

Detection of internal fault from external fault and inrush current in power transformers based on combination of VMD and ELM

Faeghe Babaei-Roudi¹, Ali Akbar Abdoos²

¹ Department of Electrical and Computer Engineering, Babol Noshirvani University of Technology, Babol, Iran

² Department of Electrical and Computer Engineering, Babol Noshirvani University of Technology, Babol, Iran

Abstract :

Power transformers are one the most expensive and important equipment of power systems that play an important role in the continuous supply of electrical energy. Therefore, their protection has a significant impact on network reliability and stability. The differential protection scheme equipped with harmonic restraint is used for detection of transformer internal faults. But, current transformer (CT) saturation would have undesirable effect on its performance. In some cases, the CT saturation during internal fault can lead to even harmonics which can prevent the relay from sending trip signal. Moreover, the CT saturation due to DC offset of inrush current can result in relay maloperation. In this paper, a new feature is extracted from differential current based on VMD analysis. This feature as well as differential and bias magnitudes are used for detection of internal faults from other operating conditions. In the proposed method, different classifier such as ANN, PNN and ELM have been used as classifier core. The obtained results show that the proposed the combination of VMD and ELM can correctly detect all internal faults even with severe CT saturation.

Keywords: Power Transformer Protection, Variational Mode Decomposition (VMD) Transform, Current Transformer (CT) Saturation, Extreme Learning Machine (ELM).

تشخیص خطای داخلی از جریان هجومی و خطای خارجی در ترانسفورماتورهای قدرت براساس تبدیل VMD و ماشین یادگیری بی نهایت فائقه بابایی رودی^۱، علی اکبر عبدوس^{۲*}

۱- دانشجوی کارشناسی ارشد، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران

faeghebabae@yahoo.com

۲- استادیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران

a.abdoos@nit.ac.ir

چکیده: ترانسفورماتورهای قدرت از تجهیزات گران قیمت و مهم در سیستم‌های قدرت‌اند که در تأمین پیوسته انرژی الکتریکی نقش مهمی دارند؛ بنابراین، حفاظت از آنها تأثیر به‌سزایی در افزایش قابلیت اطمینان و حفظ پایداری شبکه دارد. طرح حفاظت دیفرانسیل مجهز به نگهدارنده هارمونیک برای تشخیص خطاهای داخلی ترانسفورماتور استفاده می‌شود؛ اما اشباع ترانسفورماتورهای جریان ممکن است بر عملکرد آن تأثیر نامطلوبی داشته باشد. در برخی موارد، اشباع ترانسفورماتور جریان در حین خطای داخلی با ایجاد هارمونیک‌های زوج همراه است که مانع عملکرد رله می‌شود. همچنین، اشباع ترانسفورماتور جریان با ظاهر شدن مؤلفه DC در زمان برق‌دار شدن ترانسفورماتور باعث عملکرد بی‌مورد رله می‌شود. در این مقاله یک ویژگی جدید با استفاده از آنالیز جریان دیفرانسیل با تبدیل VMD استخراج می‌شود. این ویژگی به همراه دامنه جریان دیفرانسیل و جریان بایاس به منظور شناسایی خطای داخلی از دیگر شرایط به کار گرفته می‌شود. نتایج شبیه‌سازی نشان می‌دهد ترکیب VMD با ماشین یادگیری بی‌نهایت قادر است حتی با وجود اشباع ترانسفورماتور جریان، تمامی خطاهای داخلی را به‌درستی تشخیص دهد.

واژه‌های کلیدی: اشباع ترانسفورماتور جریان، تبدیل VMD، حفاظت ترانسفورماتورهای قدرت، ماشین یادگیری بی‌نهایت

۱- مقدمه

اهمیت زیادی دارد. حفاظت دیفرانسیل، ابتدایی‌ترین طرح حفاظتی بر مبنای مقایسه جریان‌های ورودی و خروجی به ترانسفورماتور ارائه شده است. حفاظت دیفرانسیل درصدی به‌منظور جلوگیری از عملکرد اشتباه رله در زمانی ارائه شده است که ترانسفورماتورهای جریان اشباع می‌شوند. برای پایداری رله در زمان برق‌دار شدن ترانسفورماتور نیز رله‌های دیفرانسیل درصدی به نگهدارنده هارمونیک مجهز شده‌اند؛ اما احتمال عملکرد اشتباه رله‌های دیفرانسیل برای خطاهای خارجی همراه با اشباع شدید ترانسفورماتورهای جریان وجود دارد. همچنین، اشباع ترانسفورماتورهای جریان در حین خطاهای داخلی موجب ظاهر شدن هارمونیک‌های زوج

ترانسفورماتورهای قدرت از تجهیزات گران قیمت و مهم در پست‌های فشار قوی است؛ به‌طوری‌که خروج نابه‌جای آن بر قابلیت اطمینان سیستم قدرت تأثیر منفی می‌گذارد؛ بنابراین، حفاظت از ترانسفورماتورهای قدرت

* تاریخ ارسال مقاله: ۱۳۹۷/۰۱/۲۱

تاریخ پذیرش مقاله: ۱۳۹۷/۰۴/۰۲

نام نویسنده مسئول: علی اکبر عبدوس

نشانی نویسنده مسئول: ایران، بابل، خیابان شریعتی، دانشگاه صنعتی نوشیروانی بابل، دانشکده برق و کامپیوتر

VMD، پارامترهای متغیر کمی دارد که برخلاف تبدیل موجک به تعیین موجک مادر نیاز ندارد؛ این تبدیل به نویز و فرکانس نمونه برداری نیز حساس نیست.

ویژگی جدید براساس آنالیز VMD از جریان دیفرانسیل استخراج می شود. این ویژگی به همراه دامنه جریان دیفرانسیل و بایاس در مرحله تشخیص خطا استفاده می شود. خطاهای داخلی و خارجی و شرایط برقرارکردن ترانسفورماتور قدرت با در نظر گرفتن مؤثر بر آنها در شرایط مختلفی در نرم افزار PSCAD/EMTDC شبیه سازی می شوند [۲۱]. به منظور در نظر گرفتن اشباع ترانسفورماتور جریان از مدل دقیق جیلز - اسرتون استفاده شده است [۲۲]. سپس ویژگی های استخراج شده با طبقه بندی کننده مناسب از یکدیگر تفکیک می شوند. طبقه بندی کننده های مختلفی از جمله ماشین یادگیری بی نهایت^۲ [۲۳]، شبکه عصبی مصنوعی^۳ و شبکه عصبی احتمالاتی^۴، هسته های تشخیص به کار گرفته شده اند تا بهترین عملکرد به دست آید. الگوریتم هوشمند ارائه شده با استفاده از نرم افزار MATLAB پیاده سازی می شود. نتایج به دست آمده برای شرایط کاری مختلف ترانسفورماتور قدرت بررسی و ارزیابی شد.

