

ارزیابی امنیت دینامیکی سیستم‌های قدرت با استفاده از الگوریتم‌های یادگیری جمعی

امین صفری^{۱*}، زهرا بهاری لشکری^۲، میثم شهریار^۳

۱- دانشیار، ۲- دانشجوی کارشناسی ارشد، ۳- دانشجوی دکتری، دانشگاه شهید مدنی آذربایجان

(دریافت: ۱۴۰۲/۰۴/۲۹، بازنگری: ۱۴۰۲/۰۸/۱۴، پذیرش: ۱۴۰۲/۰۸/۱۹، انتشار: ۱۴۰۲/۰۹/۱۳)

DOR: <https://dorl.net/dor/>

چکیده

باتوجه به اهمیت ارزیابی امنیت دینامیکی و ضرورت انجام اقدامات کنترلی پس از بروز اغتشاش، ارزیابی امنیت دینامیکی آنلاین جایگزین ارزیابی آفلاین شده است. روش‌هایی که به‌طور رایج در ارزیابی امنیت دینامیکی به کار برده می‌شوند در مواجهه با پیشامدهای خطرناک که سرعت وقوع بالایی داشته باشند، مناسب نیستند. بنابراین، ضروری است تا ارزیابی پایداری گذرا به‌صورت آنلاین و در زمان واقعی انجام گیرد تا اپراتورها فرصت مناسب برای انجام اقدام اصلاحی را داشته باشند. به همین منظور در این مطالعه، از روش‌های یادگیری ماشین جمعی جهت ارزیابی امنیت دینامیکی آنلاین بهره گرفته شده است. مسئله موردبررسی یک طبقه‌بندی چند کلاسی است که به طبقه‌بندی وضعیت امنیت دینامیکی سیستم می‌پردازد. روش پیشنهادی بر روی دو سیستم استاندارد مورد ارزیابی قرار گرفته است. همچنین مقایسه‌ای بین روش‌های یادگیری جمعی پیشنهادی با الگوریتم‌های منفرد انجام گرفته است. نتایج حاکی از آن است که روش پیشنهادی ضمن دقت، از عملکرد مناسبی برخوردار بوده و برای ارزیابی امنیت دینامیکی آنلاین مناسب بوده است.

کلیدواژه‌ها: ارزیابی امنیت دینامیکی، الگو شناسی، انتخاب ویژگی، پیش‌بینی، درخت تصمیم جمعی، یادگیری ماشین

Dynamic Security Assessment of Power Systems Using Ensemble Learning Algorithms

A. Safari^{*}, Z. Bahari Lashkari, M. Shahriyari

Azarbaijan Shahid Madani University

(Received: 2023/07/20, Revised: 2023/11/05, Accepted: 2023/11/10, Published: 2023/05/08)

Abstract

Considering the importance of dynamic security assessment and the necessity of implementing control measures after a disturbance, online dynamic security assessment has replaced offline assessment. Methods which are commonly used in dynamic security evaluation are not suitable for serious events which have a high rate of occurrence. Therefore, it is essential to perform real time transient stability assessment in order to increase operators opportunity to take remedial actions. For this purpose, in this study, ensemble machine learning methods have been used to evaluate online dynamic security. The investigated problem is a multi-class classification that deals with classifying of system's dynamic security status. The proposed method has been evaluated on two standard systems. Also, a comparison has been made between the proposed ensemble learning methods and individual algorithms. The results indicate that the proposed method, not only accurate but also has good performance in evaluating online dynamic security.

Keywords: Dynamic Security zAssessment, Pattern Recognition, Feature Selection, Prediction, Ensemble Decision Tree, Machine Learning

*Corresponding Author E-Mail: Safari@Azaruniv.Ac.Ir

۱. مقدمه

امروزه روش‌های گروهی یا جمعی^{۱۰} که مبتنی بر روش‌های پایه یادگیری ماشین هستند و عموماً عملکرد بهتری به نسبت روش‌های منفرد داشته به‌منظور افزایش کارایی مورد بهره‌برداری قرار می‌گیرند. در این روش‌ها طبقه‌بندی‌کننده‌های منفرد با یکدیگر جهت ارتقای قابلیت طبقه‌بندی و پیش‌بینی ترکیب می‌شوند [۷]. بهره‌گیری از روش‌های جمعی در مسائل مربوط به ارزیابی امنیت دینامیکی آنلاین می‌تواند دقت و کیفیت ارزیابی را بالاتر برد.

از روش‌های یادگیری الگو به‌مراتب در مطالعات مختلف جهت ارزیابی امنیت سیستم قدرت استفاده شده است. از ماشین بردار پشتیبان چند رده‌بندی‌شده برای ارزیابی امنیت استاتیکی و گذرا در سیستم قدرت استفاده شده است و شاخص‌های اضافه‌بار خطوط و فروپاشی ولتاژ برای ارزیابی امنیت استاتیکی و شاخص امنیت گذرا برای ارزیابی امنیت گذرا استفاده شده‌اند [۸]. همچنین، از روش انتخاب ویژگی متوالی روبه‌جلو^{۱۱} بهره گرفته شده است. از دو درخت تصمیم برای ارزیابی آنلاین امنیت دینامیکی و انجام اقدامات پیشگیرانه استفاده شده است [۹]. شبیه‌سازی‌های انجام‌شده در مقابل خروج یک و یا چند تجهیز بررسی‌شده است که در آن برای هر پیشامد دو درخت تصمیم ایجاد شده است. یکی از درختان تصمیم برای تشخیص امنیت و دیگری برای انجام اقدام پیشگیرانه ساخته شده‌اند. برای ارزیابی امنیت از روش‌های جمعی نیز استفاده شده است و پس از تولید داده امنیت سیستم به ۴ دسته نرمال، هشدار، حالت بحرانی قابل اصلاح و حالت بحرانی غیرقابل اصلاح طبقه‌بندی شده است [۱۰]. برای ساخت الگوریتم جمعی از روش‌های تقویتی و جنگل تصادفی^{۱۲} بهره گرفته شده است. برای ارزیابی دقت عملکرد ماشین از شاخص کاپا^{۱۳} استفاده شده است. تکنیک جنگل تصادفی نیز برای ارزیابی آنلاین امنیت دینامیکی در حضور منابع تجدید پذیر بهره گرفته شده است و جهت تولید داده از داده‌های تاریخی استفاده شده و عدم قطعیت باد و تغییر میزان بار نیز در نظر گرفته شده است [۱۱]. از یک روش جمعی مبتنی بر ماشین بردار پشتیبان نیز برای ارزیابی پایداری گذرا استفاده شده است و داده ورودی با تغییر میزان بارگذاری شبکه و اعمال خطای اتصال کوتاه بر روی خطوط شبکه ایجاد شده است. انتخاب ویژگی از طریق روش همبستگی^{۱۴} ویژگی‌های ورودی صورت گرفته است [۱۲].

منبع انرژی الکتریکی پایدار از الزامات جامعه مدرن و متمدن کنونی است. تقاضای انرژی هرساله با توجه به رشد جمعیت و گسترش شهرها افزایش می‌یابد و در نتیجه ساختار سیستم‌های قدرت پیچیده‌تر می‌شود. سیستم‌های قدرت به‌گونه‌ای طراحی شده‌اند که در شرایط نسبتاً پایدار و بارگذاری مناسب مورد بهره‌برداری قرار گیرند. با این حال، فرضیات طراحی ممکن است به دلیل پیشامدهای مختلف اعم از طبیعی و غیرطبیعی، فنی و غیرفنی تحت تأثیر قرار گرفته و باعث قطعی و یا خرابی کل شبکه شود. وقوع خرابی و یا از دست دادن جزء کوچکی از سیستم قدرت مانند خط انتقال یا یک تجهیز مجزا همانند ژنراتور و ترانسفورماتور به معنای رخداد پیشامد است. خروج یک خط ممکن است منجر به ایجاد اضافه‌بار در سایر خطوط شده و یا حتی افت ناگهانی ولتاژ را ایجاد کند. از این‌رو، ارزیابی امنیت سیستم قدرت از موضوعات مهم روز به شمار می‌آید [۱].

براین اساس، در ارزیابی امنیت سیستم قدرت به این مسئله پرداخته می‌شود که در هنگام وقوع پیشامدهای احتمالی در سیستم، نقطه کار سیستم تغییر نکند و یا در صورت تغییر، در نزدیکی نقطه کار قبلی ثابت شود [۲]. امنیت سیستم قدرت غالباً در دو حالت استاتیکی و دینامیکی مورد ارزیابی قرار می‌گیرد. ارزیابی امنیت دینامیکی به بررسی مقاومت سیستم در برابر پیشامدهای احتمالی و عبور از حالت گذرا و رسیدن به حالت دائمی می‌پردازد [۳]. با توجه به اهمیت ارزیابی امنیت دینامیکی برای اپراتورهای سیستم و ضرورت استفاده از آن در تصمیم‌گیری‌های پس از وقوع اغتشاش، ارزیابی امنیت آنلاین ضرورت بیشتری نسبت به ارزیابی آفلاین پیدا کرده است [۴].

اخیراً در مطالعات مربوط به ارزیابی امنیت دینامیکی آنلاین روش‌های تشخیص الگو^۱ به کار برده می‌شوند که از دقت و سرعت نسبتاً خوبی برخوردارند [۵]. روش‌های یادگیری ماشین^۲ را می‌توان در چهار دسته یادگیری نظارت شده^۳، یادگیری نظارت نشده^۴، یادگیری تقویتی^۵ و یادگیری نیمه نظارتی^۶ تقسیم‌بندی کرد. از جمله روش‌های یادگیری ماشین می‌توان به درخت تصمیم^۷، ماشین بردار پشتیبان^۸، K نزدیک‌ترین همسایه^۹ و غیره اشاره کرد [۶].

