

تعیین نوع و سطح تماس خطای امپدانس بالا در شبکه‌های توزیع با استفاده از روش‌های تشخیص الگو

ایمان نیکوفکر^۱ مصطفی سرلک^۲ سید محمد شهرتاش^۳

۱- کارشناسی ارشد- شرکت برق منطقه‌ای خراسان- مشهد- ایران
nikoofekr_iman@yahoo.com

۲- استادیار- دانشگاه صنعتی جندی شاپور- دزفول- ایران
sarlak@jsu.ac.ir

۳- استاد- قطب علمی اتوماسیون و بهره‌برداری سامانه‌های قدرت
دانشکده برق- دانشگاه علم و صنعت ایران- تهران- ایران
shahrtash@iust.ac.ir

چکیده: در این مقاله، به کمک روش‌های تشخیص الگو نوع خطای امپدانس بالا که می‌تواند بریده شده یا بریده نشده باشد و همچنین سطحی که خطای امپدانس بالا بر روی آن اتفاق افتاده است تشخیص داده شده است. روش‌های مذکور عبارتند از: تبدیل TT و تبدیل S در بخش استخراج ویژگی، ماشین بردار تکیه گاه چند لایه و شبکه عصبی Fuzzy ART در بخش کلاسه بندی. در این روش‌ها، ویژگی‌ها شامل انرژی، انحراف از معیار و انحراف مطلق از میانگین هستند که از یک پنجره داده به طول یک سیکل با استفاده از اطلاعات زمان- زمان ماتریس حاصل از تبدیل TT و اطلاعات زمان - فرکانسی ماتریس حاصل از تبدیل S به دست می‌آیند. سپس این ویژگی‌ها به ماشین بردار تکیه گاه چند لایه و شبکه عصبی Fuzzy ART اعمال می‌شوند تا نوع خطای امپدانس بالا و سطح تماس تشخیص داده شوند. نتایج حاصل از بکارگیری الگوریتم پیشنهادی بر روی داده‌های واقعی بدست آمده از آزمایش‌های عملی خطای امپدانس بالا، حاکی از آن است که ویژگی‌های استخراج شده از تبدیل TT نسبت به تبدیل S بهتر بوده و همچنین شبکه عصبی Fuzzy ART دارای دقت بیشتری در دسته بندی در برابر ماشین بردار تکیه گاه چند لایه است.

کلمات کلیدی: حفاظت شبکه توزیع، خطای امپدانس بالا، تشخیص الگو، تبدیل S، تبدیل TT، ماشین بردار تکیه‌گاه، شبکه عصبی ART

تاریخ ارسال مقاله: ۱۳۹۱/۰۲/۲۳

تاریخ پذیرش مشروط مقاله: ۱۳۹۲/۰۴/۱۶

تاریخ پذیرش مقاله: ۱۳۹۳/۰۷/۰۶

نام نویسنده‌ی مسئول: دکتر سید محمد شهرتاش

نشانی نویسنده‌ی مسئول: ایران - تهران - دانشگاه علم و صنعت ایران - دانشکده مهندسی برق


خطاهای امپدانس بالا (HIF^۱) آن دسته از خطاها در شبکه‌های توزیع هستند که جریان عبوری بواسطه آنها بحدی نیست که موجب عملکرد تجهیزات حفاظت اضافه جریان (یعنی فیوزها، کلیدهای وصل مجدد و رله‌ها) گردد. به عبارت دیگر خطای امپدانس بالا، اتصال کوتاهی است که به علت پایین بودن ولتاژ مدار و وجود امپدانس بالا در مسیر اتصال کوتاه، جریان اندکی از فیدرها عبور می‌کند که به وسیله دستگاه‌های حفاظتی اضافه جریان معمولی قابل آشکارسازی نیست. این نوع اتصال کوتاه به دو دلیل می‌تواند اتفاق بیافتد: یا هادی با یک جسم امپدانس بالا مانند یک درخت تماس پیدا می‌کند و یا هادی بریده شده بر روی زمین می‌افتد. بعضی از این اتصال کوتاه‌ها به قدر کافی جریان می‌کشند و آشکار می‌شوند، ولی بعضی از آنها نمی‌توانند آشکار شوند که عموماً در شبکه‌های توزیع اتفاق می‌افتند. هدف اصلی از آشکارسازی این نوع خطاها حفاظت از جان انسان‌ها و جلوگیری از بروز آتش سوزی است [۱].

تحقیق بر روی روش‌های شناسایی خطاهای امپدانس بالا تقریباً از اوایل دهه‌ی ۷۰ میلادی به این امید که با استفاده از مشخصات جریان ایجاد شده توسط خطا بتوانند تشخیص خطا دهند شروع شد. اکثر تحقیقات خطای امپدانس بالا بر روی بهبود حساسیت آشکارسازها تمرکز داشتند تا با قابلیت اطمینان بیشتری این خطاها را تشخیص دهند. هدف اصلی اکثر روشهای آشکارساز، تشخیص ویژگی مشخصی در ولتاژ و یا جریان مربوط به خطای امپدانس بالا است. در [۲-۴] با استفاده از تغییر انرژی مؤلفه‌های دو تا ده کیلو هرتز جریان خطا و مانایی و تصادفی بودن این مؤلفه‌ها تلاشی برای آشکارسازی این نوع خطاها در شبکه‌های توزیع هوایی و زیرزمینی شده است، ولی به علت کلیدزنی تصادفی برخی بارهای الکتریکی بر روی فیدرهای توزیع و تولید شکل موج‌های مشابه، این روش دارای مشکلاتی است. در [۵-۶] از یک الگوریتم سیستم خبره برای تشخیص خطا استفاده شده است. این روش یک روش توانا بوده که به دلیل پیچیدگی و استفاده فراوان از مؤلفه‌های جریان سیم نوترال که در سطح ولتاژ ۲۰ کیلوولت در بسیاری از کشورها موجود نیست، نمی‌تواند کارایی لازم را داشته باشد. در [۷] از یک شبکه عصبی ۳۳ ورودی که آموزش آن به صورت پس انتشار خطا است استفاده شده است. مشکل این روش این است که از نمونه‌های زمانی شکل موج جریان خطا به عنوان ورودی استفاده شده است. نمونه‌های زمانی نمی‌توانند به عنوان داده‌های قابل