۲- ابزارهای به کار گرفته شده

۲-۱- تبدیل VMD

VMD، روش پردازش سیگنال غیربازگشتی و بهبودیافته تبدیل EMD^۵ است که محدودیت های EMD مانند حساسیت به نویز و فرکانس نمونه برداری را ندارد. تبدیل VMD قادر است سیگنال حقیقی f را به مودهای u_k تجزیه کند؛ به گونه ای که مجموع مودها با سیگنال ورودی برابر است. در این تبدیل فرض می شود هر مود حول یک فرکانس مرکزی متمرکز شده است [۲۰]. به منظور به دست آوردن مودها و فرکانس مرکزی آنها، مسئله بهینه سازی زیر باید حل شود [۲۰]:

$$\min \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-i\omega_k t} \right\|_2^2 \right\} \quad (1)$$

$$s.t. \quad \sum_k u_k = f(t)$$

در جریان دیفرانسیل می شود که از عملکرد رله جلوگیری می کند [۱-۴].

مقالات زیادی به منظور بهبود عملکرد طرح حفاظت دیفرانسیل ارائه شده است تا بدین ترتیب دقت تشخیص خطای داخلی از دیگر شرایط کاری ترانسفورماتور بهبود یابد. در برخی از روش های ارائه شده، تشخیص خطای داخلی براساس ویژگی های استخراج شده از جریان دیفرانسیل در حوزه زمان انجام شده است [۴].

روش های هوشمندی نیز برای تشخیص خطای داخلی مبتنی بر شناسایی الگو ارائه شده است. در این روش ها از طبقه بندی کننده های مختلفی از جمله شبکه عصبی مصنوعی [۵-۸]، شبکه عصبی احتمالاتی [۹ و ۱۰]، ماشین بردار پشتیبان [۱۱] و سیستم های فازی عصبی [۱۲] به منزله هسته تشخیص دهنده استفاده شده است. در این روش های هوشمند به الگوهای آموزشی زیادی نیاز است. همچنین، روش مشخصی برای تعیین پارامترهای مربوط به شبکه های عصبی برای تعیین ساختار بهینه وجود ندارد و باید از الگوریتم های بهینه سازی بهره برد [۱۳]. در برخی از روش های ارائه شده با کمک ابزارهای آنالیز سیگنال، ویژگی هایی از شکل موج جریان دیفرانسیل استخراج می شود؛ بدین ترتیب، حجم داده های ورودی تا حد زیادی، کاهش و قابلیت تعمیم الگوریتم هوشمند افزایش می یابد. تبدیل موجک [۱۷-۱۴] و S [۱۸، ۱۹] از جمله روش های متداول آنالیز سیگنال در تحلیل جریان دیفرانسیل است. در روش های مبتنی بر تبدیل موجک، تعداد سطوح تجزیه و موجک مادر مناسب باید با استفاده از روش سعی و خطا به دست آید. ویژگی های استخراج شده به خصوص ویژگی های استخراج از سطوح جزئیات نیز به نویز بسیار حساس است. همچنین در تبدیل S، سیگنال های تجزیه شده به مقدار پارامتر متغیر مربوط به پنجره گوسین وابسته است.

در این مقاله، روش هوشمند جدید مبتنی بر آنالیز سیگنال به منظور تشخیص خطای داخلی از جریان هجومی مغناطیس کننده و خطای خارجی ارائه شده است. الگوریتم ارائه شده شامل دو بخش مهم است؛ استخراج ویژگی ها و طبقه بندی ویژگی ها. در مرحله نخست، سیگنال جریان دیفرانسیل با تبدیل VMD^۱ آنالیز می شود [۲۰]. تبدیل

با توجه به الگوریتم بالا برای تحقق فرایند VMD، مقادیر ω_k و u_k باید به روزرسانی شوند؛ بنابراین، مسئله بهینه‌سازی رابطه (۲) نسبت به u_k باید حل شود [۲۰]:

$$u_k^{n+1} = \operatorname{rg\,min}_{u_k \in X} \left\{ \alpha \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-i\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_i u_i(t) + \frac{\lambda(t)}{2} \right\|_2^2 \right\} \quad (3)$$

با به کارگیری تقارن هرمیت $\hat{\cdot}$ ، طیف فرکانسی مربوط به سیگنال‌های مودهای مختلف به آسانی به دست می‌آید. جزء حقیقی تبدیل فوریه معکوس این سیگنال فیلترشده، مود را به حوزه زمان انتقال می‌دهد؛ بنابراین، جواب مسئله بهینه‌سازی درجه دوم بالا به صورت زیر خواهد بود [۲۰]:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (4)$$

در زیر مسئله دوم بهینه‌سازی، رابطه (۲) نسبت به ω_k حل می‌شود؛ بنابراین، خواهیم داشت:

$$\omega_k^{n+1} = \operatorname{arg\,min}_{\omega_k} \left\{ \alpha \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-i\omega_k t} \right\|_2^2 \right\} \quad (5)$$

جواب مسئله بهینه‌سازی بالا در حوزه فرکانس به صورت زیر خواهد بود [۲۰]:

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (6)$$

که ω_k جدید را در مرکز ثقل قسمت مثبت مودهای مشابه طیف قدرت قرار می‌دهد؛ بنابراین با تکرار فرایند بالا تا رسیدن به همگرایی لازم، مودهای تجزیه‌شده محاسبه می‌شوند.

۲-۲- ماشین یادگیری بی‌نهایت

نخستین بار هوانگ، ماشین‌های یادگیری بی‌نهایت (ELM) را برای اهداف طبقه‌بندی و تخمین معرفی کرد [۲۲]. ELM بر مبنای یک شبکه یک‌لایه پیش‌خور (SLFN) بنا نهاده شده است که شامل لایه ورودی، لایه پنهان و لایه خروجی است.