⁸ Support Vector Machines

⁹ K-Nearest Neighbors

¹⁰ Ensemble Methods

¹¹ Sequential Forward Feature Selection

¹² Random Forest

¹³ Kappa Coefficient

¹⁴ Input Feature Correlation

¹ Pattern Recognition Methods

² Machine Learning Algorithms

³ Supervised Learning

⁴ Unsupervised Learning

⁵ Reinforcement Learning

⁶ Semi-Supervised Learning

⁷ Decision Tree

شود و یا حتی لغزش قطب^۳ در ژنراتور رخ دهد. در صورتی که این شرایط هر چه سریع‌تر اصلاح نگردد لغزش قطب ژنراتور ادامه پیدا کرده و در نهایت منجر به خروج ژنراتور و ازدست‌رفتن سنکرونیزم سیستم شود [۱۳]. به‌طور کلی پایداری گذرا با در نظر گرفتن زاویه روتور باتوجه‌به رابطه زیر قابل‌تشخیص است که در آن s به معنای پایداری و ns ناپایداری را نشان می‌دهد.

$$\begin{cases} \text{if } \Delta\delta_{\max} \geq 180^\circ & ns \\ \text{if } \Delta\delta_{\max} < 180^\circ & s \end{cases} \quad (1)$$

در رابطه (۱)، $\Delta\delta_{\max}$ حداکثر اختلاف زاویه روتور بین هر دو ژنراتور پس از وقوع اغتشاش است [۱۴]. باوجوداینکه ناپایداری گذرا به‌ندرت رخ می‌دهد اما جز شدیدترین رخدادهایی است که ممکن است منجر به خروج‌های آبخاری^۴ و در نهایت خاموشی سراسری سیستم شود.

تابع لیاپانوف در بررسی پایداری گذرا به‌وفور در مقالات استفاده شده است. دلیل اصلی استفاده از تابع لیاپانوف سرعت بالای انجام محاسبات سنگین گذرا است که با استفاده از انرژی جنبشی ایجادشده در اثر وقوع اغتشاش صورت می‌پذیرد. این در حالی است که در بررسی‌های مبتنی بر تابع لیاپانوف از مدل‌های دینامیکی بار و ژنراتورها صرف‌نظر می‌شود. به عبارتی مدل‌های بیشتر از درجه‌دو ژنراتور در نظر گرفته نمی‌شود. در بررسی پایداری گذرا علاوه بر سرعت پردازش و انجام محاسبات، باید دقت ارزیابی نیز در نظر گرفته شود. از این‌رو، به‌جای استفاده از روش‌های سنتی به‌منظور ارزیابی پایداری گذرا از روش‌های مدرن مبتنی بر یادگیری ماشین استفاده شده است تا اولاً سریعاً به پیش‌بینی وضعیت نهایی سیستم قدرت پرداخته شود و ثانیاً به دلیل انجام شبیه‌سازی‌های گسترده در فاز آفلاین، دقت ارزیابی پایداری در روش‌های یادگیری ماشین بیش از روش‌های مرسوم دیگر است و ثالثاً روش‌های مبتنی بر یادگیری ماشین با اطلاعات ناقصی که از شبکه دریافت می‌کنند می‌توانند به ارزیابی شبکه بپردازند و نیازی نیست که اطلاعات کاملی از شبکه موجود باشد

باتوجه به این توضیحات، در صورتی که سرعت زاویه روتور یک ژنراتور یا گروهی از ژنراتورها از سایر ژنراتورها بیشتر شود ناپایداری گذرا رخ می‌دهد. حذف به‌موقع خطا و یا خروج تجهیز خطا دار از سیستم، در حفظ هماهنگی سرعت ژنراتورها و حفظ پایداری سیستم از اهمیت ویژه‌ای برخوردار است. زمان رفع خطای بحرانی^۵ از دیگر مسائل مهم در ارزیابی پایداری گذرا است. در برخی از مطالعات پایداری گذرا به بررسی این مسئله مهم پرداخته شده است تا باتوجه‌به نوع خطا، محل خطا، زمان وقوع خطا و از

در روش پیشنهادی با استفاده از الگوریتم‌های یادگیری ماشین جمعی به ارزیابی امنیت دینامیکی در مقابل اغتشاشات مختلف به‌صورت چند کلاسی^۱ پرداخته شده است. نوآوری‌های این مقاله عبارت‌اند از:

- روش‌های جمعی به دلیل بهبود کارایی و زمان اجرای حل مسئله جایگزین الگوریتم‌های یادگیری منفرد شده است.
- تولید داده‌های ورودی بدون دخالت انسان بوده و از الگوریتم‌های انتخاب ویژگی جهت جلوگیری از بیش‌برازش مدل و سریع‌تر کردن پروسه پیش‌بینی و پردازش ماشین‌های یادگیری بهره گرفته شده است.
- برخلاف اکثر مقالات، خروجی مدل باینری^۲ نبوده و چشم‌انداز مناسب‌تری از وضعیت عملکردی شبکه در اختیار اپراتورهای سیستم قدرت قرار می‌دهد تا براین‌اساس اقدامات کنترلی مناسب در دستور کار قرار گیرد. به عبارتی در این مقاله، خروجی ارزیابی امنیت در چهار بخش تقسیم‌بندی شده‌اند که محاسبات را پیچیده کرده اما نتایج خروجی نشان از توانایی روش پیشنهادی در مقابل مدل‌های پیچیده را دارد.

در ادامه، ابزار موردنیاز در ارزیابی آنلاین امنیت دینامیکی در بخش دوم شرح داده خواهد شد. چهارچوب کلی روش پیشنهادی در بخش سوم گردآوری شده است. در بخش چهارم نتایج شبیه‌سازی‌ها بررسی خواهد شد و نهایتاً نتیجه‌گیری در بخش پنجم ارائه خواهد شد.

۱-۲. ابزار موردنیاز

ارزیابی امنیت دینامیکی سیستم قدرت و پایداری گذرا همواره از موضوعات بسیار مهم در سیستم‌های قدرت به‌شمار می‌آید. امروزه گسترش استفاده از انرژی و در نتیجه افزایش نیاز به تولید، سبب شده تا سیستم‌های قدرت در شرایط پیچیده‌تری مورد بهره‌برداری قرار گیرند که در واقع محدوده امنیتی و پایداری آن‌ها را به خطر می‌اندازد. در چنین شرایطی در صورت وقوع پیشامد در شبکه قدرت، امکان ازدست‌رفتن امنیت دینامیکی و پایداری شبکه و حتی قطعی گسترده در شبکه محتمل است.

هدف ارزیابی پایداری گذرا بررسی رفتار دینامیکی سیستم قدرت، قبل و بعد از وقوع خطا و همچنین بررسی توانایی سیستم در مقابله با اغتشاشات رخ داده در سیستم است. زمانی که اغتشاشی مانند خطای اتصال کوتاه سه‌فاز در سیستم قدرت رخ می‌دهد، ممکن است به‌قدری شدید باشد که منجر به تجاوز زاویه روتور ژنراتور (نسبت به زاویه روتور ژنراتور مرجع) از مقدار بحرانی

³ Pole Slip


⁴ Cascade Failure

⁵ Critical Clearing Time

¹ Multiclass Classification

² Binary

نیاز به استفاده از طبقه‌بندی‌کننده چند کلاسی است. شکل (۱) نشان‌دهنده تفاوت طبقه‌بندی‌کننده باینری و چند کلاسی است. در طبقه‌بندی چند کلاسی دو فرض اصلی وجود دارد: الف) هر داده تنها می‌تواند متعلق به یک دسته باشد. ب) برچسب‌ها مستقل از یکدیگر هستند یعنی هیچ ارتباط و همبستگی بین برچسب‌های مختلف وجود ندارد.



شکل ۱. طبقه‌بندی الف) باینری و ب) طبقه‌بندی چند کلاسی

طبقه‌بندی داده‌ها بخصوص برای مسائل طبقه‌بندی چند کلاسی لزوماً همیشه بسیار دقیق انجام نمی‌گیرد که این مورد برای داده‌های بزرگ‌تر حتی دشوارتر و پیچیده‌تر نیز است. به همین منظور در غالب مطالعات مختلف برای حل مشکل طبقه بندی چند کلاسی از دو روش در ایجاد طبقه‌بندی‌کننده استفاده می‌کنند.

- استفاده از تکنیک‌های یادگیری کارآمدتر: به‌عنوان مثال، به‌کارگیری یادگیرنده‌های جمعی با ایده استفاده هم‌زمان از چند یادگیرنده برای دستیابی به طبقه‌بندی‌کننده بهینه و پیش‌بینی دقیق‌تر.
- ایجاد تغییرات در مجموعه داده‌ها: استفاده از انواع روش‌های انتخاب ویژگی به‌منظور کاهش ابعاد مسئله و همچنین روش‌های بیش نمونه‌برداری یا زیر نمونه‌برداری [۱۹].

درخت تصمیم به‌عنوان یکی از الگوریتم‌های نظارت شده، درختی است که از بالا به پایین بر مبنای اطلاعات پایه تشکیل می‌شود. مطابق شکل (۲) درخت تصمیم همانند درخت معمولی از اجزایی مانند ریشه، شاخه و برگ تشکیل شده است. گره آغازین درخت که والد تمامی گره‌ها است گره ریشه^۱ نامیده می‌شود. در درخت تصمیم هر گره یک ویژگی، هر شاخه نشان‌دهنده یک تصمیم و در نهایت برچسب هر طبقه یا دسته در برگ‌ها نشان داده می‌شود. در یک درخت تصمیم برای پیش‌بینی وضعیت نهایی مجموعه داده‌های موجود، از گره ریشه شروع کرده و مقادیر ویژگی‌های ریشه را با ویژگی‌های مجموعه داده واقعی مقایسه می‌کند و براین‌اساس یک شاخه را دنبال کرده و به گره بعدی می‌رود.