اتکا برای آموزش شبکه عصبی بکار روند. در [۸] استفاده از تغییر هارمونیک سوم قبل و بعد از خطا و همچنین تغییر مؤلفه زیر امپدانس سیستم توزیع پیشنهاد شده ولی با توجه به تاثیر عوامل مختلف بر هارمونیک سوم در شبکه قدرت، این روش قابل اتکا نیست. در [۹] به دلیل اینکه شکل موج جریان خطا دارای دامنه متغیر با زمان است و تبدیل فوریه نمی‌تواند ابزاری کارآمدی برای استخراج مؤلفه‌های شکل موج جریان خطا باشد از فیلتر کالمن استفاده شده است. در [۱۰] از تغییر انرژی مؤلفه‌های نزدیک فرکانس شبکه جریان خطا و مانایی و تصادفی بودن این مؤلفه‌ها استفاده شده است، که در این روش نیز بعلت کلیدزنی نامنظم برخی بارهای الکتریکی و تولید شکل موج‌های مشابه خطا احتمال آشکارسازی اشتباه وجود دارد. در [۱۱] با استفاده از روش تشخیص الگو آشکارسازی خطای امپدانس بالا انجام شده است. در این روش با استفاده از تبدیل موجک سیگنال جریان تجزیه شده و ویژگی‌های مورد نظر با استفاده از تحلیل مولفه‌های اساسی (PCA) استخراج شده‌اند. سپس این ویژگی‌ها به دسته‌بندی کننده بیز (Bayes) برای جداسازی حالت‌های خطا از غیر خطا اعمال شده‌اند. در [۱۲] از ترکیب فیلتر کالمن و ماشین بردار تکیه گاه برای آشکارسازی خطای امپدانس بالا استفاده شده است. در این مقاله از تغییرات دامنه و فاز مؤلفه اصلی و هارمونیک های ۳، ۵، ۷، ۱۱ و ۱۳ که توسط فیلتر کالمن تخمین زده می‌شود به عنوان ویژگی‌های ورودی به SVM استفاده شده است. مراجع [۱۵-۱۳] از تبدیل موجک برای آشکارسازی استفاده کرده‌اند. در [۱۳] از سیگنال جریان تبدیل موجک گرفته شده و سپس ویژگی‌های استخراج شده از آن به شبکه عصبی اعمال می‌شود. در [۱۴] از سیگنال‌های ولتاژ و جریان تبدیل موجک گرفته شده و از مقایسه ضرایب تقریبی سطح سوم آشکارسازی انجام می‌شود. در [۱۵] با استفاده از ضرایب تقریبی سطح پنجم شاخصی به منظور آشکارسازی خطای امپدانس بالا به دست آمده است. در [۱۶] با استفاده از امواج گذرای الکترومغناطیس ایجاد شده در اثر HIF، آشکارسازی و مکان‌یابی انجام می‌شود. مؤلفه‌های فرکانس بالا با استفاده از تبدیل موجک گسسته استخراج شده سپس انرژی ضرایب تبدیل موجک توسط سنسورهای نصب شده در نقاط مختلف شبکه توزیع محاسبه شده و آشکارسازی و مکان‌یابی HIF انجام می‌شود. در این مقاله عنوان شده است که با توجه به نصب سنسور در نقاط مختلف مکان‌یابی دقیق امکان پذیر نبوده فقط محدوده آن قابل شناسایی است. همچنین الگوریتم مکان-یابی می‌تواند آنالاین یا آفلاین باشد و نیازی به دانستن

است در این حالت، ارسال آلام جهت رفع آن کافی است و نیازی به قطع برق فیدر نیست [۱۹]. همچنین با اطلاع از سطحی که خطای امپدانس بالا بر روی آن واقع شده است می‌توان محدوده‌ای که خطای امپدانس بالا در آنجا اتفاق افتاده است را تعیین کرد. به عبارتی دیگر با تشخیص نوع سطح خطا، مکانیابی آن نیز آسانتر می‌شود.

در این مقاله مطابق الگوریتم‌های ارائه شده در شکل (۱)، برای تشخیص نوع خطای امپدانس بالا و سطح آن، یک سیکل کامل از جریان فیدر توسط پنجره زمانی متحرک دریافت شده و با اعمال تبدیل‌های زمان - فرکانس (تبدیل S) و زمان - زمان (تبدیل TT) به آن، ویژگی‌های مورد نظر از آن استخراج می‌شوند. سپس برای دسته‌بندی ویژگی‌های استخراج شده، از روش ماشین بردار تکیه‌گاه چند لایه و شبکه عصبی Fuzzy ART استفاده شده تا خطای امپدانس بالا از حالت‌های غیرخطا (مانند کلیدزنی خازنی، کلیدزنی بار، جریان نشتی مقره (ILC)، بار هارمونیک و...) جدا شده و همچنین سطح تماس خطای امپدانس بالا تعیین شود. بنابراین الگوریتم ارائه شده در شکل (۱) شامل چهار روش مستقل از هم است که هر یک از این چهار روش به تنهایی برای تشخیص و دسته بندی نوع خطای امپدانس بالا و تعیین سطح تماس کاربرد دارند.



شکل (۱): الگوریتم‌های روش پیشنهادی

۲- تبدیل S

تبدیل S همان روش تبدیل فوریه کوتاه مدت است با این تفاوت که پنجره مربوطه با فرکانس مقیاس پذیر شده است در نتیجه قدرت تفکیک زمان - فرکانس تامین می‌شود. تبدیل S سیگنال $h(t)$ به صورت زیر تعریف می‌شود [20]:

پارامترهای فیدر توزیع نیست. در [۱۷] از روش ریخت شناسی محاسباتی برای تشخیص خطای امپدانس بالا استفاده شده است. در این مقاله ابتدا با استفاده از سیگنال ولتاژ و روش ریخت شناسی محاسباتی، اغتشاش ایجاد شده بر روی سیستم تشخیص داده می‌شود و سپس برای تمایز بین خطای امپدانس بالا از سایر اغتشاشات از الگوریتم مبتنی بر قانون استفاده شده است. در [۱۸] از امضای الکتریکی «شدت میدان مغناطیسی» به منظور بررسی پدیده خطای امپدانس بالا استفاده شده است. در این مقاله نشان داده شده است که امضای الکتریکی مذکور دارای حساسیتی به مراتب بیشتر از سیگنال ولتاژ و هم‌تراز با سیگنال جریان است، اما از نظر بهره‌برداری و هزینه به دلیل نصب بر روی تیر و استفاده از فقط یک حسگر به جای سه حسگر برای اندازه‌گیری، برتری قابل توجهی نسبت به سیگنال جریان دارد.

برخورد هادی برقرار با شاخه‌های درخت بطور لحظه‌ای خطرناک نیست ولی ادامه این روند در نهایت می‌تواند موجب بریده شدن هادی برقرار شود. همچنین اگر در یک ناحیه خشک، هادی با شاخه‌های یک درخت خشک برخورد کند، در اثر تولید جرقه‌های متوالی بین درخت و هادی ممکن است این امر موجب بروز آتش سوزی شود. تفاوت اصلی مشخصه خطای امپدانس بالایی که در اثر برخورد هادی با شاخه‌های درخت بوجود می‌آید، با خطایی که در اثر بریده شدن و بر روی زمین افتادن هادی ایجاد می‌شود در این است که هنگامیکه هادی بر روی زمین می‌افتد، جریان بار به شدت کاهش می‌یابد، در صورتیکه در حالت برخورد هادی برقرار با شاخه‌های درخت چنین اتفاقی مشاهده نمی‌شود. تفاوت دیگر آن است که هنگامیکه هادی بر روی زمین می‌افتد، تا زمانیکه هادی از روی زمین برداشته نشود، خطای امپدانس بالا ادامه می‌یابد، در حالیکه برخورد هادی با شاخه‌های درخت اینگونه نیست.