ماشین یادگیری بی‌نهایت برای N نمونه دلخواه مجزا $(\mathbf{p}_j, \mathbf{o}_j) \in \mathbb{R}^n \times \mathbb{R}^m$ و با در نظر گرفتن یک شبکه یک‌لایه

که $f(t)$ سیگنال اصلی و $\{u_k\} := \{u_1, \dots, u_K\}$ و $\{\omega_k\} := \{\omega_1, \dots, \omega_K\}$ به ترتیب مجموعه مودهای تجزیه‌شده و فرکانس‌های مرکزیشان هستند. همچنین، $\delta(t)$ پاسخ ضربه و $*$ نشان‌دهنده عملگر کانولوشن است. برای حل مسئله بهینه‌سازی فوق از ضرایب جریمه درجه دو و ضرایب لاگرانژ استفاده می‌شود؛ بنابراین، مسئله بالا به صورت مسئله بهینه‌سازی نامقید به صورت زیر ارائه می‌شود [۲۰]:

$$\mathcal{L}(\{u_k\}, \{\omega_k\}, \lambda) := \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-i\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (2)$$

که در آن، α پارامتر متعادل‌ساز قید است. سپس برای حل مسئله مینیمم‌سازی ارائه‌شده در (۲) از روش مسیر متناوب ضرایب (ADMM) استفاده می‌شود. به دلیل اینکه در روش ADMM، جواب مسئله با محاسبه نقطه زینی تابع لاگرانژ به واسطه حل متوالی زیرمسئله‌های بهینه‌سازی به دست می‌آید، برای مسائل پیچیده، همگرایی بهتری در مقایسه با بعضی از روش‌های بهینه‌سازی غیرمحدب مانند روش نقطه درونی^۷ دارد [۲۰]. الگوریتم پیاده‌سازی تجزیه VMD به صورت زیر تحقق می‌یابد:

$$\{\hat{u}_k^1\}, \{\omega_k^1\}, n \leftarrow 0$$

تکرار

$$n \leftarrow n + 1$$

for $k = 1 : K$ do

$$\text{به‌روزرسانی } \{u_k^1\} \text{ برای } \omega_k \geq 0:$$

به‌روزرسانی ω_k

$$\omega_k^{n+1} \leftarrow \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega}$$

end for

برای تمامی $\omega \geq 0$:

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau \left(\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right)$$

تا رسیدن به همگرایی $\sum_k \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2 / \|\hat{u}_k^n\|_2^2 < \epsilon$

پیش خور با L گره مخفی و تابع تحریک $G(a_i, b_i, p_j)$ به صورت ریاضیاتی مطابق فرمول زیر مدل می شود [۲۳]:

$$\sum_{i=1}^N \beta_i G(a_i, b_i, p_j) = o_j \quad j = 1, 2, \dots, N \quad (7)$$

که a_i بردار وزن ورودی متصل به گره مخفی نام و گره های ورودی است و b_i آستانه یا ضریب تأثیر^۱ گره پنهان نام و β_i بردار وزن متصل به گره پنهان نام است. فرمول (۷) به صورت ماتریس زیر نوشته می شود [۲۳]:

$$H\beta = O \quad (8)$$

$$H = \begin{bmatrix} h(p_1) & \dots & h(p_N) \end{bmatrix} \begin{bmatrix} G(a_1, b_1, p_1) & \dots & G(a_L, b_L, p_1) \\ \vdots & \dots & \vdots \\ G(a_1, b_1, p_N) & \dots & G(a_L, b_L, p_N) \end{bmatrix}_{N \times L}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}, \quad O = \begin{bmatrix} o_1^T \\ \vdots \\ o_L^T \end{bmatrix}_{N \times m}$$

که در رابطه بالا H ماتریس خروجی لایه پنهان است که ستون نام آن خروجی گره پنهان نام با ورودی های p_1, p_2, \dots, p_N است.

اثبات شده است که برای هر تابع پیوسته تکه ای غیر ثابت مانند G ، تابع هدف پیوسته $f(p)$ با شبکه یک لایه پیش خور و بدون تنظیم پارامترهای گره پنهان تقریب زده می شود؛ بنابراین، همه پارامترهای گره پنهان به صورت تصادفی، بدون اطلاع از داده های آموزش تولید می شوند؛ بنابراین، سه گام برای تحقق ELM باید اجرا شود [۲۳]:
گام اول، تعیین پارامترهای گره پنهان به صورت تصادفی؛

گام دوم، محاسبه ماتریس خروجی لایه پنهان (H)؛
گام سوم، محاسبه ماتریس وزن خروجی ($\beta = H^+ T$) که H^+ معکوس تعمیم یافته مور - پنروس^{۱۱} مربوط به ماتریس خروجی لایه پنهان (H) است.

این روش نسبت به برخی طبقه بندی کننده های هوشمند از جمله ماشین های بردار پشتیبان و شبکه عصبی مصنوعی برتری های زیر را دارد:

۱. سرعت یادگیری بالا؛
۲. قابلیت یادگیری الگوهای آموزشی با حجم بالای

داده؛

۳. عدم حساسیت عملکرد به تعداد گره های لایه پنهان.

۳- سیستم مورد مطالعه

برای ارزیابی عملکرد روش پیشنهادی، یک ترانسفورماتور سه فاز با نسبت تبدیل ۲۳۰/۶۳ کیلوولت با اتصال ستاره / مثلث و ظرفیت ۱۶۰ مگاوات آمپر در شبکه قدرت با استفاده از ترانسفورماتورهای جریان یک آمپری برای انواع خطاهای داخل و خارج ناحیه حفاظتی و شرایط برق دار کردن ترانسفورماتور در محیط نرم افزار PSCAD/EMTDC شبیه سازی شده است. انواع خطاها در داخل ناحیه حفاظتی و خارج از آن در لحظات مختلف و برای مقاومت های خطای ۰ و ۵۰ اهم تحت شرایط بارگذاری مختلف شبیه سازی می شود. همچنین، جریان هجومی مغناطیس کننده برای لحظات مختلف کلیدزنی با فاصله زمانی ۰/۴ میلی ثانیه در یک سیکل، با در نظر گرفتن شار پسماند بین ۰/۸- تا ۰/۸+ ایجاد می شود. منحنی مغناطیس شونده است ترانسفورماتور با استفاده از اطلاعات ولتاژ و جریان مربوط به آزمایش بی باری یا محاسبه نقطه زانویی شبیه سازی می شود. ماکزیمم شار پسماند در داخل هر ساق هسته ترانسفورماتور در حدود ۰/۸۰٪ پیک شار پیوندی در ولتاژ نامی در نظر گرفته شده است. شبیه سازی شار پسماند هسته بسیار مهم است؛ زیرا جریان هجومی در هنگام وصل ترانسفورماتور به اندازه شار پسماند وابسته است. شار پسماند با قرارداد یک منبع جریان به موازات هر سیم پیچ در اتصال ستاره مدل می شود [۲۳].

منحنی مغناطیس شونده هسته ترانسفورماتورهای جریان به همراه پارامترهای متناظر با آن در مدل جیلز اسرتون ارائه شده است [۲۲]. تمامی ترانسفورماتورهای جریان، کلاس دقت 5P20 دارند و حداکثر بار نامی آنها ۳۰ ولت آمپر است. مشخصات مربوط به ساختار ترانسفورماتورهای جریان نصب شده در دو طرف ترانسفورماتور قدرت در جدول (۱) ارائه شده است [۱۸]. همچنین، منحنی مغناطیس شونده هسته ترانسفورماتور جریان در شکل (۱) نشان داده شده است.