همه مهم‌تر زمان رفع آن شرایط سیستم قدرت را مورد بررسی قرار دهند. در هنگام بروز خطا، زمان رفع خطای بحرانی حداکثر مدت‌زمان ممکن برای رفع خطا بدون ایجاد اختلال در عملکرد سیستم است. در صورتی که خطا در بازه زمانی کمتر از زمان رفع خطای بحرانی برطرف گردد، سیستم به عملکرد عادی خود ادامه داده و در واقع پس از سپری کردن نوسانات گذرا به یک حالت پایدار جدید خواهد رسید در غیر این صورت ممکن است زاویه روتور ژنراتور دچار تغییرات اساسی شده و ژنراتور از حالت سنکرون خارج شده و سیستم دچار ناپایداری شود [۱۵]. تعیین زمان رفع خطای بحرانی با استفاده از روش‌های مختلف از جمله استفاده از توابع انرژی و یا بهره‌گیری از روش شبیه‌سازی معادلات غیرخطی [۱۶] امکان‌پذیر است. این روش‌ها غالباً برای سیستم‌هایی با تعداد تجهیزات زیاد از لحاظ محاسباتی مناسب نبوده و روش‌هایی زمان‌گیر و یا غیردقیق به شمار می‌آیند.

به‌منظور مطمئن‌تر بودن زمان رفع خطا بحرانی برای یک تجهیز مانند خط انتقال معمولاً بدترین حالت اغتشاش را در نظر گرفته و زمان رفع خطای بحرانی را متناسب با آن شرایط به دست می‌آورند. از این‌رو در اکثر مطالعات جهت یافتن زمان رفع خطای بحرانی با هر روشی معمولاً خطای سه‌فاز اعمال شده و با توجه به آن زمان رفع خطا بحرانی محاسبه می‌گردد.

۱-۳. الگوریتم‌های یادگیری ماشین


الگوریتم‌های یادگیری ماشین به‌ویژه الگوریتم‌های نظارت شده، با داشتن قابلیت الگو شناسی، یادگیری، سرعت بالای محاسبات و سرعت بالای تعیین محدوده‌های امنیتی از روش‌های محبوب در ارزیابی آنلاین امنیت دینامیکی به حساب می‌آیند [۱۷].

در روش‌های یادگیری ماشین نظارت شده برای هر نمونه مورد مطالعه یک بردار ویژگی x و یک برچسب خروجی y وجود دارد. فرض می‌شود که تابعی با نام f ارتباطی بین x و y به صورت $y = f(x)$ ایجاد می‌کند. هدف الگوریتم‌های یادگیری، رسیدن به تقریب خوبی از h نسبت به f است. به h طبقه‌بند گفته می‌شود چراکه x را به یک طبقه و یا دسته از y مرتبط می‌سازد. با استفاده از این روند در صورت وجود یک نمونه مورد مطالعه جدید می‌توان تشخیص داد که این داده متعلق به کدام دسته از y خواهد بود که به این روند طبقه‌بندی داده گفته می‌شود [۱۸]. طبقه‌بندی در یادگیری ماشین بدین معناست که تشخیص داده شود یک داده جدید متعلق به کدام دسته و طبقه از داده‌های برچسب است. زمانی که در خروجی تنها دو نوع دسته وجود داشته باشد در این صورت طبقه‌بندی باینری انجام می‌گیرد. در صورتی که تعداد دسته‌ها در برچسب بیش از دو حالت باشد

¹ Root Node

دو روش اصلی برای ایجاد یادگیرنده‌های جمعی وجود دارد که عبارت‌اند از:

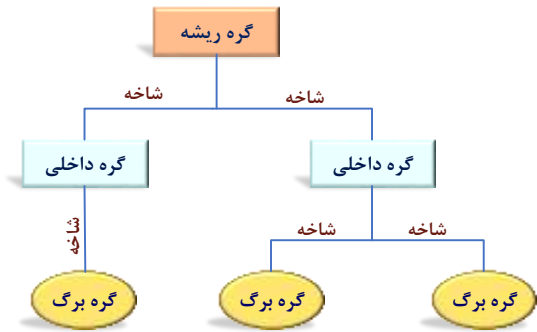
الف) روش دسته‌بندی^۱: این روش برای کاهش واریانس به کار برده می‌شود. در ابتدا مجموع داده‌هایی به صورت تصادفی از داده اصلی انتخاب می‌شوند. سپس برای هر مجموعه داده یک الگوریتم پایه ایجاد می‌شود. سپس با استفاده از الگوریتم پایه طبقه‌بندی داده انجام گرفته و با استفاده از روش رأی‌گیری^۲، دسته‌ای که بیشترین هم‌پوشانی برای داده را داشته باشد به عنوان طبقه آن داده انتخاب می‌شود [۲۱]. شناخته‌شده‌ترین روش دسته‌بندی جنگل تصادفی نام دارد که در ادامه نحوه عملکرد آن توضیح داده خواهد شد. شکل (۴) روند کلی عملکرد روش‌های دسته‌بندی مناسب برای مسائل طبقه‌بندی را نشان می‌دهد. این روش برای مسائلی که در آن مشکل بیش‌برازش وجود دارد مناسب است.



شکل ۴. روند کلی عملکرد روش‌های دسته‌بندی مناسب برای مسائل طبقه‌بندی

ب) روش تقویتی: برخلاف بسیاری از مدل‌های یادگیری ماشین که بر روی پیش‌بینی‌هایی با دقت بالا تمرکز دارند، روش‌های تقویتی به دنبال افزایش کیفیت پیش‌بینی با آموزش مدل‌های ضعیف هستند که هر یک درصد جبران ضعف مدل پیش از خود هستند. برای تبدیل مدل ضعیف به مدل قوی‌تر، پیش‌بینی‌های انجام‌گرفته توسط هر یک از مدل‌های ضعیف با استفاده از روش‌های میانگین‌گیری و انتخاب پیش‌بینی با تعداد رأی بیشتر با یکدیگر ادغام می‌شوند. روش‌های تقویتی برای کاهش بایاس مناسب هستند.

برای یافتن یادگیرنده ضعیف، از الگوریتم‌های پایه یادگیری ماشین استفاده می‌شود. هر بار که الگوریتم یادگیری پایه اعمال می‌شود، یک پیش‌بینی ضعیف جدید ایجاد می‌کند. این یک فرایند تکراری بوده و پس از انجام تکرارهای زیاد، الگوریتم تقویتی پیش‌بینی‌های ضعیف را برای ایجاد پیش‌بینی قوی ترکیب می‌کند [۲۲]. در شکل (۵) روند کلی عملکرد روش‌های تقویتی مناسب برای مسائل طبقه‌بندی را می‌توان مشاهده کرد.




شکل ۲. درخت تصمیم و اجزا تشکیل‌دهنده آن

روش‌های مبتنی بر درخت تصمیم نسبت به روش‌های ترکیبی قابلیت تفسیرپذیری بالاتری دارند و اپراتور سیستم قدرت چشم‌انداز مناسب‌تری از وضعیت عملکرد شبکه خواهد داشت. با این حال، در روش‌های مبتنی بر درخت تصمیم منفرد، اگر خطایی در گره‌های بالاتر و نزدیک به گره ریشه اتفاق بیافتد می‌تواند منجر به اشتباهات زنجیره‌ای شده و کل ارزیابی را در معرض ریسک قرار دهد. از طرف دیگر روش درخت تصمیم منفرد در مقابل داده‌های اندازه‌گیری شده نویز دار می‌تواند منجر به اختلال در عملکرد پیش‌بینی وضعیت سیستم شود. بنابراین استفاده از روش‌های ترکیبی در برابر روش‌های مبتنی بر درخت تصمیم منفرد قابلیت اطمینان بیشتری دارند چراکه از تعداد بیشتری ماشین یادگیری تعبیه‌شده‌اند بنابراین ریسک پیش‌بینی، با وقوع یک اشتباه در اندازه‌گیری در یک درخت منفرد در روش‌های ترکیبی پایین‌تر است.

۴-۱. الگوریتم یادگیری ماشین جمعی

برخلاف الگوریتم‌های یادگیری فردی که تنها یک یادگیرنده از مجموعه داده‌ها افند ایجاد می‌شود، روش‌های جمعی چندین یادگیرنده از داده‌های در دسترس ایجاد کرده و در نهایت از ترکیب آن‌ها استفاده می‌کند. الگوریتم‌های پایه مورد استفاده در روش‌های جمعی می‌توانند الگوریتم‌هایی همانند درخت تصمیم، شبکه عصبی، ماشین بردار پشتیبان و سایر الگوریتم‌های یادگیری ماشین باشند. در روش‌های جمعی معمولاً تلاش می‌شود تا تنها از یک نوع الگوریتم یادگیرنده پایه استفاده شود تا یک الگوریتم یادگیری جمعی همگن حاصل شود [۲۰]. شکل (۳) نحوه کلی عملکرد الگوریتم‌های جمعی را نمایش می‌دهد.



شکل ۳. نحوه کلی عملکرد الگوریتم‌های جمعی

¹ Classification Methods

² Voting

که بیشترین میزان رأی و یا میانگین انتخاب بالاتری دارند به‌عنوان طبقه داده جدید انتخاب می‌شود. یعنی:

$$f(x) = \arg \max_y \sum_{j=1}^J I(h_j(x) = y) \quad (5)$$

$$\begin{cases} 1 & I(h_j(x) = y) \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

در این رابطه $h_j(x)$ پیش‌بینی انجام‌گرفته توسط درخت تصمیم z برای نقطه داده x است [۲۳].