از آنجایی که نحوه برطرف نمودن خطای امپدانس بالا در هادی بریده شده و هادی بریده نشده فرق می‌کند، اطلاع از نوع خطای امپدانس بالای ایجاد شده دارای اهمیت ویژه ایست. به طوری که با انتخاب تجهیزات مناسب و اعزام نیروی متخصص جهت رفع آن می‌توان به برقرار کردن سریع فیدر کمک کرد. به عنوان مثال اگر خطای امپدانس بالا از نوع هادی بریده نشده باشد (اتصال هادی به شاخه‌های درخت) نیاز به شاخه زنی برای رفع آن است. ولی هنگامی که خطای امپدانس بالا همراه با هادی بریده شده است نیاز به تجهیزات خاصی برای اتصال مجدد آن است. از طرفی دیگر با تشخیص نوع خطای امپدانس بالا، از آنجایی که خطر هادی بریده نشده از هادی بریده شده کمتر

۴- استخراج ویژگی

۴-۱- استخراج ویژگی از تبدیل S

همانطور که گفته شد، خروجی تبدیل S ماتریس $N \times N$ است که سطرها بیانگر اطلاعات فرکانسی و ستون ها نشان دهنده اطلاعات زمانی هستند. ویژگی‌های مورد نظر با تبدیل S گرفتن از یک سیکل جریان HIF استخراج می‌شوند. اطلاعات فرکانسی را می‌توان به کمک رابطه (۷) از ماتریس S استخراج کرد [22]:

$$A = \max(\text{abs}(S^T)) \quad (۷)$$

که S^T ترانپوز ماتریس S است. رابطه (۷) نشان دهنده اطلاعات دامنه بر حسب فرکانس است، یعنی A برداری است که دامنه را بر حسب فرکانس نشان می‌دهد. به طریق مشابه، جهت استخراج اطلاعات زمانی از ماتریس S از رابطه (۸) استفاده می‌شود:

$$B = \max(\text{abs}(S)) \quad (۸)$$

که B نشان دهنده اطلاعات دامنه بر حسب زمان (نمونه) است. به عبارتی دیگر B برداری است که تغییرات دامنه سیگنال مورد نظر را با زمان (نمونه) نشان می‌دهد. شکل (۲) پارامترهای A و B را برای سیگنال‌های HIF و ILC نشان می‌دهد.

وجود قوس در خطاهای امپدانس بالا باعث ایجاد مولفه‌های فرکانسی بالا در آن می‌شود که دارای انرژی زیادی هستند لذا از معیار انرژی می‌توان برای آشکارسازی استفاده کرد. همچنین به دلیل تصادفی بودن شکل موج خطای امپدانس بالا، عدم تقارن و وجود هارمونیک‌های زیاد در آن انحراف از معیار می‌تواند معیار خوبی برای تمایز با حالت غیر خطا باشد. انرژی، انحراف از معیار و انحراف مطلق از میانگین اطلاعات زمانی و فرکانسی با استفاده از رابطه‌های زیر به دست می‌آیند:

$$F1_S = \text{sum}(A^2) \quad (۹)$$

$$F2_S = \text{std}(A) \quad (۱۰)$$

$$F3_S = \text{mad}(A) \quad (۱۱)$$

$$F4_S = \text{sum}(B^2) \quad (۱۲)$$

$$F5_S = \text{std}(B) \quad (۱۳)$$

$$F6_S = \text{mad}(B) \quad (۱۴)$$

ویژگی‌های $F1, F2, F3$ به ترتیب انرژی، انحراف از معیار و انحراف مطلق از میانگین (mad) اطلاعات فرکانسی و ویژگی‌های $F4, F5, F6$ به ترتیب انرژی، انحراف از معیار و انحراف مطلق از میانگین اطلاعات زمانی هستند.

$$S(\tau, f) = \int_{-\infty}^{\infty} h(t) w(t - \tau, f) e^{-j2\pi ft} dt \quad (۱)$$

که در آن f فرکانس، t و τ متغیرهای زمان هستند. در رابطه (۱) پنجره w ، پنجره گوسی بوده و به صورت زیر تعریف می‌شود:

$$w(t, f) = \frac{|f|}{\sqrt{2\pi}} e^{-\frac{t^2 f^2}{2}} \quad (۲)$$

در نتیجه رابطه تبدیل S را می‌توان مطابق رابطه زیر بیان کرد:

$$S(\tau, f) = \int_{-\infty}^{\infty} h(t) \frac{|f|}{\sqrt{2\pi}} e^{-\frac{(t-\tau)^2 f^2}{2}} e^{-j2\pi ft} dt \quad (۳)$$

$$\int_{-\infty}^{+\infty} S(\tau, f) d\tau = H(j\omega) \quad (۴)$$

در رابطه (۴)، $H(j\omega)$ تبدیل فوریه سیگنال $h(t)$ است و این رابطه نشان می‌دهد که تبدیل S تبدیلی برگشت پذیر است. خروجی تبدیل S ماتریس $N \times N$ با مقادیر مختلط است که سطرها اطلاعات فرکانسی و ستون‌ها اطلاعات زمانی را ارائه می‌کنند.

۳- تبدیل TT

تبدیل TT تبدیل فوریه معکوس تبدیل S است و سری زمانی یک بعدی را به صورت دوبعدی در صفحه زمان - زمان نشان می‌دهد. در واقع، تبدیل TT ویژگی‌های زمانی یک سیگنال را حول یک نقطه مشخص (مرکز پنجره گوسی) روی منحنی زمانی متمرکز می‌کند [21]. تبدیل TT سیگنال $h(t)$ به صورت زیر بیان می‌شود:

$$TT(\tau, t) = \int_{-\infty}^{\infty} S(\tau, f) e^{j2\pi ft} df \quad (۵)$$

از رابطه (۴) و (۵) رابطه زیر حاصل می‌شود:

$$\int_{-\infty}^{\infty} TT(\tau, t) d\tau = h(t) \quad (۶)$$

پس تبدیل TT همانند تبدیل S برگشت پذیر است. خروجی تبدیل TT ماتریسی با ابعاد $N \times N$ (تعداد نمونه‌های سیگنال مورد نظر است) با مقادیر مختلط است. ستون‌های این ماتریس، سری‌های زمانی (معروف به سری‌های TT) هستند که حول مرکز پنجره گوسی ($t=\tau$) متمرکز شده‌اند. این سری‌های زمانی دارای ویژگی خاصی هستند به طوری که فرکانس‌های بالاتر دارای تمرکز بیشتری حول $t=\tau$ نسبت به فرکانس‌های کمتر هستند. این ویژگی، تمرکز دیفرانسیلی فرکانس‌ها نامیده می‌شود. نکته قابل توجه در این سری‌ها این است که با توجه به ویژگی مقیاس‌پذیری پنجره در تبدیل S، دامنه مولفه‌های فرکانس بالا افزایش محسوسی نسبت به دامنه مولفه‌های فرکانس پایین (حول $t=\tau$) دارند.