جدول (۱): ساختار ترانسفورماتورهای جریان

شناسایی خطا ندارند؛ به همین دلیل، انرژی مدهای اول و دوم در ارائه شاخص جدید به کار گرفته می‌شوند.

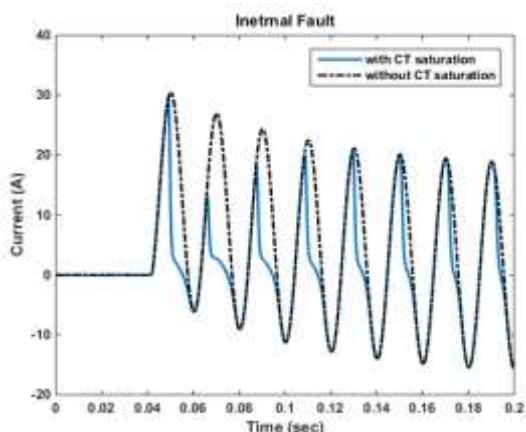
برای شرایط کاری مختلف ترانسفورماتور قدرت با به‌کارگیری یک سیکل از جریان دیفرانسیل قدرمطلق اختلاف انرژی مدهای اول و دوم و نسبت انرژی مود دوم به اول، محاسبه و در شکل (۵) نشان داده شده است. هر سیکل حاوی ۵۰ نمونه است؛ یعنی فرکانس نمونه‌برداری با $50 \times 50 = 2500 \text{ Hz}$ برابر است. شاخص جدید ارائه شده براساس مشاهدات زیر محاسبه می‌شود:

- همان‌طورکه در شکل (۳) مشاهده می‌شود، به‌طورکلی و بدون در نظر گرفتن اشباع، نسبت هارمونیک دوم به مؤلفه اصلی (I_2/I_1) در خطای داخلی نسبت به جریان هجومی کمتر است.

- مطابق شکل (۳-ج)، برای خطای خارجی در صورت به اشباع رفتن ترانسفورماتور جریان، نسبت هارمونیک دوم به مؤلفه اصلی (I_2/I_1) زیاد است.

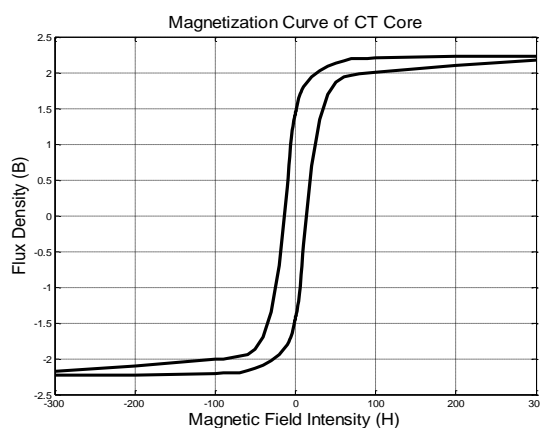
- مقدار اختلاف انرژی مود ۱ و ۲ برای حالت خطای داخلی نسبت به جریان هجومی و خطای خارجی بسیار بیشتر است. مطابق شکل (۵-الف)، این مقدار برای خطای داخلی به ۱۸۰۰ می‌رسد؛ درحالی‌که برای جریان هجومی و خطای خارجی کمتر از ۴۰ و ۴۰ است.

- طبق شکل (۵-ب)، نسبت انرژی مود ۲ به انرژی مود ۱ نیز برای حالت خطای داخلی به بیش از $2/77 \times 10^4$ می‌رسد که بسیار بیشتر از حالت‌های دیگر است.



الف) خطای داخلی

فشار ضعیف	فشار قوی	ترانسفورماتور جریان
۲۰۰۰/۱	۶۰۰/۱	نسبت تبدیل
$10/36 \times 10^{-4}$	$32/9 \times 10^{-4}$	سطح مقطع هسته به متر مربع
۰/۵۴۸	۰/۸۴۸	طول مسیر هسته به متر
۶۳	۲۳۰	سطح ولتاژ به کیلوولت
۷/۷۷	۴/۳	مقاومت سیم‌پیچ ثانویه به اهم



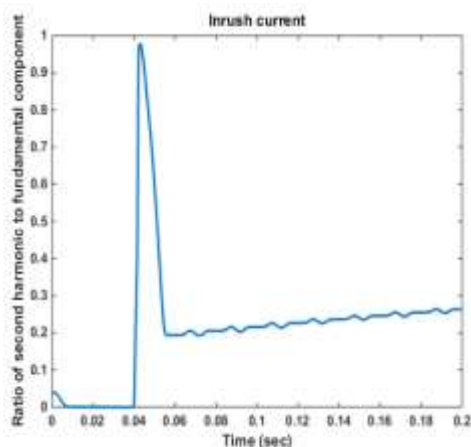
شکل (۱) منحنی مغناطیس‌شوندگی هسته ترانسفورماتورهای جریان

۴- تحلیل نتایج به دست آمده

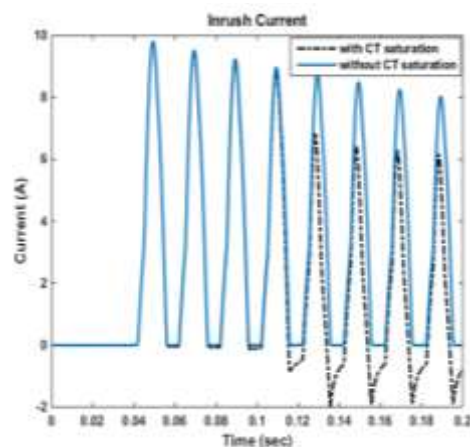
برای اینکه طرح پیشنهادی، فارغ از نوع طبقه‌بندی‌کننده بین خطای داخلی و سایر شرایط سیستم قدرت، با دقت مناسب تمایز ایجاد کند باید علاوه بر دو ویژگی جریان دیفرانسیل و بایاس، ویژگی متمایزکننده دیگری به طرح حفاظتی اضافه کند تا رله عملکرد مناسب داشته باشد.