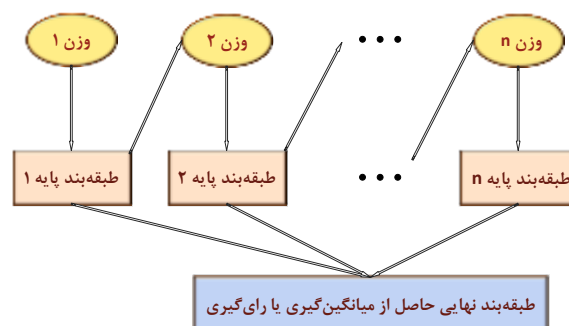
۱-۴-۲. روش تقویتی انطباقی

روش تقویتی انطباقی یا روش Adaboost یک‌روند تکرارشونده است که تلاش می‌کند طبقه‌بندی‌کننده $f(x)$ را با ترکیب یادگیرنده‌های ضعیف تقریب زند. در صورتی که از الگوریتم پایه درخت تصمیم برای ایجاد این طبقه‌بندی‌کننده استفاده شود در ابتدا با استفاده از نمونه‌های آموزشی بدون وزن شروع به ساختن طبقه‌بندی‌کننده درختی می‌کند. در صورت طبقه‌بندی اشتباه داده آموزشی، وزن داده آموزشی افزایش پیدا می‌کند. نهایتاً، طبقه بندی‌کننده دوم با استفاده از وزن‌های جدید که دیگر برابر نیستند ایجاد می‌شود. برای طبقه‌بندی‌کننده دوم نیز همانند طبقه‌بندی‌کننده اول عمل می‌شود. مدل جدید به‌دست‌آمده مجموع دو درخت اول و دوم است. پس از آن مقدار خطای طبقه بندی محاسبه شده و درخت سوم پرورش داده می‌شود. این روند آن‌قدر ادامه پیدا می‌کند تا به یک طبقه‌بندی‌کننده مناسب دست‌یافته شود. طبقه‌بندی‌کننده Adaboost ذاتاً یک طبقه‌بندی‌کننده باینری است. برای مسائل مربوط به طبقه‌بندی چند کلاسی یک الگوریتم پیشرفته‌تر معرفی شده است که در ادامه به توضیح آن پرداخته می‌شود.

اگر یک طبقه‌بندی‌کننده چند کلاسی ضعیف برای طبقه‌بندی داده استفاده شده باشد در این صورت الگوریتم مورد استفاده بدین‌صورت خواهد بود که ابتدا باید یک تخصیص ضریب وزنی برای هر یک از داده‌های قسمت یادگیری با استفاده از رابطه (۷) اعمال شود.

$$\omega_i = \frac{1}{n} \quad i = 1, 2, \dots, n \quad (7)$$

در این رابطه n تعداد کل نمونه‌های موجود برای یادگیری است. سپس برای $m = 1, \dots, M$ که M نیز تعداد طبقه‌بندی‌کننده‌های ضعیف است: الف) استفاده از ضرایب وزنی ω_i برای تعلیم یادگیرنده‌های ضعیف $T^{(m)}(x)$ ب) محاسبه خطا پیش‌بینی با استفاده از رابطه (۸):



شکل ۵. روند کلی عملکرد روش‌های تقویتی مناسب برای مسائل طبقه‌بندی

۱-۴-۱. جنگل تصادفی

جنگل تصادفی یک الگوریتم جمعی مبتنی بر درخت تصمیم است که هر درخت وابسته به مجموعه متغیرهای تصادفی است. در واقع برای یک بردار تصادفی p بعدی که $X = (X_1, \dots, X_p)^T$ نشان‌دهنده متغیرهای ورودی و یا متغیرهای پیش‌بینی بوده و متغیر تصادفی Y بیانگر مقدار پاسخ است یک توزیع توأم $P_{XY}(X, Y)$ در نظر گرفته می‌شود. هدف نیز یافتن تابع پیش‌بینی $f(X)$ برای تخمین Y است. تابع پیش‌بینی باتوجه به تابع تلفات $L(Y, f(X))$ برای حداقل سازی مقدار تلفات مورد انتظار تعریف می‌شود.

$$E_{XY}(L(Y, f(X))) \quad (2)$$

$L(Y, f(X))$ معیاری است که نشان می‌دهد تا چه اندازه $f(X)$ به Y نزدیک است.

$$L(Y, f(X)) = \begin{cases} 0 & \text{if } Y = f(X) \\ 1 & \text{otherwise} \end{cases} \quad (3)$$

در صورتی که ρ مقادیر ممکن Y را نشان دهد، می‌توان گفت:

$$f(x) = \arg \max_{y \in \rho} P(Y = y | X = x) \quad (4)$$

ساختار گروهی f از مجموعه یادگیرنده‌های پایه (درخت تصمیم) $h_1(x), \dots, h_J(x)$ ایجاد می‌شود و این یادگیرنده‌های پایه با یکدیگر ترکیب شده و در نهایت پیش‌بینی‌کننده گروهی $f(x)$ را ایجاد می‌کنند. در این حالت $f(x)$ برابر با کلاسی است که بیشترین تعداد پیش‌بینی را دارد (بیشترین رأی را دارد).

در صورتی که داده‌های آموزشی به صورت $D = \{(x_1, y_1), \dots, (x_N, y_N)\}$ باشند نحوه کارکرد جنگل تصادفی در حالت طبقه‌بندی بدین صورت خواهد بود که ابتدا مجموعه داده‌های تصادفی از مجموعه انتخاب می‌شوند. سپس برای داده‌های انتخاب‌شده چندین درخت تصمیم ایجاد می‌شود. برای یک داده جدید پیش‌بینی‌های جدید توسط درختان انجام‌شده و دسته‌ای

$$Gini(S) = 1 - \sum_{i=1}^m P_i^2 \quad (12)$$

$$Gini_{split}(S) = \sum_{j=1}^s \frac{S_j}{S} Gini(S_j) \quad (13)$$

در این رابطه P_i احتمال تعلق هر ویژگی به طبقه C_i بوده و به صورت $\frac{S_i}{S}$ محاسبه می‌شود و z نیز ویژگی موردبررسی را نشان می‌دهد [۲۹].

پس از دستیابی به ویژگی‌های انتخابی، باید داده‌های انتخابی نرمالیزه شوند. یکی از این روش‌ها روش مقیاس‌بندی استاندارد^۱ است که در آن مقادیر در اطراف میانگین با یک انحراف معیار واحد متمرکز می‌شوند.

$$z = \frac{(x - u)}{s} \quad (14)$$

جهت ارزیابی مدل ایجادشده روش‌های مختلفی وجود دارد که دقت طبقه‌بندی‌کننده یکی از این شاخص‌ها است. همان‌طور که از نام این شاخص می‌توان دریافت این شاخص معیاری برای تعیین دقت طبقه‌بندی و یا کیفیت عملکرد مدل است. باتوجه به رابطه (۱۵) محاسبه این شاخص از طریق تقسیم تعداد پیش‌بینی‌های صحیح انجام‌گرفته بر تعداد کل پیش‌بینی‌های صورت گرفته است [۳۰].

$$accuracy = \frac{NR}{NT} \times 100 \quad (15)$$

در این رابطه دقت با $accuracy$ نشان داده شده و NR و NT به ترتیب تعداد مواردی که به‌درستی طبقه‌بندی شده‌اند و تعداد کل موارد طبقه‌بندی‌شده را نشان می‌دهد.

یکی دیگر از روش‌های ارزیابی کارایی مدل تشکیل ماتریس درهم‌ریختگی^۲ است. این ماتریس معمولاً برای الگوریتم‌های نظارت شده مورد استفاده قرار می‌گیرد [۳۱].

۲. روش تحقیق

در این مقاله به ارزیابی امنیت دینامیکی آنلاین توسط روش‌های یادگیری ماشین جمعی پرداخته خواهد شد. الگوریتم‌های جنگل تصادفی و روش تقویت انطباقی دو روش جمعی مورد استفاده هستند. روند کلی مقاله بدین صورت است که ابتدا برای شبکه موردنظر به تولید داده پرداخته می‌شود. تولید داده صحیح و منطقی و کارآمد اهمیت بسیار ویژه‌ای در طراحی و کارکرد الگوریتم یادگیری ماشین دارد. همچنین در این نوع مسائل طبقه‌بندی علاوه بر کیفیت، کمیت داده‌ها نیز مهم است. از آنجایی که چند نوع کلاس خروجی وجود دارد و ماشین باید

$$err^{(m)} = \sum_{i=1}^n \omega_i I(c_i \neq T^{(m)}(x_i)) / \sum_{i=1}^n \omega_i \quad (8)$$

سپس محاسبه ضریب یادگیرنده از رابطه (۹) به دست می‌آید:

$$\alpha^{(m)} = \log \frac{1 - err^{(m)}}{err^{(m)}} + \log(K - 1) \quad (9)$$

پس از آن تعیین ضرایب وزنی جدید با استفاده از رابطه (۱۰):

$$\omega_i = \omega_i \cdot \exp(\alpha^{(m)} \cdot I(c_i \neq T^{(m)}(x_i))) \quad i = 1, \dots, n \quad (10)$$

و نهایتاً

$$C(x) = \arg \max_k \sum_{m=1}^M \alpha^{(m)} \cdot I(T^{(m)}(x) = k) \quad (11)$$

در روابط فوق $\alpha^{(m)}$ ضریب یادگیرنده ضعیف و k تعداد طبقات است. روش فوق مربوط به Adaboost چند کلاسه است، در صورتی که $k = 2$ باشد، یک روش Adaboost باینری خواهیم داشت [۲۴].

۱-۴-۳. ارزیابی آفلاین

اهمیت داده در الگوریتم‌های یادگیری به‌قدری است که مستقیماً بر روی عملکرد آن‌ها تأثیر می‌گذارد. محققان این حوزه بر این باورند که ۸۰ درصد از عملکرد الگوریتم‌های یادگیری ماشین به داده وابسته است [۲۵]. در مسائل مربوط به ارزیابی امنیت دینامیکی سیستم قدرت نیز معمولاً پارامترهای مربوط به تجهیزات سیستم بسته به نوع مسئله به‌عنوان داده‌های ورودی به ماشین‌های یادگیری ارائه می‌شوند. این داده‌ها ممکن است از طریق به‌کارگیری داده‌های تاریخی و یا واحد اندازه‌گیر فازور حاصل شوند. در برخی مطالعات نیز از پارامترهای آنلاین شبکه بهره گرفته می‌شود [۲۶].