۴-۲- استخراج ویژگی از تبدیل TT

همانطور که گفته شد، خروجی تبدیل TT ماتریس $N \times N$ با مقادیر مختلط است و برای استخراج ویژگی از قسمت حقیقی این ماتریس استفاده می‌شود. ویژگی‌های مورد نظر با تبدیل TT گرفتن از یک سیکل جریان HIF استخراج می‌شوند (در اینجا $N=64$ و در نتیجه ابعاد ماتریس TT، 64×64 است). از آنجایی که تمرکز زمانی حول $t=t$ صورت می‌گیرد و سری‌های TT ماکزیمم دامنه خود را در نقطه $t=t$ دارند، لذا از عناصر قطری (Diagonal) ماتریس TT و مساحت کانتورها (Area) برای استخراج ویژگی استفاده شده است:

$$Diagonal = diag(TT \text{ matrix}) \quad (۱۵)$$

$$Area = polyarea(contour(TT \text{ matrix})) \quad (۱۶)$$

شکل (۳) عناصر قطری و مساحت کانتورهای سیگنال‌های HIF و ILC را نشان می‌دهد. انرژی، انحراف از معیار و انحراف مطلق از میانگین عناصر قطری و مساحت کانتورها مطابق رابطه‌های زیر استخراج می‌شوند:

$$F_{1TT} = sum(Diagonal^2) \quad (۱۷)$$


$$F_{2TT} = std(Diagonal) \quad (۱۸)$$

$$F_{3TT} = mad(Diagonal) \quad (۱۹)$$


$$F_{4TT} = sum(Area^2) \quad (۲۰)$$

$$F_{5TT} = std(Area) \quad (۲۱)$$

$$F_{6TT} = mad(Area) \quad (۲۲)$$



شکل (۲): (الف) سیگنال ILC (ب) سیگنال HIF (ج) پارامتر B سیگنال ILC و HIF (د) پارامتر A سیگنال ILC و HIF




شکل (۳): (الف) کانتورهای TT سیگنال ILC (ب) کانتورهای TT سیگنال HIF (ج) عناصر قطری سیگنال ILC (د) عناصر قطری سیگنال HIF

۵- ماشین بردار تکیه‌گاه چند لایه

۵-۱- ماشین بردار تکیه‌گاه

یکی از روش‌های موجود در حوزه روش‌های کلاسه‌بندی، روش ماشین بردار تکیه‌گاه است که برای اولین بار توسط آقای Vapnik ارائه شد [۲۳]. در این روش، هدف پیدا کردن مرز تصمیم‌گیری خطی مابین نمونه‌های متعلق به کلاس‌های مختلف، با لحاظ نمودن بیشترین فاصله بین کلاس‌های موجود است. شکل (۴) یک مساله کلاسه‌بندی با دو کلاس مجزا را نشان می‌دهد که نمونه‌های متعلق به دو کلاس، قابل جداسازی با یک خط هستند. همانطور که مشاهده می‌شود، خط‌های متمایز کننده متعددی را می‌توان مابین نمونه‌های مختلف در دو کلاس در نظر گرفت، لیکن در ماشین بردار تکیه‌گاه، هدف پیدا کردن خطی است که بیشترین فاصله (m) را بین نزدیکترین نمونه‌ها ایجاد کند (نزدیکترین نمونه‌ها از هر دو کلاس به خط متمایز کننده بردارهای تکیه‌گاه نامیده می‌شوند) [۲۴].



شکل (۴): اساس کار ماشین بردار تکیه‌گاه

به فرض، تعدادی از بردارهای ویژگی یا الگوهای آموزشی بصورت $\{x_1, x_2, x_3, \dots, x_N\}$ وجود داشته باشند، که هر کدام یک بردار ویژگی d بعدی بوده و دارای برچسب y_i به طوری که $y_i \in \{-1, +1\}$ و این دو کلاس با تابع تمایز $f(x)$ و با یک ابر صفحه $H^\pm$ با معادله زیر از هم جدا شوند:

$$H: w \cdot x + b = 0 \quad (23)$$

$$f(x) = \text{sign}(w \cdot x + b) \quad (24)$$

بردار وزن w ، بردار عمود بر صفحه جدا کننده و b مقدار بایاس است و منظور از $w \cdot x$ حاصلضرب داخلی است. هدف تعیین یک خط (در فضای دو بعدی) و یا یک ابر صفحه (در

فضای سه بعدی و بالاتر) با لحاظ نمودن حداکثر فاصله بین بردارهای تکیه‌گاه است که به صورت زیر تعریف می‌گردد:

$$m = \frac{2}{\|w\|} \quad (25)$$

که معادل است با مساله بهینه سازی زیر:

$$\begin{cases} \text{Minimize} & \frac{1}{2} \|w\|^2 \\ \text{Subject to} & y_i (w \cdot x_i + b) \geq 1 \quad \text{for } i = 1, 2, \dots, N \end{cases} \quad (26)$$

در حالیکه:

$$w = [w_1, w_2, \dots, w_d]^T \quad (27)$$

$$\|w\| = w \cdot w^T$$

مساله فوق یک مساله بهینه سازی است که روش لاگرانژ جهت حل آن پیشنهاد شده است [۲۴].

در عمل، برخی مسائل از جمله تشخیص خطای امیدانس بالا، در فضای ویژگی‌های مربوط، به صورت ساده مانند شکل (۴) جدایی ناپذیرند زیرا شباهتهایی بین شکل موج جریان خطای امیدانس بالا و حالت‌های غیر خطا وجود دارد و بنابراین تمایز بین این حالت‌ها به صورت خطی مشکل است. در این حالت، دو راه حل وجود دارد. در راه حل اول یک سری از متغیرهای slack، ξ_i ، تعریف می‌شوند (شکل ۵) به ترتیبی که شرط زیر برقرار باشد:


$$y_i (w \cdot x_i + b) \geq 1 - \xi_i \quad \xi_i \geq 0, \quad \text{for } i = 1, 2, \dots, N \quad (28)$$

واضح است که هر چقدر مجموع مقادیر متغیرهای ξ_i بیشتر شود، از حالت بهینه دورتر شده و خطا بیشتر می‌شود. پس مساله بهینه سازی بصورت زیر تعریف خواهد شد:

$$\begin{cases} \text{Minimize} & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \\ \text{Subject to} & y_i (w \cdot x_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0 \\ & \text{for } i = 1, 2, \dots, N \end{cases} \quad (29)$$

پارامتر کنترلی C در رابطه فوق توسط کاربر تعریف می‌شود. مقادیر زیاد C نشان دهنده باریک شدن ناحیه مرزی است، و مقادیر کوچک C نشان دهنده ناحیه مرزی عریض‌تر است. ابر صفحه به دست آمده در این حالت را ابر صفحه یا ناحیه مرزی نرم می‌نامند.


۵-۲- دسته بندی با استفاده از ماشین بردار تکیه گاه



شکل (۷): ساختار ماشین بردار تکیه گاه چند لایه در [۲۵]


هر SVM تنها قادر به دسته بندی دو کلاس است و برای دسته بندی بیش از دو کلاس توسط SVM از ماشین بردار تکیه گاه چند لایه^۸ که در این ساختار از چند SVM (که تعداد آنها بستگی به تعداد کلاسها دارد) استفاده می شود. شکل (۷) ساختار Multi-Layer SVM را نشان می دهد که از دو SVM برای دسته بندی سه کلاس استفاده شده است. به طور کلی در این نوع ساختار به ازای n کلاس، $n-1$ واحد SVM وجود دارد [۲۵].

