مجموعه‌ای از داده‌های مصنوعی برای آموزش SVM تولید شد. ۲۵۶ نقطه در یک شبکه توزیع، انتخاب و مقادیر ویژگی‌ها برای آن به صورت تصادفی یکنواخت شدند. کلاس‌بندی به کمک داده‌های تعیین شده با دقت $96/83\%$ حاصل شد که بیان‌کننده کیفیت بالای روش پیشنهادی برای تخمین

- [9] L. Wehenkel, "Machine-learning approaches to power-system security assessment", IEEE Expert, Vol. 12, No. 5, pp. 60–72, 1997.
- [10] Weicong Kong, Zhao Yang Dong, David J. Hill, Fengji Luo, Yan Xu, "Short-Term Residential Load Forecasting based on Resident Behaviour Learning", IEEE Transactions on Power Systems, Vol.33, No.1, pp.1087-1088, 2016.
- [11] Ke Yan, Yang Du, Zixiao Ren, "MPPT Perturbation Optimization of Photovoltaic Power Systems Based on Solar Irradiance Data Classification", IEEE Transactions on Sustainable Energy, Vol.10, No.2, pp.514-521, 2018.
- [12] Xing, X., et al, "Model predictive control of LPC-looped active distribution network with high penetration of distributed generation", IEEE Transactions on Sustainable Energy, Vol.8, No.3, pp.1051-1063, 2017
- [13] Diego Cerrai , Marika Koukoulou, Peter Watson, Emmanouil N. Anagnostou, "Outage prediction models for snow and ice storms", Sustainable Energy, Grids and Networks, Vol.21, 2020.
- [14] D.Cerrai, David W. Wank, MD Abul Ehsan Bhuiyan, "Predicting Storm Outages Through New Representations of Weather and Vegetation", IEEE Access, Vol.7, pp. 29639 – 29654, 2019.
- [15] Astik Dhandhia, Vivek Pandya, Praghmesh Bhatt, "Multi-class support vector machines for static security assessment of power system", Ain Shams Engineering Journal, Vol.11, No.1, pp.57-65, 2019.
- [16] Jaber Sohrabi, Majid Moazami, "Probabilistic mid-term net load forecasting considering the effect of solar power using extreme learning machine", Computational Intelligence in Electrical Engineering, Vol. 11, No. 2, 2020.
- [17] Masoud Sharifian, Hossein Karshenas , Saeid Sharifian, "Improving Network Intrusion Detection by Identifying Effective Features using Evolutionary Algorithms based on Support Vector Machine", Computational Intelligence in Electrical Engineering, Vol. 11, No. 1, 2020.