با افزایش اطلاعات و داده، کیفیت اطلاعات مورد نیاز برای تشخیص الگو و آموزش روش‌های یادگیری ماشین به‌شدت کاهش می‌یابد. به عبارتی افزایش ابعاد و اندازه مسئله باعث بالا رفتن تعداد داده‌های نامربوط و اضافی می‌شود. یکی از راه‌های حل این مسئله روش انتخاب ویژگی است [۲۷]. برای انتخاب ویژگی روش‌های بسیاری وجود دارد که شاخص Gini یکی از آن‌ها است. شاخص Gini معیار اندازه‌گیری ناخالصی است که ویژگی‌هایی که ناخالصی کمتر و اطلاعات بیشتری دارد را فیلتر و انتخاب می‌کند. هر قدر مقدار ناخالصی کمتر باشد ویژگی در تشخیص کلاس خروجی مفید خواهد بود [۲۸]. در روش Gini، ویژگی‌ها و متغیرهای تقسیم باتوجه به معیار تقسیمی انتخاب می‌شوند که بیشترین کاهش ناخالصی را برای تقسیم بعدی ایجاد می‌کند. در صورتی که S مجموع s داده بوده که دارای m طبقه است در این صورت شاخص Gini به صورت زیر

قابل محاسبه است:

¹ Standard Scaling
² Confusion Matrix

برای زمان رفع خطا بحرانی تعیین می‌گردد، سپس در یک مدت‌زمان تعیین‌شده خطایی در یک خط انتقال اعمال می‌شود. سپس برای این خطا در یک بازه چندثانی‌های شبیه‌سازی‌هایی انجام‌گرفته و خطا در یک‌زمان مشخص حذف می‌گردد. در هر شبیه‌سازی زاویه روتور بین هر دو ژنراتور بررسی می‌شود که از ۱۸۰ درجه تجاوز نکرده باشد. در صورت تجاوز از مقدار بیان‌شده، شبیه‌سازی متوقف شده و مجدداً با زمان رفع خطای متفاوت انجام می‌شود. این چرخه به‌طور مداوم ادامه پیدا کرده و در نهایت طولانی‌ترین زمان ممکن برای رفع خطا بدون ازدست‌رفتن سنکرونیزم سیستم به‌عنوان زمان رفع خطای بحرانی در نظر گرفته می‌شود. علت استفاده از این روش عدم نیاز به انجام محاسبات دیفرانسیلی پیچیده و دقت بالای آن است. از آنجایی که زمان رفع خطای بحرانی در مسئله پیش رو به‌عنوان داده ورودی به ماشین ارائه خواهد شد و قسمت تهیه داده به‌صورت آفلاین انجام می‌گیرد، سرعت محاسبات مدنظر نبوده و دقت به همراه سادگی مسئله‌ای حائز اهمیت است. روش پیشنهادی برای محاسبه زمان رفع خطای بحرانی پاسخگویی مناسبی دارد.

پس از یافتن زمان رفع خطای بحرانی خطوط باتوجه‌به تعداد خطوط بحرانی، خطوط نیمه بحرانی و خطوط غیر بحرانی موجود در هر حالت، وضعیت امنیت دینامیکی در هر سناریو به چند دسته تقسیم می‌شود. برای تشخیص وضعیت خط (بحرانی، نیمه بحرانی و غیر بحرانی) به‌صورت زیر عمل شده است:

معمولاً در صورتی که زمان رفع خطای بحرانی برای خطای سه‌فاز اعمال‌شده در یک خط کمتر از ۱۰۰ms باشد آن خط جزء دسته خطوط بحرانی حساب می‌شود [۳۷]. چراکه در مدت‌زمان ۱۰۰ms حذف خطا از خط بسیار دشوار است. چنین خطوط بحرانی در طبقه‌بندی صورت گرفته در این مطالعه hc نامیده شده‌اند. در صورتی که زمان رفع خطای بحرانی برای خطای سه‌فاز اعمال‌شده در یک خط بین (۱۷۰-۱۰۰)ms باشد آن خط جزء دسته خطوط نیمه بحرانی حساب می‌شود. در چنین مدت زمانی امکان حذف خطا از تجهیز تقریباً امکان‌پذیر است. خطوط نیمه بحرانی در طبقه‌بندی صورت گرفته mc نامیده شده‌اند. در صورتی که زمان رفع خطای بحرانی بیشتر از ۱۷۰ms باشد آن خط جزء دسته خطوط عادی یا غیر بحرانی دسته‌بندی می‌شود. چراکه در مدت‌زمان بیش از ۱۷۰ms حذف خطا از خط کاملاً میسر است. خطوط غیر بحرانی در دسته lc قرار می‌گیرند.

در این مرحله، داده‌های لازم آماده استفاده هستند. ویژگی‌های اولیه انتخابی عبارت‌اند از: توان اکتیو و راکتیو ژنراتورها، بارها، خطوط انتقال و ولتاژ شین‌ها و پرچم

قوانین مرتبط برای طبقه‌بندی هر دسته را فراگیرد در نتیجه تعداد داده نیز باید به‌اندازه‌ای باشد تا چنین امکانی برای الگوریتم وجود داشته باشد.

به‌منظور تولید داده به تولید سناریوهای مختلف برای شبکه از طریق تغییر بار شبکه و ایجاد پیشامد در شبکه پرداخته می‌شود. نوع پیشامد در نظر گرفته‌شده $N-1$ است که باتوجه‌به آن در هر پیشامد یک خط انتقال و یا یک ژنراتور از مدار خارج می‌شود. پس از ایجاد سناریوهای مختلف و در نظر گرفتن پیشامد پخش بار در دستور کار قرار می‌گیرد. در این قسمت نقاط کاری که در آن‌ها محدودیت‌های استاتیکی نقض می‌شوند در نظر گرفته نشده و آن سناریو از مجموعه داده‌ها حذف می‌شود. منظور از محدودیت‌های استاتیکی روابط (۱۶) و (۱۷) هستند:

$$\begin{cases} l_i > l_i^{\max} & \text{ns} \\ \text{else} & \text{s} \end{cases} \quad (16)$$

$$\begin{cases} |V_k| < |V_k^{\min}| & \text{ns} \\ |V_k| > |V_k^{\max}| & \text{ns} \\ \text{else} & \text{s} \end{cases} \quad (17)$$

در این رابطه l_i مقدار بارگذاری خط i و l_i^{\max} نیز حداکثر مقدار بارگذاری مجاز در خط i است. همچنین V_k^{\min} و V_k^{\max} مقدار حداقل و حداکثر ولتاژ مجاز در شین k را نشان داده که V_k نیز اندازه ولتاژ در شین k را بیان می‌کند [۳۲].

لازم به ذکر است، در عمده مطالعات مربوط به حوزه امنیت دینامیکی به‌طورکلی از بررسی استاتیکی سیستم قدرت صرف‌نظر شده است. دلیل این امر، افزایش محاسبات و توضیحات است که با اضافه‌شدن قیدهای مهم استاتیکی از قبیل حد گرمایی انتهایی استاتور، حد جریان فوق تحریک و زیر تحریک از بحث امنیت دینامیکی سیستم قدرت با استفاده الگوریتم‌های یادگیری ماشین فاصله گرفته می‌شود. این در حالی است که در مقاله پیشنهادی، در کنار امنیت دینامیکی که هدف اصلی این مقاله است به بررسی امنیت استاتیکی با در نظرگیری محدودیت ولتاژ شین‌ها و جریان عبوری از خطوط پرداخته شده است.

در سناریوهای امن از لحاظ استاتیکی پارامترهای شبکه قبل از اعمال خطا یعنی توان اکتیو و راکتیو ژنراتورها، بارها، خطوط انتقال و ولتاژ شین‌ها برای استفاده به‌عنوان داده‌های اولیه ثبت می‌شوند که معمولاً پارامترهایی تأثیرگذار بر روی امنیت دینامیکی سیستم هستند [۳۳]. پس از این مرحله برای سناریوهای باقی‌مانده، خطای سه‌فاز در تمام خطوط اعمال می‌شود و زمان رفع خطا بحرانی در تمام خطوط محاسبه می‌گردد. در این مطالعه از روش بهره‌گرفته‌شده در دیگر گزارشات استفاده شده است [۳۴-۳۶]. بر طبق این روش یک محدوده حداقل و حداکثر مشخص


روش پیشنهادی بر روی یک شبکه کوچک و یک شبکه نسبتاً بزرگ اعمال شده است تا کارایی روش مورد ارزیابی قرار گیرد. همان‌طور که پیش‌تر ذکر شد در طبقه‌بندی چند کلاسی علاوه بر کیفیت داده کمیت داده نیز مسئله‌ای مهم است؛ از این رو در این مقاله از دو شبکه با اندازه‌های متفاوت بهره گرفته شده است تا تفاوت عملکرد مدل در شبکه‌های مختلف مورد بررسی قرار گیرد. همچنین در انتها روش‌های جمعی با دو روش منفرد پایه مقایسه می‌شوند تا عملکرد روش‌های جمعی جنگل تصادفی و روش تقویت انطباقی بررسی شوند. روش‌های پایه مورد مقایسه دو روش درخت تصادفی و k نزدیک‌ترین همسایه هستند.

۳. نتایج شبیه‌سازی

سیستم‌های مورد مطالعه در این تحقیق شامل IEEE 9 bus test system و IEEE 39 bus test system هستند. شبیه‌سازی‌های صورت گرفته با استفاده از دو نرم‌افزار پایتون و دیگسایلنت انجام شده‌اند.

۳-۱. شبکه ۹ شینه

شکل (۸) ساختار شبکه مورد آزمایش برای ارزیابی امنیت دینامیکی را نمایش می‌دهد [۳۸].