SVM1 در شکل (۷) طوری آموزش دیده است که داده های کلاس ۱ از دو کلاس دیگر جدا شوند و SVM2 نیز طوری آموزش دیده است که داده های کلاس ۲ را از کلاس ۳ جدا کند. در این روش با توجه به ترتیب قرارگیری SVMها آموزش هر SVM متفاوت از دیگری است و پس از آموزش نمی توان جای آنها را عوض کرد. به این ترتیب، با اعمال داده به ورودی شبکه، SVM1 داده های کلاس ۱ را از دو کلاس دیگر جدا کرده و داده های مربوط به دو کلاس ۲ و ۳ به SVM2 اعمال می شوند. SVM2 نیز بر اساس آموزش دیده شده داده های کلاس ۲ را از کلاس ۳ جدا می کند. عیبی که در این روش وجود دارد این است که اگر نمونه هایی که متعلق به کلاس ۱ هستند به دلیل خطای SVM1 دسته بندی نشوند و همراه نمونه های دیگر به لایه بعدی منتقل شوند، این نمونه ها در یکی از کلاس های ۲ یا ۳ قرار می گیرند که باعث کاهش دقت دسته بندی می شود. به عبارتی دیگر به دلیل وجود خطا در دسته بندی هر SVM نمونه هایی که به درستی دسته بندی نشوند معمولاً به لایه آخر منتقل شده و به ناچار در یکی از دو دسته موجود در لایه آخر قرار می گیرند. به این منظور در [۲۶] به ازای n کلاس از n تعداد SVM استفاده شده است به طوری که نمونه هایی که به دلیل خطای SVMها دسته بندی نمی شوند به لایه آخر منتقل شده و در آنجا در کلاسی به نام نمونه های دسته بندی نشده قرار می گیرند. در این مقاله به دلیل وجود ۵ کلاس از SVM ۵ استفاده شده است به گونه ای که در لایه اول داده های HIF از



شکل (۵): ماشین بردار تکیه گاه در حالت جدایی ناپذیر خطی

راه حل دوم استفاده از ماشین بردار تکیه گاه غیر خطی است. ماشین بردار تکیه گاه نشان داده شده در شکل (۴)، برای دسته بندی الگوهای یک مساله دو کلاسه، از مرزهای جداکننده خطی و از یک ابر صفحه استفاده می کند و در واقع حاصلضرب داخلی بردار ورودی با هر کدام از بردارهای تکیه گاه در فضای d بعدی ورودی محاسبه می گردد. Vapnik نشان داد که ابتدا می توان بردار ورودی x را با یک تبدیل غیر خطی (به کارگیری تابع کرنل^۹) به یک فضای با بعد زیاد انتقال داد و در آن فضا حاصلضرب داخلی را انجام داد به نحوی که در فضای جدید بتوان الگوها را با یک خط (در فضای دو بعدی) و یا یک ابر صفحه (در فضای سه بعدی و بالاتر) از یکدیگر جدا نمود (شکل ۶). توابع کرنل مرسوم به صورت زیر هستند:




شکل (۶): ماشین بردار تکیه گاه غیر خطی، انتقال از فضای اصلی به فضای جدید با تابع کرنل $K(.)$

$$k(x, y) = (xy + 1)^r \quad r = 2, 3, \dots$$


$$k(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right) \quad (30)$$

$$k(x, y) = \tanh(p_1 x \cdot y + p_2)$$

این توابع به ترتیب کرنل چند جمله ای، کرنل RBF^۹ و کرنل MLP^۷ هستند.



شکل (۸): آموزش Multi-Layer SVM برای مسئله HIF



شکل (۹): ساختار Multi-Layer SVM برای دسته بندی HIF

دریافت می‌کند. در لایه F2 نرون‌ها با هم رقابت کرده و نرونی که مقدار آن از همه بیشتر باشد به عنوان نرون برنده مشخص می‌شود (مقدار آن یک می‌شود) و نرون‌های دیگر غیر فعال می‌شوند (مقدار صفر می‌گیرند) یعنی بردار ورودی در کلاسی قرار می‌گیرد که نرون برنده تعیین کننده آن است. سپس بردار Y که تمام عناصر آن به غیر از نرون برنده صفر است در وزن‌های بالا به پایین (C) ضرب شده و بردار V تشکیل می‌شود. تشابه بردار V و بردار X سنجیده می‌شود و اگر از حدی بیشتر باشد شبکه به حالت تشدید رفته و وزن‌ها به روز می‌شوند. ولی اگر تشابه از حدی کمتر باشد ادعای نرون برنده برای دسته بندی بردار ورودی مورد قبول واقع نمی‌شود و شبکه به حالت جستجو در می‌آید و نرون برنده قبلی غیر فعال شده و دیگر در رقابت شرکت نمی‌کند. این روند تا زمانی که تشدید رخ دهد تکرار می‌شود ولی اگر نرونی در لایه F2 نتواند بردار ورودی را در دسته خود قرار دهد (تمام نرون‌های F2 غیر فعال شده باشند) نرون جدیدی در لایه F2 ساخته می‌شود و وزن‌های متناظر با ورودی مورد نظر در حافظه بلند مدت LTM ثبت می‌شود.

No-HIF جدا می‌شود در لایه دوم داده‌های هادی بریده شده از بریده نشده در لایه سوم داده‌های آسفالت از بتن و سنگریزه و در لایه چهارم داده بتن از سنگریزه و در لایه آخر داده‌های سنگریزه از داده‌های دسته بندی نشده جدا می‌شوند. شکل (۸) نحوه آموزش و شکل (۹) نحوه تست ساختار Multi-layer SVM را برای دسته بندی خطای امپدانس بالا نشان می‌دهند. همانطور که در شکل (۸) دیده می‌شود هر SVM طوری آموزش دیده است که کلاس مربوط به خود را از سایر کلاس‌ها جدا می‌کند. در نتیجه ترتیب قرار گیری SVM‌ها در شکل (۹) اختیاری است و تاثیر زیادی در نتیجه نهایی نخواهد داشت و بهترین ترتیب قرار گیری به صورت آزمایش و تعیین دقت دسته بندی به دست می‌آید.

۶- شبکه عصبی ART

شکل (۱۰) مدل اصلی شبکه‌های ART را نشان می‌دهد. این مدل از دو لایه تشکیل شده است. لایه ورودی F1 که لایه مقایسه نامیده می‌شود دارای M نرون و لایه F2 که لایه تشخیص نامیده می‌شود دارای N نرون است. لایه‌های F1 و F2 از طریق بردارهای وزن LTM^1 یا حافظه بلند مدت، به طور کامل به هم متصلند. این بردارها را به این دلیل حافظه بلند مدت می‌گویند زیرا تا مدت طولانی باقی می‌مانند. الگوهایی که لایه‌های F1 و F2 را فعال می‌کنند حافظه کوتاه مدت یا STM^{10} نامیده می‌شوند زیرا تا زمانی که یک بردار ورودی وجود دارد این مقادیر نیز موجود هستند یا به عبارتی دیگر، با اعمال هر ورودی به شبکه، STM ‌ها نیز تغییر می‌کنند [۲۷].