مرحله مهم در روش‌های الگوشناسی، استخراج ویژگی‌های مهم از اطلاعات مشاهده‌شده در حالات و شرایط مختلف است. ویژگی ارائه‌شده در این روش با به‌کارگیری آنالیز تبدیل VMD استخراج شده است. در شکل (۲) نمونه‌هایی از شرایط کاری مختلف ترانسفورماتور نشان داده شده است. نسبت هارمونیک دوم به مؤلفه اصلی و مدهای تجزیه‌شده برای شرایط بالا به ترتیب در شکل (۳) و (۴) نمایش داده شده است. در این پژوهش، سیگنال اصلی به چهار مود تجزیه می‌شود؛ زیرا مدهای مرتبه بالاتر حاوی فرکانس‌های بالایی هستند که اطلاعات زیادی برای


تشخیص خطای داخلی از جریان هجومی و خطای خارجی در ترانسفورماتورهای قدرت براساس ...




ب) جریان هجومی بدون در نظر گرفتن اشباع



ب) جریان هجومی



ج) خطای خارجی با در نظر گرفتن اشباع



ج) خطای خارجی با اشباع ترانسفورماتور جریان

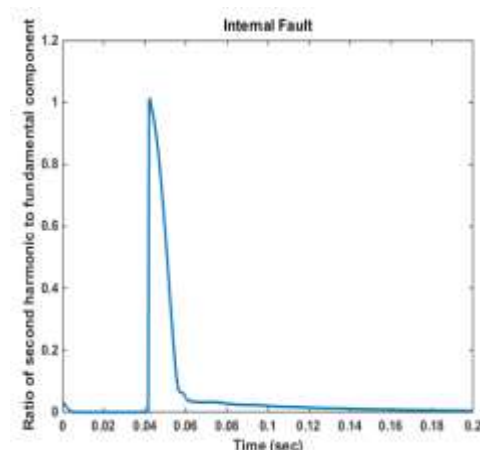
شکل (۳): نسبت هارمونیک دوم به مؤلفه اصلی در شرایط کاری مختلف ترانسفورماتور قدرت

شکل (۲): نمونه‌هایی از جریان دیفرانسیل در شرایط مختلف


با توجه به ویژگی‌های ذکر شده بالا، شاخص جدید به صورت زیر ارائه می‌شود:

$$Index = \frac{|E_1 - E_2|}{I_2/I_1} \times \frac{E_2}{E_1} \quad (9)$$

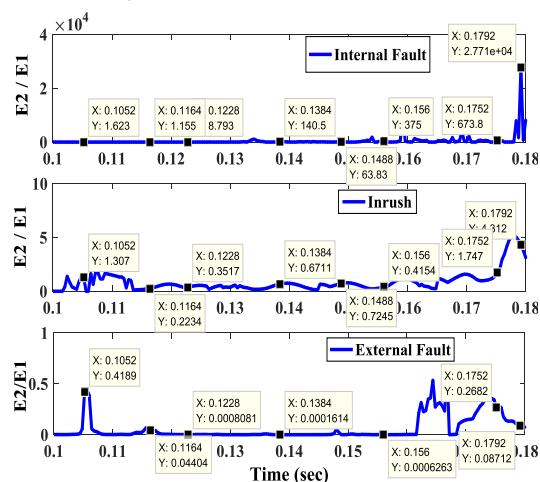
که E_1 و E_2 به ترتیب انرژی مود ۱ و مود ۲ و I_1 و I_2 نیز به ترتیب مؤلفه اصلی و هارمونیک دوم جریان دیفرانسیل هستند. مقدار این شاخص برای شرایط کاری مختلف در شکل (۶) نشان داده شده است؛ همان‌طور که مشاهده می‌شود مقدار شاخص محاسبه شده برای خطای داخلی به 1.6×10^7 می‌رسد؛ در حالی که برای جریان هجومی و خطای خارجی مقدار آن کمتر از ۲۰۰۰ و ۴۰ است.



الف) خطای داخلی بدون در نظر گرفتن اشباع

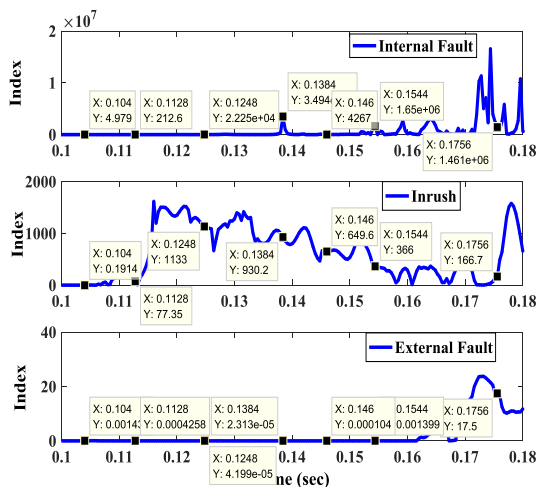


الف) اختلاف انرژی مود اول و دوم




ب) نسبت انرژی مود دوم به اول


شکل (۵): ویژگی‌های استخراج شده با استفاده از تبدیل VMD



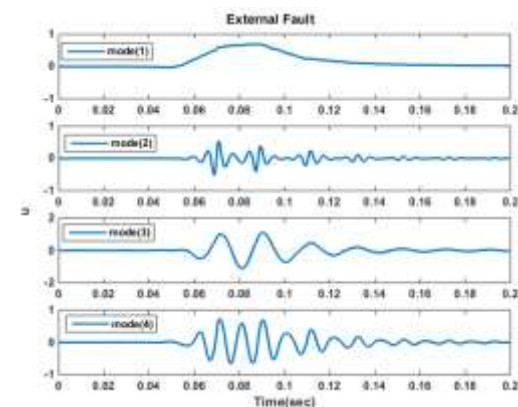
شکل (۶): شاخص ارائه شده



الف) خطای داخلی



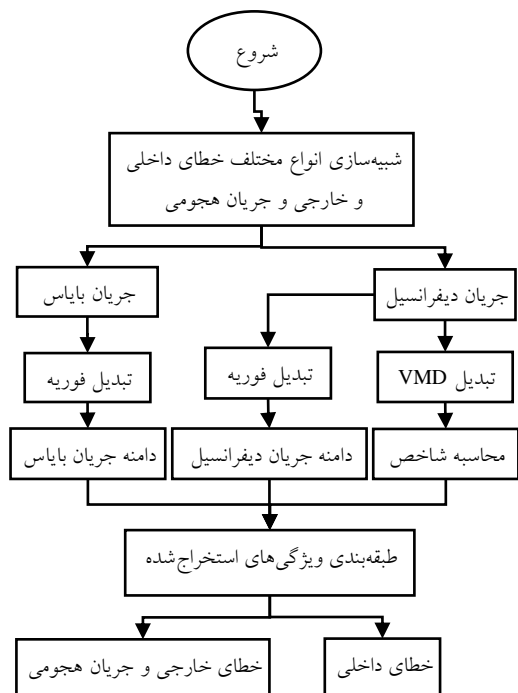
ب) جریان هجومی



ج) خطای خارجی


شکل (۷): مودهای تجزیه شده با استفاده از تبدیل VMD

است که در رابطه (۹) بیان شده است. در مرحله آخر، تشخیص خطای داخلی از خطای خارجی و جریان هجومی به وسیله طبقه‌بندی‌کننده مناسب صورت می‌گیرد.