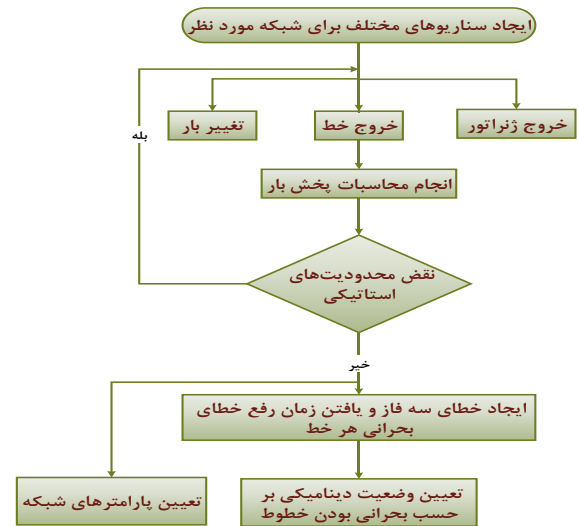


شکل ۸. دیاگرام تک‌خطی سیستم قدرت ۹ شینه

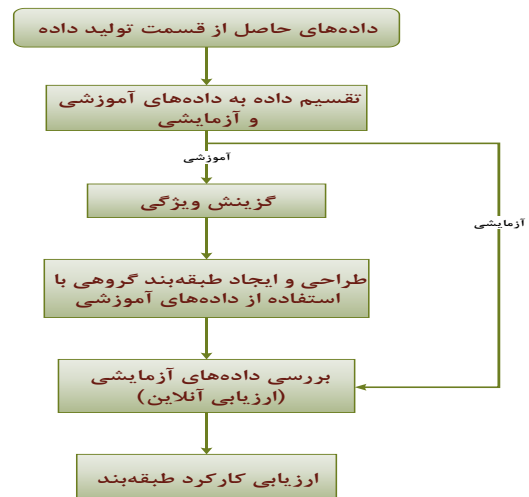
برای این شبکه بارها در ۴ حالت در نظر گرفته شده‌اند: بار نصف، ۰/۷۵، بدون تغییر و ۱/۱ برابر بار اصلی شده‌اند و پیشامدها شامل خروج یک‌به‌یک تمامی خطوط و ژنراتورها از سیستم است. سپس محاسبات پخش بار انجام گرفته و مواردی که منجر به اضافه بار در خطوط یا نقض محدودیت ولتاژ شین‌ها گشته‌اند، حذف شده‌اند. پس از تعیین بردار ویژگی اولیه با اعمال روش انتخاب ویژگی، ویژگی‌های اصلی به‌دست آمده است. نتایج اعمال شاخص Gini در شکل (۹) نشان داده شده است.

باتوجه به شکل (۹) در بردار ویژگی اعمال شده به مدل جمعی هشت ویژگی نشان داده شده که دارای کمترین میزان ناخالصی

مشخص‌کننده خروج تجهیز خط انتقال یا ژنراتور. این ویژگی‌ها به‌عنوان ورودی به مدل اعمال می‌شوند و خروجی نیز وضعیت امنیت دینامیکی شبکه است که در اختیار ماشین قرار خواهد گرفت. سپس داده‌های جمع‌آوری شده به دودسته داده آموزشی و آزمایشی تقسیم می‌گردند. در قسمت داده‌های آموزشی برای بردار ویژگی اولیه به‌دست آمده از مرحله قبل روش گزینش ویژگی Gini استفاده می‌شود و ویژگی‌هایی که بیشترین کاربرد را در طراحی مدل دارند با استفاده از شاخص Gini تعیین می‌شوند. پس از ایجاد مدل داده‌های آزمایشی مورد بررسی قرار می‌گیرند. بدین صورت که یک سری ویژگی‌هایی به ماشین ارائه شده و طبق این ویژگی‌ها ماشین به‌صورت آنلاین در مورد طبقه‌بندی امنیتی آن‌ها تصمیم‌گیری می‌کند. شکل‌های (۶) و (۷) به ترتیب نحوه تولید داده به‌صورت آنلاین و چارچوب طراحی و ارزیابی امنیت دینامیکی آنلاین توسط طبقه‌بندی‌کننده جمعی را نشان می‌دهند.




شکل ۶. روند تولید داده آنلاین برای الگوریتم‌های یادگیری ماشین پیشنهادی



شکل ۷. چارچوب طراحی و ارزیابی امنیت دینامیکی آنلاین توسط طبقه‌بندی‌کننده‌های جمعی

نمونه از هفت نمونه مورد مطالعه کلاس c2 به درستی پیش‌بینی شده‌اند و فقط دو نمونه به اشتباه در کلاس c3 قرار گرفته‌اند. کلاس c3 دارای یک نمونه مورد مطالعه است که آن هم به درستی پیش‌بینی شده است و نهایتاً دو نمونه در کلاس c4 قرار داشته‌اند که یکی به درستی دیگری به اشتباه در کلاس c3 دسته‌بندی شده است.

همانند ماتریس درهم‌ریختگی، در شکل (۱۰) خطای پیش‌بینی طبقه‌بندی‌کننده توسط نمودار میله‌ای نشان داده شده است. در این شکل هر نمودار مربوط به یکی از کلاس‌های خروجی است. هر کدام از نمودارهای میله‌ای تعداد پیش‌بینی‌های صحیح انجام‌گرفته و یا پیش‌بینی‌های اشتباه برای هر کلاس را نشان می‌دهد. نمودار میله‌ای سمت چپ پیش‌بینی‌های صورت گرفته برای کلاس c1 را نشان می‌دهد. همان‌طور که پیش‌تر در قسمت ماتریس درهم‌ریختگی نیز بیان شد، ۱۱ نمونه به درستی در کلاس c1 پیش‌بینی شده‌اند. با این حال، یک نمونه به اشتباه در کلاس c2 جای گرفته است.




شکل ۱۰. نمودار خطای پیش‌بینی طبقه‌بندی‌کننده جنگل تصادفی برای سیستم ۹ شینه

ب) طبقه‌بندی‌کننده تقویتی انطباقی: در این روش از میان ۲۲ نمونه مورد مطالعه ۱۷ مورد به درستی دسته‌بندی شده است که دقت پیش‌بینی نهایی برابر با ۷۷/۲۷ درصد شده است. همچنین ماتریس درهم‌ریختگی به صورت زیر است:

$$cm = \begin{pmatrix} 11 & 0 & 0 & 0 \\ 1 & 4 & 0 & 1 \\ 1 & 0 & 1 & 2 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

همان‌طور که از نتایج می‌توان دریافت، روش مبتنی بر جنگل تصادفی دقت بالاتری نسبت به مدل تقویتی انطباقی دارد. بر طبق نتایج حاصل از ماتریس درهم‌ریختگی و خطای پیش‌بینی، مطابق شکل (۱۱) مدل تقویتی انطباقی ۱۱ مورد را به درستی در طبقه c1 طبقه‌بندی کرده است و دو مورد مربوط به طبقه c2 و c3 را به اشتباه در دسته c1 جای داده است. همچنین دو مورد باید در

بوده و به عنوان ویژگی‌های ورودی استفاده می‌شوند. پس‌از این مراحل باتوجه به شرایط شبکه و زمان رفع خطای بحرانی خطوط شبکه، مرزبندی امنیت دینامیکی انجام شده است. در این شبکه وضعیت امنیت دینامیکی سیستم باتوجه به تعداد خطوط بحرانی، نیمه بحرانی و غیر بحرانی به چهار کلاس تقسیم شده‌اند. جدول (۱) نحوه طبقه‌بندی امنیتی در شبکه ۹ شینه را نشان می‌دهد.



شکل ۹. نتایج حاصل از به‌کارگیری شاخص Gini و ویژگی‌های منتخب توسط آن در سیستم ۹ شینه

با استفاده از فلوجارت شکل (۷) و اطلاعات تولید شده، دو طبقه‌بندی‌کننده جمعی جنگل تصادفی و Adaboost برای شبکه تشکیل شده‌اند. در ادامه به بررسی هر یک از طبقه‌بندی‌کننده‌ها پرداخته می‌شود.

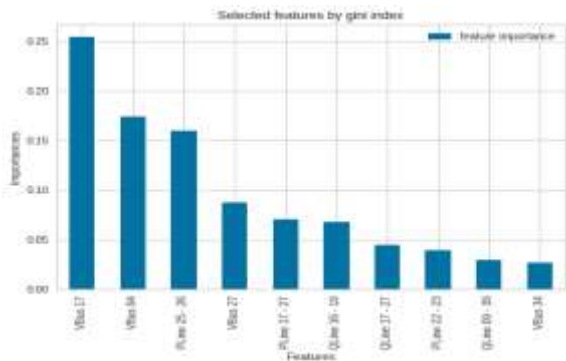
جدول ۱. طبقه‌بندی امنیتی سیستم ۹ شینه

خطوط غیر بحرانی	خطوط نیمه بحرانی	خطوط بحرانی	طبقه‌بندی
$1 \leq lc \leq 6$	$mc < 4$	$hc = 0$	کلاس c1
$lc \leq 2$	$4 \leq mc \leq 6$	$hc = 0$	کلاس c2
$1 \leq lc \leq 5$	$1 \leq mc \leq 5$	$1 \leq hc \leq 2$	کلاس c3
$1 \leq lc \leq 3$	$1 \leq mc \leq 3$	$hc \geq 3$	کلاس c4

الف) جنگل تصادفی: طبق معادله (۱۵) ایجاد طبقه‌بندی‌کننده جنگل تصادفی برای شبکه ۹ شینه دارای دقت ۸۱/۸۱ درصد است. همچنین نتایج ماتریس درهم‌ریختگی در ادامه آورده شده است.

$$cm = \begin{pmatrix} 11 & 0 & 0 & 0 \\ 1 & 5 & 0 & 0 \\ 0 & 2 & 1 & 1 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

از ماتریس درهم‌ریختگی می‌توان دریافت که ۱۱ نمونه مورد مطالعه به درستی در کلاس c1 قرار گرفته‌اند. یعنی برچسب خروجی واقعی و پیش‌بینی‌شده یکسان و برابر هستند. البته یک نمونه به اشتباه در کلاس c2 دسته‌بندی شده است. همچنین پنج



شکل ۱۳. نتایج حاصل از به‌کارگیری شاخص Gini و ویژگی‌های منتخب توسط آن در سیستم ۳۹ شینه


نحوه تعیین خطوط بحرانی، نیمه بحرانی و غیر بحرانی دقیقاً همانند شبکه ۹ شینه است. اما به علت تغییر شبکه نوع طبقه بندی هر کلاس متفاوت است. چهار کلاس خروجی امنیتی در نظر گرفته شده برای شبکه ۳۹ شینه مطابق جدول (۲) است. در این طبقه‌بندی کلاس c1 و c4 به ترتیب بهترین و بحرانی‌ترین وضعیت امنیت دینامیکی سیستم را بیان می‌کنند.