با اعمال ورودی به شبکه، بردار X در لایه F1 تشکیل می‌شود (بردار X نرمالیزه شده بردار ورودی است). سپس بردار X توسط وزن‌های مربوطه (W) به لایه F2 منتقل می‌شود. هر نرون در F2 بردار X را که در وزن‌ها ضرب نقطه‌ای شده است را



$$X = X_1, X_2, \dots, X_n = \frac{I}{|I|} \quad (32)$$

$$Y = \frac{|X \wedge W_j|}{\alpha + |W_j|} \quad (33)$$

مقادیر اولیه وزن پایین به بالا به صورت زیر تعیین می‌شود:

$$W = I_1, I_2, \dots, I_n \quad (34)$$

در رابطه (۳۳)، α مقداری بزرگتر از صفر است و رابطه AND فازی ($\wedge$) به صورت زیر تعریف می‌شود:

$$(p \wedge q)_i = \min(p_i, q_i) \quad (35)$$

همچنین برای هر بردار با طول M رابطه نرم به صورت زیر است:

$$\|P\| = \sum_{i=1}^M |P_i| \quad (36)$$

از آنجایی که لایه F2 لایه ای رقابتی است، نرون‌های این لایه به رقابت پرداخته و نرون با بیشترین مقدار به عنوان نرون برنده شناسایی می‌شود. اگر بیش از یک نرون دارای مقدار ماکزیمم باشند نرون با اندیس کوچکتر انتخاب می‌شود.

$$T_j = \max\{Y_j\} \quad (37)$$


بعد از مشخص شدن نرون برنده، بردار وزن بالا به پایین مربوط به نرون برنده به لایه F1 ارسال می‌شود (وزن بالا به پایین مشابه وزن پایین به بالا است یا به عبارتی $W_{ij} = W_{ji}$). درجه شباهت بردار مذکور با بردار ورودی سنجیده می‌شود و اگر درجه شباهت از حدی (vigilance) کمتر باشد، ادعای نرون برنده برای دسته‌بندی کردن ورودی فعلی پذیرفته نخواهد شد و با غیر فعال شدن نرون برنده شبکه به حالت جستجو در آمده تا نرون برنده دیگری انتخاب شود. اگر نرونی در لایه F2 نتواند شرط vigilance را برآورده کند، نرون جدیدی در لایه F2 ساخته می‌شود (به این معناست که هیچ کدام از نرون‌های لایه F2 قادر به دسته‌بندی ورودی مورد نظر نیستند) و ورودی مورد نظر در کلاس مربوط به این نرون جای می‌گیرد. ولی اگر درجه شباهت بزرگتر یا مساوی ρ باشد به این مفهوم است که ورودی می‌تواند در کلاس مربوط به نرون برنده جای گیرد. درجه شباهت طبق رابطه (۳۸) تعیین می‌شود:

$$\frac{|I \wedge W_j|}{|I|} \geq \rho \quad (38)$$

وقتی در شبکه رزونانس رخ دهد (شرط vigilance برآورده شود) وزن‌های مربوط به ورودی مورد نظر طبق رابطه زیر به روز می‌شوند (عمل یادگیری رخ می‌دهد):


$$W_j^{new} = \beta(I \wedge W_j^{old}) + (1 - \beta)W_j^{old} \quad (39)$$

در رابطه (۳۹)، W^{old} بردار وزن قبل از یادگیری و W^{new} بردار وزن پس از یادگیری است. I بردار ورودی و β معرف ضریب



شکل (۱۰): مدل اصلی شبکه‌های ART

شبکه‌های عصبی ART با معرفی ART1 شناخته شدند و بعد از آن شبکه‌های ART2، ART2-a، Fuzzy ART، ARTMAP و Fuzzy ARTMAP معرفی شدند. شبکه‌ای است که ورودی‌های آن باینری (صفر و یک) است و در ابتدا برای دسته بندی حروف الفبا به کار برده شد. ART2 ساختاری مشابه ART1 دارد با این تفاوت که ورودی‌های آن آنالوگ نیز می‌تواند باشد. ART2-a مدل سریع و ساده شده ART2 است. شبکه Fuzzy ART ساختاری مشابه ART1 دارد. در این شبکه به جای استفاده از رابطه‌های منطقی از رابطه‌های فازی استفاده شده است که این شبکه را قادر به پذیرفتن ورودی‌های آنالوگ علاوه بر ورودی‌های باینری می‌کند. به عنوان مثال در این شبکه عملگر AND منطقی ($\cap$) که در شبکه ART1 استفاده می‌شود با عملگر AND فازی ($\wedge$) عوض شده است. شکل (۱۱) ساختار شبکه Fuzzy ART را نشان می‌دهد که از سه لایه تشکیل شده است [۲۸]. عملکرد شبکه Fuzzy ART به طور خلاصه در ذیل آمده است:



شکل (۱۱): ساختار شبکه Fuzzy ART


بردار ورودی (I) به لایه F0 وارد شده و عمل نرمالیزه سازی روی آن انجام می‌شود و سپس بردار حاصل (X) به لایه F1 منتقل می‌شود. بردار X با رابطه (۳۳) به لایه F2 منتقل شده و بردار Y در لایه F2 تشکیل می‌شود.

$$I = I_1, I_2, \dots, I_n \quad (31)$$

یادگیری است و مقدار آن بین صفر و یک انتخاب می‌شود. طبق [28] در یادگیری سریع مقدار β را برابر با یک در نظر می‌گیرند. همچنین وقتی نرون برنده برای اولین بار در یادگیری شرکت می‌کند $\beta=1$ و برای دفعات بعدی $\beta < 1$ انتخاب می‌شود.

۷- شبکه توزیع مورد آزمایش

به منظور تست روش پیشنهادی (شکل (۱))، از داده‌های واقعی جریان خطای امپدانس بالا که از فیدر بدون بار پالاش واقع در محدوده شرکت توزیع جنوب غرب تهران با مدار تک خطی نشان داده شده در شکل (۱۲) جمع آوری شده، استفاده شده است [۲۹]. این فیدر از طریق یک ترانسفورماتور ۶۳/۲۰ کیلوولت با توان نامی ۳۰ مگاوات آمپر تغذیه می‌گردد که اتصالات آن در سمت فشار قوی و ضعیف به ترتیب ستاره و مثلث هستند و سمت ۲۰ کیلوولت آن از طریق یک ترانسفورماتور زیگزاگ و مقاومت متغیر تنظیم شده در اندازه ۲۹/۵ اهم زمین شده است. همچنین بر روی باس بار این پست دو خازن، هر کدام با اندازه ۲/۴ مگاوار از طریق کلیدهای فشار قوی متصل هستند. سیگنال‌های ناشی از خطای امپدانس بالا و حالت‌های غیر خطا مانند بار هامونیک و جریان ناشی مقرر از طریق دستگاه ION 7650 و با نرخ نمونه برداری ۶۴ نمونه در هر سیکل در محل پست اندازه‌گیری شده‌اند.



شکل (۱۲): دیگرام تک خطی شبکه توزیع مورد آزمایش

جدول (۱) شرایط آزمایش خطای امپدانس بالا را برای شبکه واقعی نشان می‌دهد. به دلیل اینکه آزمایش حالت‌های غیرخطای دیگر مانند کلید زنی بار، کلید زنی بانک خازنی و کلید زنی ترانسفورماتور بی‌بار در یک شبکه واقعی همراه با مشکلات زیادی است از داده‌های شبیه‌سازی شده با استفاده از مدلسازی شبکه مذکور در نرم افزار ATP برای این حالت‌ها استفاده شده است. ولی حالت‌های غیر خطای دیگر مانند بار

هامونیک و جریان ناشی مقرر (ILC) در محل پست از طریق دستگاه ION 7650 و با نرخ نمونه برداری ۶۴ نمونه در هر سیکل برداشت شده‌اند. جدول (۲) انواع مختلف پدیده‌های خطا و غیرخطا را برای شبکه واقعی و پدیده‌های غیرخطا را برای شبکه مدلسازی شده نشان می‌دهد.