شکل (۸): طرح الگوریتم پیشنهادی

ویژگی جدید پیشنهادی باید فضای ویژگی‌ها را به نواحی مجزایی تقسیم کند؛ به طوری که خطای داخلی از خطای خارجی و برق دار کردن ترانسفورماتور به درستی تفکیک شود. به منظور نشان دادن تفکیک پذیری ویژگی‌های استخراج شده، مقادیر نرمالیزه شده ویژگی استخراج شده، جریان دیفرانسیل و جریان بایاس برای ۳۰۰ نمونه مختلف از خطای داخلی، خطای خارجی و جریان هجومی در شکل (۷) به صورت سه بعدی رسم شده است. شکل (۷) نشان می‌دهد خطای داخلی در ناحیه‌ای قرار می‌گیرد که از خطای خارجی و جریان هجومی کاملاً مجزا شده است. با توجه به قدرت تفکیک پذیری بالای ویژگی استخراج شده، طبقه‌بندی‌کننده ماشین یادگیری بی‌نهایت قادر است تمامی خطاهای داخلی را به درستی تشخیص دهد.



شکل (۷): نمایش سه بعدی ویژگی‌های استخراج شده

۵-۱- بررسی عملکرد روش ارائه شده با در نظر

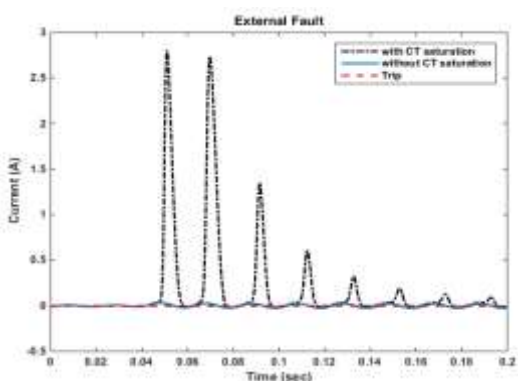
گرفتن اشباع ترانسفورماتور جریان

ترانسفورماتورهای جریان به دلیل افزایش شار عبوری از هسته در حین خطاهای داخلی، خارجی و حین برق دار شدن ترانسفورماتورهای قدرت در معرض اشباع قرار دارند. خطاها معمولاً دامنه جریان بزرگ دارند و مؤلفه میراثونده DC هستند که بزرگی آن با توجه به نوع خطا، مقاومت خطا و لحظه رخداد خطا متفاوت است. پارامترهای ذکر شده در به اشباع رفتن ترانسفورماتورهای جریان تأثیر زیادی دارند. همچنین، امکان اشباع ترانسفورماتورهای جریان در حین برق دار شدن ترانسفورماتورهای جریان به سبب ظاهر شدن مؤلفه DC و مؤلفه هارمونیک دوم افزایش می‌یابد؛ بنابراین، صحت عملکرد الگوریتم ارائه شده باید در زمانی بررسی شود که ترانسفورماتورهای جریان اشباع می‌شوند. به منظور ارزیابی عملکرد روش ارائه شده، ۱۰۰ حالت تست برای

۵- الگوریتم ارائه شده

فلوچارت تشخیص خطای داخلی از جریان هجومی و خطای خارجی با روش ارائه شده، در شکل (۸) نشان داده شده است. ابتدا انواع خطاها در لحظات مختلف و برای مقاومت‌های گوناگون خطا تحت شرایط بارگذاری مختلف برای سیستم تست اشاره شده شبیه‌سازی می‌شوند. همچنین، جریان هجومی مغناطیس‌کننده برای لحظات مختلف کلیدزنی با در نظر گرفتن شار پسماند ایجاد می‌شود. در مرحله بعد، سه ویژگی ذکر شده برای تشخیص خطای داخلی از سایر شرایط کاری ترانسفورماتور استخراج می‌شود. دو ویژگی استخراجی، همان جریان دیفرانسیل و جریان بایاس هستند و ویژگی سوم، شاخص ارائه شده توسط آنالیز جریان دیفرانسیل با استفاده از تبدیل VMD

هر خطایی خارج از ناحیه حفاظت شده رله دیفرانسیل، خطای خارجی در نظر گرفته می شود که به عملکرد رله نیاز نیست. مهم ترین مسئله در هنگام رخداد خطای خارجی این است که در جریان های بالا، احتمال اشباع ترانسفورماتور جریان وجود دارد؛ بنابراین، ممکن است در زمان رخداد خطای خارجی، جریان دیفرانسیل به اندازه ای زیاد شود که رله، فرمان قطع صادر کند. این عملکرد نامطلوب است و باید به گونه ای مناسب از عملکرد اشتباه رله جلوگیری کرد. همان طور که در شکل (۱۱) مشخص است سیستم حفاظتی در چنین شرایطی نیز عملکرد صحیح خواهد داشت.

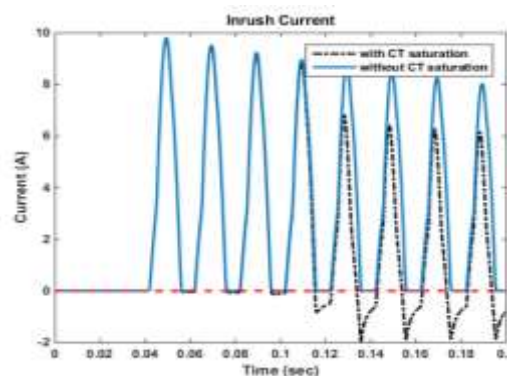


شکل (۱۱): عملکرد طرح حفاظتی در خطای خارجی با در نظر گرفتن اشباع ترانسفورماتور جریان

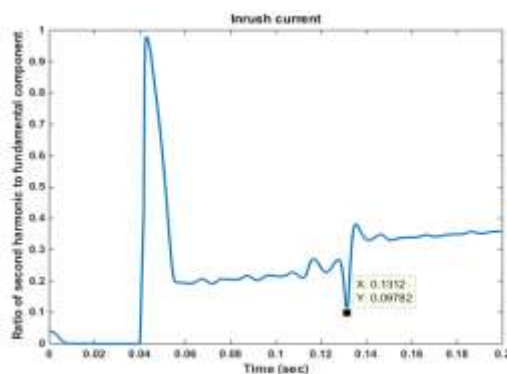
شکل (۱۲)، خطای داخلی به همراه اشباع شدید ترانسفورماتور جریان را نشان می دهد. همان طور که در شکل (۱۳) نشان داده شده است، اشباع ترانسفورماتور جریان، هارمونیک های مرتبه بالا از جمله هارمونیک مرتبه دوم را ایجاد می کند؛ به طوری که میزان هارمونیک دوم به مؤلفه اصلی در برخی لحظات از مقدار آستانه (۰/۱۵) فراتر می رود؛ بنابراین، روش های مبتنی بر هارمونیک دوم ممکن است با خطا مواجه شوند یا با تأخیر زمانی عمل کنند.