جدول ۲. طبقه‌بندی امنیتی سیستم ۳۹ شینه استاندارد

خطوط غیر بحرانی	خطوط نیمه بحرانی	خطوط بحرانی	طبقه‌بندی
$1 \leq lc \leq 34$	$mc < 4$	$hc = 0$	کلاس c1
$24 \leq lc < 30$	$4 < mc \leq 10$	$hc = 0$	کلاس c2
$1 \leq lc \leq 23$	$mc > 10$	$hc = 0$	کلاس c3
$1 \leq lc \leq 33$	$1 \leq mc \leq 33$	$hc = 1$	کلاس c4


الف) جنگل تصادفی: در این روش از میان ۴۸ نمونه مورد مطالعه ۴۶ نمونه به‌درستی پیش‌بینی شده که منجر به دقت پیش‌بینی ۹۵/۸۳ درصد شده است. همین‌طور طبق ماتریس درهم‌ریختگی و نمودار خطای پیش‌بینی شکل (۱۴) یک نمونه از کلاس c2 و یک نمونه از کلاس c3 به‌اشتباه در کلاس‌های c1 و c2 قرار گرفته‌اند.

$$cm = \begin{pmatrix} 26 & 0 & 0 & 0 \\ 1 & 3 & 0 & 0 \\ 0 & 1 & 4 & 0 \\ 0 & 0 & 0 & 13 \end{pmatrix}$$



شکل ۱۴. نمودار خطای پیش‌بینی طبقه‌بندی‌کننده تقویتی انطباقی برای سیستم ۳۹ شینه


گروه c3 و یک مورد در گروه c2 طبقه‌بندی می‌شدند و باقی طبقه‌بندی‌ها به درستی انجام شده است.



شکل ۱۱. نمودار خطای پیش‌بینی مدل تقویتی انطباقی برای سیستم ۹ شینه

۳-۲. شبکه ۳۹ شینه

سیستم مورد مطالعه دوم برای ارزیابی امنیت دینامیکی (شکل (۱۲)) از ۳۹ شین، ۱۰ ژنراتور، ۳۴ خط انتقال و ۱۹ تشکیل شده است [۳۹]. تولید سناریو برای این شبکه نیز دقیقاً همانند شبکه ۹ شینه صورت گرفته است. پس از تولید سناریوهای مختلف محاسبات پخش بار انجام گرفته و تمام مراحل مذکور مجدداً انجام شده است. پس از به دست آوردن بردار ویژگی اولیه شاخص Gini اعمال شده و ویژگی‌های دارای بیشترین اهمیت در شکل (۱۳) نشان داده شده‌اند.



شکل ۱۲. دیاگرام تک‌خطی شبکه ۳۹ شینه استاندارد

نزدیک‌ترین همسایه دارند. همچنین نتایج مربوط به بررسی سیستم ۳۹ شینه در جدول (۴) گردآوری شده است. می‌توان به راحتی وضعیت طبقه‌بندی‌های درست و اشتباه هر الگوریتم را مشاهده کرد.

جدول ۴. مقایسه دقت عملکرد الگوریتم‌های جمعی و منفرد در سیستم ۳۹ شینه

مدل	جنگل تصادفی	تقویتی انطباقی	درخت تصمیم	K نزدیک‌ترین همسایه
دقت	۹۵/۸۳	۹۳/۷۵	۸۷/۵	۸۱/۲۵


همان‌طور که انتظار می‌رفت نتایج موجود در جدول (۴) نشان‌دهنده این است که الگوریتم‌های جمعی جنگل تصادفی و تقویتی انطباقی دقت و کیفیت عملکرد به مراتب بالاتری نسبت به دو الگوریتم منفرد درخت تصمیم و k نزدیک‌ترین همسایه دارند.

۴. نتیجه‌گیری

در این مطالعه روشی برای ارزیابی امنیت آنلاین با استفاده از روش‌های یادگیری جمعی جنگل تصادفی و الگوریتم تقویتی انطباقی مبتنی بر الگوریتم پایه درخت تصمیم ارائه شد. با استفاده از روش معرفی شده یک ارزیابی امنیت دینامیکی جامع و کاربردی ارائه شده است. علاوه بر این، یک الگوی مرزبندی امنیتی ارائه شد که با استفاده از آن امکان تعیین وضعیت امنیتی سیستم از لحاظ دینامیکی ایجاد می‌شود. همچنین با استفاده از الگوریتم‌های جمعی جنگل تصادفی و الگوریتم تقویتی انطباقی امکان پیش‌بینی وضعیت امنیتی سیستم نیز میسر گشت تا در نهایت با استفاده از آن تشخیص وضعیت سیستم و اتخاذ تصمیم‌های به موقع جهت حفظ پایداری سیستم امکان‌پذیر باشد. الگوریتم‌های جمعی بر روی دو سیستم با ابعاد متفاوت پیاده‌سازی شدند و مشاهده شد که در هر دو سیستم دقت عملکرد طبقه‌بندی‌کننده‌ها مناسب بوده است. در سیستم بزرگ‌تر نتایج به مراتب بهتر بوده است چراکه در این سیستم حجم داده بیشتر بوده و در طبقه‌بندی چند کلاسی حجم داده مفید باعث افزایش قدرت یادگیری و در نتیجه عملکرد مناسب ماشین می‌شود. در هر دو شبکه روش جمعی دسته‌بندی عملکرد بهتری نسبت به روش جمعی تقویتی داشته است اما در صورت با استفاده از روش‌های ارزیابی عملکرد ماشین یادگیری هر دو نوع الگوریتم جمعی از کارایی خوبی برخوردار بوده‌اند. همچنین در این پژوهش مقایسه‌ای بین عملکرد الگوریتم‌های جمعی پیشنهادی با دو الگوریتم درخت تصمیم و k نزدیک‌ترین همسایه انجام گرفت. در هر دو شبکه مورد آزمایش الگوریتم‌های جمعی طراحی شده عملکرد به مراتب بهتری نسبت به الگوریتم‌های پایه داشته‌اند که این امر نشان‌دهنده قدرت طبقه‌بندی الگوریتم‌های جمعی تدوین شده است.

ب) *تقویتی/انطباقی*: مدل تقویتی انطباقی توانسته از میان ۴۸ نمونه مورد مطالعه ۴۵ نمونه را به درستی پیش‌بینی کند که نشان از قدرت روش پیشنهادی در مواجهه با انواع مختلف مدل‌های یادگیری ماشین دارد. بنابراین، دقت نهایی برابر با ۹۳/۷۵ درصد شده است.

$$cm = \begin{pmatrix} 26 & 0 & 0 & 0 \\ 2 & 2 & 0 & 0 \\ 0 & 1 & 4 & 0 \\ 0 & 0 & 0 & 13 \end{pmatrix}$$



شکل ۱۵. نمودار خطای پیش‌بینی طبقه‌بندی‌کننده تقویتی انطباقی برای سیستم ۳۹ شینه

نتایج ارزیابی با استفاده از ماتریس درهم‌ریختگی و نمودار شکل (۱۵) همان‌طور که پیش‌تر بیان شد قابل تحلیل است. دقت مدل طراحی شده کمی کمتر از جنگل تصادفی است. با این حال، بازهم دقت حاصل از طبقه‌بندی توسط روش تقویتی انطباقی مناسب بوده و مدل جمعی از کارایی خوبی برخوردار است.

۳-۳. مقایسه الگوریتم‌های جمعی با الگوریتم‌های منفرد

در این بخش مقایسه‌ای بین عملکرد دو طبقه‌بندی‌کننده جنگل تصادفی و Adaboost با دو الگوریتم منفرد طبقه‌بندی در دو سیستم مورد مطالعه انجام شده است. الگوریتم‌های k نزدیک‌ترین همسایه و درخت تصمیم که خود از قدرت خوبی برای طبقه‌بندی‌های چند کلاسی برخوردارند، دو الگوریتم مورد مقایسه در این بخش هستند. ابتدا به ارزیابی شبکه ۹ شینه پرداخته می‌شود. دقت پیش‌بینی برای چهار الگوریتم یادگیری طراحی شده در جدول (۳) قابل رؤیت است.