جدول (۱): شرایط آزمایش‌های خطای امپدانس بالا

شماره آزمایش	نوع سطح	شرایط	نکات	شرایط فیدر در حین آزمایش
۱	بتن	۲۰ سانتی متر	همراه با قوس‌های بسیار کوتاه	بی باری
		۱۰ سانتی متر	همراه با قوس‌های متعدد و طول‌های مختلف	بی باری
	آسفالت	۲ سانتی متر	همراه با قوس	بی باری
۲	بتن	۱۰ سانتی متر	همراه با قوس‌های متعدد و طول‌های مختلف	۱۰ درصد بار نامی
	درخت	خشک	همراه با قوس‌های ریز	۱۰ درصد بار نامی
۳	بتن	۱۵ سانتی متر	همراه با قوس‌های کوتاه	۵۰ درصد بار نامی
	آسفالت	۱۰ سانتی متر	همراه با قوس‌های بسیار کوتاه	۵۰ درصد بار نامی
	سنگریزه	۱۰ سانتی متر	همراه با قوس‌های کوتاه	۵۰ درصد بار نامی

شکل (۱۳) ساختار فیزیکی آزمایش خطای امپدانس بالا را بر روی سطوح سیمان، آسفالت و سنگریزه و همچنین تماس هادی با درخت را نشان می‌دهد.

جدول (۲): تعداد نمونه‌های انواع مختلف پدیده‌های خطا و غیرخطا

پدیده‌های مختلف		تعداد	
شبکه واقعی	HIF	هادی بریده نشده (در تماس با درخت)	۱۱۴۸
		هادی بریده شده	۲۴۹۲
	No-HIF	جریان ناشی مقرر	۵۳۲
		بار هامونیک	۲۸
شبکه مدلسازی شده در نرم افزار ATP	No-HIF	کلید زنی بانک خازنی	۱۵۱۲
		کلید زنی بار	۴۲۰۰
	No-HIF	کلید زنی ترانسفورماتور بی بار	۷۲
		خطای سه فاز در فیدر مجاور	۲۸۸

لایه و شبکه عصبی Fuzzy ART

		تعداد نمونه ها		% درست		% نادرست	
		آموزش	تست	Multi-Layer SVM	Fuzzy ART	Multi-Layer SVM	Fuzzy ART
تبدیل S	No-HIF	۳۹۵۵	۲۵۷۳	۹۸/۴۸	۹۸/۹۹	۱/۵۲	۱
	هادی بریده نشده	۶۵۳	۴۹۵	۹۹/۷۹	۹۹/۵۹	۰/۲	۰/۴
	آسفالت	۳۴۱	۱۹۱	۹۷/۹	۹۴/۲۴	۲/۱	۵/۷۵
	سیمان	۱۴۶۷	۱۰۲۵	۹۷/۵۶	۹۸/۵۳	۲/۴۴	۱/۴۶
	سنگریزه	۲۱	۷	۱۰۰	۱۰۰	۰	۰
	مجموع	۶۴۳۷	۴۲۹۱	۹۸/۳۹	۹۸/۷۴	۱/۶	۱/۲۵
تبدیل TT	No-HIF	۳۹۵۵	۲۵۷۳	۹۸/۸	۹۹/۲۲	۱/۲	۰/۷۷
	هادی بریده نشده	۶۵۳	۴۹۵	۱۰۰	۹۹/۶	۰	۰/۴
	آسفالت	۳۴۱	۱۹۱	۹۸/۴۳	۹۸/۹۵	۱/۵۷	۱/۰۴
	سیمان	۱۴۶۷	۱۰۲۵	۹۸/۰۴	۹۸/۹۲	۱/۹۵	۱/۰۷
	سنگریزه	۲۱	۷	۱۰۰	۱۰۰	۰	۰
	مجموع	۶۴۳۷	۴۲۹۱	۹۸/۷۴	۹۹/۱۸	۱/۲۵	۰/۸۱



شکل (۱۳): ساختار فیزیکی آزمایش خطای امپدانس بالا

۸- نتایج و تحلیل

بعد از استخراج ویژگی از یک سیکل سیگنال جریان، برای ارزیابی روش پیشنهادی، مجموعه داده‌های تولیدی به دو دسته نمونه‌های آموزشی و تست تقسیم‌بندی شده‌اند. در این مقاله از ۶۰ درصد کل داده‌ها برای مرحله آموزش و از ۴۰ درصد باقی مانده برای مرحله تست استفاده شده است.

به منظور تشخیص خطای امپدانس بالا، مجموعه داده‌های تست و آموزش به ماشین بردار تکیه‌گاه چند لایه و شبکه عصبی اعمال شده است. جدول (۳) داده‌های استفاده شده در مرحله آموزش و تست ماشین بردار تکیه‌گاه چند لایه و شبکه عصبی Fuzzy ART و همچنین مقادیر درصدی تشخیص درست و نادرست در مرحله تست را نشان می‌دهد. نتایج و دقت ماشین بردار تکیه‌گاه چند لایه و شبکه عصبی Fuzzy ART در جدول (۴) آمده است. همانطور که در جدول‌های (۳) و (۴) دیده می‌شود، اعمال ویژگی‌های استخراج شده از تبدیل TT به ماشین بردار تکیه‌گاه چند لایه و شبکه عصبی Fuzzy ART نتایج دسته بندی بهتری نسبت به اعمال ویژگی‌های استخراج شده از تبدیل S دارد. همچنین شبکه عصبی Fuzzy ART نسبت به ماشین بردار تکیه‌گاه چند لایه از دقت بالاتری در دسته بندی نمونه‌ها برخوردار بوده است.

جدول (۴): نتایج دسته بندی

		تعداد داده های ورودی		تشخیص درست		تشخیص نادرست		دقت (%)	
		تعداد	داده های	درست	نادرست	درست	نادرست	درست	نادرست
تبدیل S	Multilayer SVM	۴۲۹۱	۴۲۲۲	۶۹	۹۸/۳۹				
	Fuzzy ART	۴۲۹۱	۴۲۳۷	۵۴	۹۸/۷۴				
تبدیل TT	Multilayer SVM	۴۲۹۱	۴۲۳۷	۵۴	۹۸/۷۴				
	Fuzzy ART	۴۲۹۱	۴۲۵۶	۳۵	۹۹/۱۸				

۹- نتیجه گیری

در این مقاله، دو دسته بندی کننده ماشین بردار تکیه‌گاه چند لایه و شبکه عصبی Fuzzy ART برای تشخیص نوع خطای امپدانس بالا (هادی بریده شده و هادی بریده نشده) و همچنین تعیین نوع سطح تماس (آسفالت، سیمان و سنگریزه) با هادی در شبکه‌های توزیع با اعمال ویژگی‌های استخراج شده از تبدیل TT