لحظه رخداد خطا ۰/۰۴ ثانیه و لحظه صدور فرمان قطع ۰/۰۵۱۶ ثانیه است و حدود ۱۱ میلی ثانیه نیاز است که از لحظه خطا سپری شود تا الگوریتم خطای داخلی را تشخیص دهد. زمان لازم برای آنالیز جریان توسط ابزار پردازش سیگنال حدود ۵ میلی ثانیه است؛ در نتیجه در مجموع، ۱۶ میلی ثانیه، یعنی کمتر از یک سیکل کاری، زمان برای انجام عمل قطع توسط رله دیفرانسیل نیاز است.

خطای خارجی، ۱۰۰ حالت برای خطای داخلی و ۱۰۰ حالت برای جریان هجومی شبیه سازی شدند. در این میان، شدیدترین جریان هجومی و خطاهای خارجی با در نظر گرفتن اشباع هسته ترانسفورماتور جریان انتخاب شده اند تا صحت این روش در سخت ترین شرایط ارزیابی شود. در شکل (۹)، جریان هجومی بزرگی به همراه خروجی طبقه بندی کننده ماشین یادگیری بی نهایت نمایش داده شده است. همان طور که در این شکل مشاهده می شود، ترانسفورماتور در لحظه ۰/۰۴ ثانیه برق دار می شود؛ در حالی که شار هسته در بیشترین مقدار خود قرار دارد و نسبت هارمونیک دوم به هارمونیک اول نیز با توجه به شکل (۱۰) به کمتر از ۰/۱۵ نیز می رسد؛ با این حال، طرح پیشنهادی برای این حالت فرمان قطع صادر نمی کند و رله پایدار باقی می ماند.



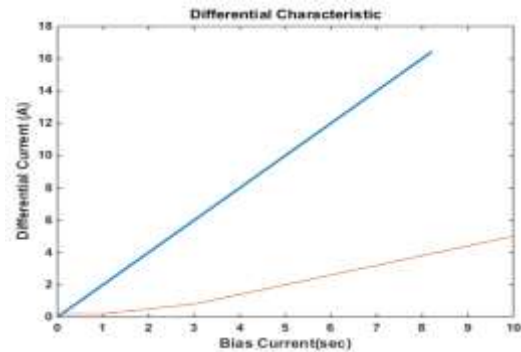
شکل (۹): عملکرد سیستم حفاظتی در زمان برقرار کردن ترانسفورماتور قدرت با اثر اشباع ترانسفورماتور جریان



شکل (۱۰): نسبت هارمونیک دوم به مؤلفه اصلی جریان دیفرانسیل در حین برق دار شدن ترانسفورماتور

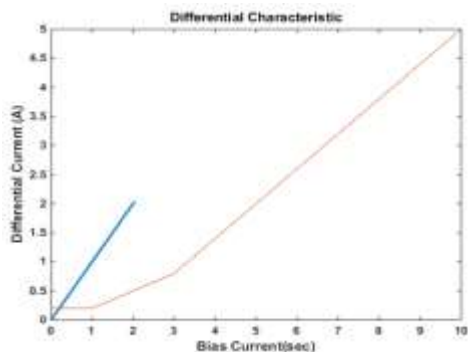
شکل (۱۱)، عملکرد سیستم حفاظتی را حین خطای خارجی همراه با اشباع ترانسفورماتور جریان نشان می دهد.

نسبت هارمونیک دوم به مؤلفه اصلی در شکل (۱۳) نشان داده شده که کمترین مقدار آن $0/2558$ است؛ بنابراین به دلیل اینکه مقدار آن برای تمامی لحظات بیشتر از میزان آستانه تعیین شده، یعنی بیشتر از مقدار $0/15$ است، با وجود وارد شدن رله به ناحیه عملکرد مطابق شکل (۱۴)، رله‌های مجهز به نگهدارنده هارمونیک فرمان قطع صادر نمی‌کنند.

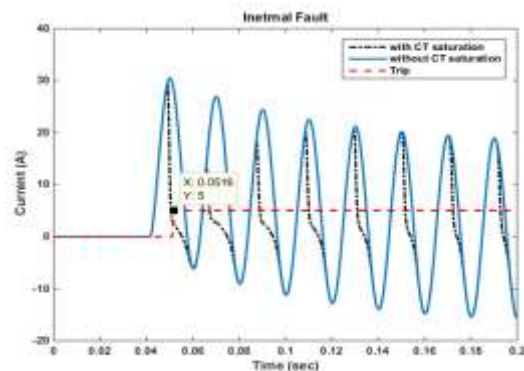


شکل (۱۴): عملکرد رله دیفرانسیل درصدی حین خطای داخلی

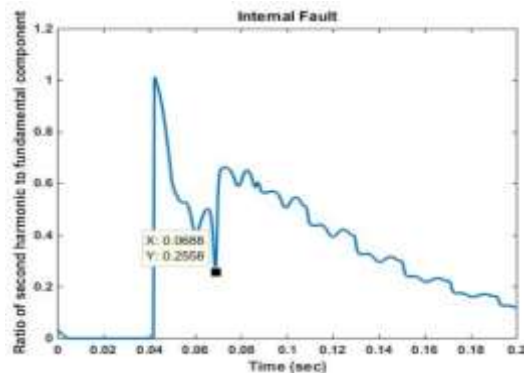
نمونه‌ای از جریان دیفرانسیل در حین برق‌دار شدن ترانسفورماتور نیز در شکل (۹) نشان داده شده است. طبق شکل (۱۵)، عبور جریان هجومی سبب می‌شود رله دیفرانسیل درصدی، وارد ناحیه عملکرد و نسبت هارمونیک دوم به مؤلفه اصلی مطابق شکل (۱۰) در برخی لحظات کمتر از $0/15$ شود؛ بنابراین با وجود نگهدارنده هارمونیک، جلوگیری از عملکرد اشتباه رله اجتناب‌ناپذیر است. در واقع اشباع ترانسفورماتور جریان در حین عبور جریان هجومی باعث می‌شود دامنه هارمونیک دوم کاهش یابد و در نتیجه، نسبت هارمونیک دوم به مؤلفه اصلی کاهش یابد و به کمتر از میزان تعیین شده برسد.