جدول ۳. مقایسه دقت عملکرد الگوریتم‌های جمعی و منفرد در شبکه ۹ شینه

مدل	جنگل تصادفی	تقویتی انطباقی	درخت تصمیم	K نزدیک‌ترین همسایه
دقت	۸۱/۸۱	۷۷/۲۷	۷۲/۷۲	۶۳/۶۳

همان‌طور که از جدول (۳) می‌توان دریافت الگوریتم‌های جمعی جنگل تصادفی و تقویتی انطباقی دقت و کیفیت عملکرد به مراتب بالاتری نسبت به دو الگوریتم منفرد درخت تصمیم و k

۵. مراجع‌ها

- System”, *J. Adv. Defence Sci. & Technol.* 2021., 3, 251-263. DOR: 20.1001.1.26762935.1400.12.4.3.5
- [16] Anwar, N.; Hanif, A.; Khan, H.F.; Ullah, M. F. “Transient Stability Analysis of The IEEE-9 Bus System Under Multiple Contingencies”; *Eng. Technol. Appl. Sci. Res.* 2020, 10, 5925-5932.
- [17] Shahriyari, M.; Khoshkhoo, H. “A Deep Learning-Based Approach for Comprehensive Rotor Angle Stability Assessment”; *J. Oper. Autom. Power Eng.* 2022, 10, 105-112. <https://doi.org/10.22098/JOAPE.2022.8701.1607>.
- [18] Dietterich, T. G. “Ensemble Learning”; *The handbook of brain theory and neural networks* 2002, 2, 110-125.
- [19] Silva-Palacios, D.; Ferri, C.; Ramírez-Quintana, M. J. “Improving Performance of Multiclass Classification by Inducing Class Hierarchies”; *Procedia Comput. Sci.* 2017, 108, 1692-1701. <https://doi.org/10.1016/j.procs.2017.05.218>.
- [20] Zhou, Z. H. “Ensemble Methods: Foundations and Algorithms”; CRC Press., 2012.
- [21] Witten, I. H.; Frank, E.; Hall, M. A.; Pal, C. J.; DATA, M. “Practical Machine Learning Tools and Techniques”; *Data Mining. Fourth Edition*, Elsevier Publishers 2017.
- [22] Bühlmann, P.; Hothorn, T. “Boosting Algorithms: Regularization, Prediction and Model Fitting”; *Statist. Sci.* 2007, 22, 477-505. <https://doi.org/10.1214/07-STS242>.
- [23] Cutler, A.; Cutler, D. R.; Stevens, J. R. “Random Forests”; *Ensemble Machine Learning: Methods and Applications* 2012, 157-175. <https://doi.org/10.1007/978-1-4419-9326-7-5>
- [24] Hastie, T.; Rosset, S.; Zhu, J.; Zou, H. “Multi-Class Adaboost”; *Stat. Interface* 2009, 2, 349-360. doi:<https://dx.doi.org/10.4310/SII.2009.v2.n3.a8>
- [25] Zhang, S.; Zhang, C.; Yang, Q. “Data Preparation for Data Mining”; *Appl. Artif. Intell.* 2003, 17, 375-381. <https://doi.org/10.1080/713827180>.
- [26] Zhang, Y.; Xu, Y.; Dong, Z. Y. “Robust Classification Model for PMU- Based Online Power System DSA with Missing Data”; *IET Gener. Transm. Dis.* 2017, 11, 4484-4491. <https://doi.org/10.1049/iet-gtd.2016.2010>.
- [27] Bachu, V.; Anuradha, J. “A Review of Feature Selection and Its Methods”; *Cybernetics and Information Technologies* 2019, 19(1), 3-26
- [28] Al-Harbi, O. “A Comparative Study of Feature Selection Methods for Dialectal Arabic Sentiment Classification Using Support Vector Machine”; *arXiv preprint arXiv 1902.06242* 2019. <https://doi.org/10.48550/arXiv.1902.06242>.
- [29] Yang, J.; Qu, Z.; Liu, Z. “Improved Feature-Selection Method Considering The Imbalance Problem in Text Categorization”; *Scientific World Journal* 2014, <https://doi.org/10.1155/2014/625342>.
- [30] Sun, M.; Konstantelos, I.; Strbac, G. “A Deep Learning-Based Feature Extraction Framework for System Security Assessment”; *IEEE Trans. Smart Grid* 2018, 10, 5007-5020. <https://doi.org/10.1109/TSG.2018.2873001>.
- [31] Kulkarni, A.; Chong, D.; Batarseh, F. A. “Foundations of Data Imbalance and Solutions for a Data Democracy”; *Data democracy. Academic Press*, 2020, 83-106. <https://doi.org/10.1016/B978-0-12-818366-3.00005-8>.
- [32] Sekhar, P.; Mohanty, S. “Classification and Assessment of Power System Static Security Using Decision Tree and
- [1] Shahpari, A.; Khansari, M.; Moeini, A. “Prediction of Vulnerability in Iran's Power Grid by Link Analysis”; *J. Adv. Defence Sci. Technol.* 2018, 9, 461-466.
- [2] Shahidehpour, M.; Tinney, W. F.; Fu, Y. “Impact of Security on Power Systems Operation”; *Proc. IEEE* 2005, 11, 2013-2025. <http://doi.org/10.1109/JPROC.2005.857490>.
- [3] Shahriyari, M.; Safari, A.; Quteishat, A.; Afsharirad, H. “A Short-Term Voltage Stability Online Assessment Based on Multi-Layer Perceptron Learning”; *Electr. Pow. Syst. Res.* 2023, 223, 109562. <https://doi.org/10.1016/j.eprsr.2023.109562>.
- [4] Sayyidipour, S.; Ghaffarpour, R.; Ranjbar, A. “A Review on Vulnerability Analysis of Electric Grid: Approaches, Models, and Solution Methods”; *Adv. Defence Sci. & Technol.* 2018, 9, 11-28. DOR: 20.1001.1.26762935.1397.9.1.2.7
- [5] Shahriyari, M.; Khoshkhoo, H. “A Novel Approach for Fast Prediction of Transient Angle Stability Status in Power Systems”; *J. Adv. Defence Sci. & Technol.* 2020, 3, 309-324. DOR: 20.1001.1.26762935.1399.11.3.8.1
- [6] Patel, H. H.; Prajapati, P. “Study and Analysis of Decision Tree Based Classification Algorithms”; *Int. J. Comp. Sci. Eng.* 2018, 6, 74-78.
- [7] Pal, M. “Ensemble Learning With Decision Tree for Remote Sensing Classification”; *World Acad. Sci. Eng. Technol.* 2007, 36, 258-260.
- [8] Kalyani, S.; Swarup, K. S. “Classification and Assessment of Power System Security Using Multiclass SVM”; *IEEE Trans. Syst. Man Cybernet. C.*, 2010, 41, 753-758. <https://doi.org/10.1109/TSMCC.2010.2091630>
- [9] Liu, C.; Sun, K.; Rather, Z. H.; Chen, Z.; Bak, C. L.; Thøgersen, P.; Lund, P. “A Systematic Approach for Dynamic Security Assessment and The Corresponding Preventive Control Scheme Based on Decision Trees”; *IEEE Trans. Power Syst.* 2013, 29, 717-730. <https://doi.org/10.1109/TPWRS.2013.2283064>
- [10] Zhukov, A.; Tomin, N.; Kurbatsky, V.; Sidorov, D.; Panasetsky, D.; Foley, A. “Ensemble Methods of Classification for Power Systems Security Assessment”; *Appl. Applied Comput. Inform.* 2019, 15, 45-53. <https://doi.org/10.1016/j.aci.2017.09.007>
- [11] Liu, C.; Tang, F.; Leth Bak, C. “An Accurate Online Dynamic Security Assessment Scheme Based on Random Forest”; *Energies* 2018, 11, 1914. <https://doi.org/10.3390/en11071914>
- [12] Liu, J.; Sun, H.; Li, Y.; Fang, W.; Niu, S. “An Improved Power System Transient Stability Prediction Model Based on mRMR Feature Selection and WTA Ensemble Learning”; *Appl. Sci.* 2020, 10, 2255. <https://doi.org/10.3390/app10072255>
- [13] Shahriyari, M.; Khoshkhoo, H.; Pouryekta, A.; Ramachandaramurthy, V. K. “Fast Prediction of Angle Stability Using Support Vector Machine and Fault Duration Data”; *IEEE Int. Conf. Aut. Ctr. Intelligent Syst.*, 2019, 258-263. <https://doi.org/10.1109/ICACIS.2019.8825052>
- [14] Li, H.; Diao, R.; Zhang, X.; Lin, X.; Lu, X.; Shi, D.; Wang, Z.; Wang, L. “An Integrated Online Dynamic Security Assessment System for Improved Situational Awareness and Economic Operation”; *IEEE Access* 2019, 7, 162571-162582. <https://doi.org/10.1109/ACCESS.2019.2952178>.
- [15] Khoshkhoo, H.; Akbarzadeh, A.P. “Prediction of Voltage Stability Status Considering the Impact of the Protection

- [38] Sharma, S.; Velgapudi, N. S.; Pandey, K. "Performance Analysis of IEEE 9 Bus system using TCSC"; IEEE Recent Developments in Control, Automation & Power Engineering 2017, 251-256. <https://doi.org/10.1109/RDCAPE.2017.8358277>.
- [39] Shahriyari, M.; Khoshkhoo, H.; Guerrero, J. M. "A Novel Fast Transient Stability Assessment of Power Systems Using Fault-on Trajectory"; IEEE Syst. J. 2022, 16, 4334-4344. <https://doi.org/10.1109/JSYST.2022.3148815>.
- Random Forest Classifiers"; Int. J. Numer. Model. El. 2016 29, 465-474. <https://doi.org/10.1002/jnm.2096>.
- [33] Zhang, T.; Sun, M.; Cremer, J. L.; Zhang, N.; Strbac, G.; Kang, C. "A Confidence-Aware Machine Learning Framework for Dynamic Security Assessment"; IEEE Trans. Power Syst., 2021, 36, 3907-3920. <https://doi.org/10.1109/TPWRS.2021.3059197>.
- [34] Xyngi, I.; Ishchenko, A.; Popov, M.; van der Sluis, L. "Transient Stability Analysis of a Distribution Network with Distributed Generators"; IEEE Trans. Power Syst. 2009, 24, 1102-1104. <https://doi.org/10.1109/TPWRS.2008.2012280>.
- [35] Fan, Y.; Li, X.; Zhang, P. "Integrated Approach for Online Dynamic Security Assessment with Credibility and Visualization Based on Exploring Connotative Associations in Massive Data"; IEEE Access 2017, 5, 16555-16567. <https://doi.org/10.1109/ACCESS.2017.2739818>.
- [36] Liu, S.; Liu, L.; Fan, Y.; Zhang, L.; Huang, Y.; Zhang, T.; Cheng, J.; Wang, L.; Zhang, M.; Shi, R.; Mao, D. "An Integrated Scheme for Online Dynamic Security Assessment Based on Partial Mutual Information and Iterated Random Forest"; IEEE Trans. Smart Grid, 2020, 11, 3606-3619. <https://doi.org/10.1109/TSG.2020.2991335>.
- [37] Mukherjee, R.; De, A. "Development of an Ensemble Decision Tree-Based Power System Dynamic Security State Predictor"; IEEE Syst. J. 2020, 14, 3836-3843. <https://doi.org/10.1109/JSYST.2020.2978504>.