- Recognition," IEEE Transactions on Power Delivery, Vol. 20, No. 4, Oct. 2005.
- [12] S.R. Samantaray and P.K. Dash, "High Impedance Fault Detection in Distribution Feeders Using Extended Kalman Filter and Support Vector Machine," European Transactions on Electrical Power, Vol. 20, pp. 382-393, April 2010.
- [13] B. Vahidi, N. Ghaffarzadeh, S. H. Hosseini and S. M. Ahadi, "An Approach to Detection of High Impedance Fault Using Discrete Wavelet Transform and Artificial Neural Networks," SIMULATION, Vol. 86, pp. 203-215, April 2010.
- [14] Y. Huang, M. Chen, J. Zhai and H. Yan, "High Impedance Fault Identification Method of Distribution Networks," Advanced Materials Research, Vols. 516-517, pp. 1785-1790, 2012.
- [15] A. Eldin, E. Abdallah and N. Mohamed, "Detection Of High Impedance Faults In Medium Voltage Distribution Networks Using Discrete Wavelet Transform," CIREN, June 2013.
- [16] W. C. Santos, F. V. Lopes, N. S. D. Brito, B. A. Souza, D. Fernandes and W. L. A. Neves, "Detection of High Impedance Fault in Power Distribution Systems Using Mathematical Morphology," High Impedance Fault Detection and Location Based on Electromagnetic Transient Analysis," International Conference on Power Systems Transients (IPST2013).
- [17] S. Gautam, S. M. Brahma, "Detection of High Impedance Fault in Power Distribution Systems Using Mathematical Morphology," IEEE Transaction on Power Systems, No.2, pp. 1226-1234, September 2012.
- [18] M. Sarlak, S.M. Shahrtash, "High-Impedance Faulted Branch Identification Using Magnetic-Field Signature Analysis," IEEE Transaction on Power Delivery, No.1, pp. 67-74, January 2013.
- [19] ایمان نیکوفکر، مصطفی سرلک، سید محمد شهرتاش، "تشخیص نوع خطای امپدانس بالا در شبکه‌های توزیع"، پانزدهمین کنفرانس شبکه‌های توزیع نیروی برق، تهران، اردیبهشت ۱۳۸۹.
- [20] R.G. Stockwell, L. Mansinha, and R. P. Lowe, "Localization of the complex spectrum: The *S*-transform," IEEE Trans. Signal Processing, vol. 44, pp. 998-1001, April 1996.
- [21] C.R. Pinnegar, L. Mansinha, "A method of time-time analysis: The *TT*-transform," Digital Signal Processing, vol. 13, pp. 588-603, 2003.
- [22] S.R. Samantaray, B.K. Panigrahi and P.K. Dash, "High Impedance Fault Detection in Power Distribution Networks Using Time-Frequency Transform and Probabilistic Neural Network," IET General Transmission Distribution, vol. 2, no. 2, pp. 261-270, 2008.
- [23] C. Cortes and V. Vapnik, "Support Vector Networks," Machine Learning, vol. 20, pp. 293-297, 1995.

و تبدیل S از یک سیکل جریان عبوری از فیدر توزیع، پیشنهاد شد. این ویژگی‌ها شامل انرژی، انحراف از معیار و انحراف مطلق از میانگین هستند که از اطلاعات زمان-زمان ماتریس حاصل از تبدیل TT و اطلاعات زمان-فرکانس ماتریس حاصل از تبدیل S به دست می‌آیند. نتایج حاصل از بکارگیری الگوریتم پیشنهادی بر روی داده‌های واقعی بدست آمده از آزمایش‌های عملی خطای امپدانس بالا، حاکی از آن است که ویژگی‌های استخراج شده از تبدیل TT نسبت به تبدیل S بهتر بوده و همچنین شبکه عصبی Fuzzy ART دارای دقت بیشتری در دسته بندی در برابر ماشین بردار تکیه گاه چند لایه است.

مراجع

- [1] "High Impedance Fault Detection Technology," Report of IEEE PSRC Working Group D15, March 1996.
- [2] R. Chrisite, H. Zadehgole, M. Habib, "High impedance fault detection in low voltage networks," IEEE Transaction on Power Delivery, No.4, pp. 1829-1836, October 1993.
- [3] M.A. Aucoin, B.D. Russell, "Distribution high impedance detection utilizing high frequency components," IEEE Transaction on Power Systems, No.6, pp. 1596-1606, June. 1982.
- [4] M. Aucoin, J. Zeigler, B.D. Russell, "Feeder protection and monitoring system part 1 : design implementation and testing," IEEE Transaction on Power Systems, pp. 873-880, No.4, April 1985.
- [5] B.D. Russell, R.P. Chinchali, "A digital signal processing algorithm for detection arcing faults on power distribution feeders," IEEE Transaction on Power Delivery, No.1, pp. 132- 140, January 1989.
- [6] C.J. Kim, B.D. Russell, "Classification of faults and switching's events by inductive reasoning and expert system methodology," IEEE Transaction on Power Delivery, No.3, pp. 1631- 1637, 1989.
- [7] A.F. Sultan, G.W. Swift, D.J. Fedrichuk, "Detection of High Impedance Arcing Fault Using a Multi-Layer Perceptron," IEEE Transaction on Power Delivery, Vol.7, No.4, October 1992.
- [8] D. Jeeringes, J.R. Linders, "Unique aspects of distribution harmonic due to high impedance ground faults," IEEE Transaction on Power Delivery, No.2, pp. 1086-1094, April 1990.
- [9] A. Girgis, W. Chang, "Analysis of High Impedance Fault Generated Signal Using a Kalman Filtering Approach," IEEE Transaction on Power Delivery, Vol.5, No.4, November 1990.
- [10] M.A. Aucion, B.D. Russell, "Detection of high impedance faults using bursts signals near 60 Hz," IEEE Transaction on Power Delivery, No.2, pp. 342-348, April 1987.
- [11] A. Sedighi, M. Haghifam, O. P. Malik, M. Ghassemian, "High Impedance Fault Detection Based on Wavelet Transform and Statistical Pattern



- [24] J. C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition," Data Mining and Knowledge Discovery, vol. 2, no. 2, pp. 121-167, 1998.
- [25] G. Lv, H. Cheng, H. Zhai, L. Dong, "Fault diagnosis of power transformer based on multilayer SVM classifier" Electric Power Systems Research, vol.75, pp. 9-15, 2005.
- [۲۶] رضا دانش آموز و جواد ساده "ارائه روش جدید بکارگیری طبقه بندی کننده SVM جهت طبقه بندی خطاهای داخلی ترانسفورماتورهای قدرت"، بیست و چهارمین کنفرانس بین المللی برق، تهران، ۲۵-۲۷ آبان ۱۳۸۸.
- [27] G. A. Carpenter and S. Grossberg, "A massively parallel architecture for a self-organizing neural pattern recognition machine," Computer Vision, Graphics, and Image Processing, vol. 37, pp. 54-115, 1987.
- [28] G. A. Carpenter, S. Grossberg and D. B. Rosen, "Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system," Neural Networks, vol. 4, pp. 759-771, 1991.
- [۲۹] رسول خلیلی و همکاران "بررسی رفتار خطای امپدانس بالا بر روی سطوح مختلف مبتنی بر آزمایشات واقعی"، چهاردهمین کنفرانس شبکه‌های توزیع نیروی برق، کرمان، اردیبهشت ۱۳۸۸.

زیرنویس‌ها

- ¹ High Impedance Fault
- ² Median Absolute Deviation
- ³ Hyper plane
- ⁴ Soft Margin Hyper plane
- ⁵ Kernel Function
- ⁶ Radial Basis Function
- ⁷ Multi Layer Perceptron
- ⁸ Multi-Layer SVM
- ⁹ Long Term Memory
- ¹⁰ Short Term Memory