شکل (۱۵): عملکرد رله دیفرانسیل درصدی در حین برق‌دار شدن ترانسفورماتور



شکل (۱۲): عملکرد طرح حفاظتی در خطای داخلی با در نظر گرفتن اشباع ترانسفورماتور جریان



شکل (۱۳): نسبت هارمونیک دوم به مؤلفه اصلی در حین خطای داخلی با اشباع ترانسفورماتور جریان

۵-۲- مقایسه نتایج با عملکرد رله دیفرانسیل درصدی مجهز به نگهدارنده هارمونیک

در شکل (۱۲)، جریان دیفرانسیل نمونه‌ای از خطای داخلی با اشباع شدید ترانسفورماتور جریان نشان داده شد. با توجه به اینکه دامنه جریان‌های خطا بیشتر بزرگ بوده است و در برخی موارد مؤلفه DC در شکل موج جریان خطا ظاهر می‌شود، ترانسفورماتور جریان اشباع می‌شود. رخداد خطای داخلی به همراه اشباع ترانسفورماتورهای جریان موجب کاهش دامنه جریان ثانویه خواهد شد و همچنین تولید هارمونیک‌های مرتبه بالا در شکل موج جریان دیفرانسیل را سبب می‌شود. تولید هارمونیک‌های مرتبه بالا در عملکرد رله‌های مبتنی بر روش نگهدارنده هارمونیک تأثیر منفی دارد و در برخی موارد مانع از عملکرد رله می‌شود.

۵-۳- مقایسه بین طبقه‌بندی‌کننده‌های مختلف

بر اساس قانون بیز، میزان تشابه بردار ورودی و نمونه‌های آموزشی را می‌سنجد و کلاس غالب را تعیین می‌کند. دقت کلی PNN، ۹۷/۳۳٪ به دست آمد که به ترتیب ۴، ۲ و ۲ عملکرد اشتباه در حین برق‌دار کردن، خطای داخلی و خطای خارجی دارد. زمان اجرای PNN، ۶ میلی‌ثانیه است که نشان می‌دهد از ANN، سریع‌تر و از ELM کندتر است. ELM نیز ساختاری ساده دارد که در آن، تعداد گره‌های لایه پنهان ۲۵ و تابع تحریک آن از نوع سیگموئید لگاریتمی است. نتایج به‌طور کلی نشان می‌دهند ELM هم از لحاظ دقت و هم از لحاظ سرعت عملکرد بر PNN و ANN برتری دارد؛ بنابراین از الگوریتم پیشنهادی مبتنی بر ترکیب ELM و VMD در کاربردهای عملی می‌توان استفاده کرد.

به منظور مقایسه عملکرد طبقه‌بندی‌کننده‌ها بر دقت تشخیص، علاوه بر ماشین یادگیری بی‌نهایت از شبکه عصبی مصنوعی (ANN) و شبکه عصبی احتمالی (PNN) به‌منزله هسته تشخیص دهنده الگوریتم ارائه شده استفاده شده است. شبکه عصبی، سه لایه با تعداد نرون‌های ۳، ۱۵ و ۱ دارد و تابع محرک در هر سه لایه از نوع سیگموئید لگاریتمی است. نتایج به‌دست آمده در جدول (۲) نشان می‌دهد شبکه عصبی مصنوعی، بالاترین زمان آموزش یعنی ۱۸ ثانیه را دارد و همچنین دقت آن ۹۵٪ است که از PNN و ELM کمتر است. شبکه عصبی احتمالی، ساختار ساده‌تری دارد و تنها یک پارامتر تنظیم‌شونده (σ) دارد که مقدار آن ۰/۱ تنظیم شده است. شبکه عصبی احتمالی

جدول (۲): عملکرد الگوریتم ارائه شده با در نظر گرفتن طبقه‌بندی‌کننده‌های مختلف

دقت کلی (درصد)	زمان اجرا (میلی ثانیه)	زمان آموزش (ثانیه)	تعداد تشخیص نادرست	تعداد تشخیص نادرست در خطای خارجی به همراه اشباع ترانسفورماتور نادرست در جریان	تعداد تشخیص نادرست در شرایط برق‌دار کردن ترانسفورماتور قدرت	پارامترهای تنظیمی	طبقه‌بندی‌کننده
۹۵	۷	۱۸	۵	۳	۷	سه لایه تعداد نرون‌ها: ۳-۱۵-۱ تابع تحریک: همگی از نوع سیگموئید لگاریتمی	ANN
۹۷/۳۳	۶	۰/۰۵	۲	۲	۴	$\sigma=0/1$ گره‌های لایه پنهان ۲۵	PNN
۱۰۰	۵	۱	۰	۰	۰	تابع تحریک: سیگموئید لگاریتمی	ELM

شده است. نتایج به‌دست آمده نشان می‌دهد الگوریتم فوق قادر به شناسایی تمامی خطاهای داخلی است. اشباع ترانسفورماتور جریان بر دقت تشخیص روش هوشمند ارائه شده نیز تأثیری ندارد. همچنین در بدترین شرایط، روش ارائه شده قادر به شناسایی خطاها در کمتر از ۲۵ میلی‌ثانیه است؛ بنابراین، این الگوریتم را در حفاظت ترانسفورماتورهای قدرت می‌توان به کار گرفت.

۶- نتیجه‌گیری

در این مقاله، روش هوشمند جدیدی مبتنی بر آنالیز سیگنال ارائه شده است. با استفاده از تبدیل VMD یک ویژگی جدید از جریان دیفرانسیل استخراج شده است. این ویژگی به همراه دامنه جریان دیفرانسیل و بایاس برای تشخیص خطای داخلی از جریان هجومی و خطای خارجی به کار گرفته شده است. عملکرد الگوریتم ارائه شده با استفاده از نتایج شبیه‌سازی یک سیستم تست واقعی ارزیابی

مراجع

- Components and Systems, Vol. 36, No. 3, pp. 299-316, 2008.
- [13] S. Sudha and A. E. Jayekumar, "PSOWNN Based Relaying for Power Transformer Protection," International Journal of Electrical and Power Engineering, Vol. 3, No. 3, pp. 140-149, 2009.
- [14] P. L. Mao and R. K. Aggrawal, "A Novel Approach to the Classification of the Transient Phenomena in Power Transformers Using Combined Wavelet Transform and Neural Network," IEEE Transaction on Power Delivery, Vol. 16, No. 4, pp. 654-660, 2001.
- [15] S. Jazebi, B. Vahidi, and M. Jannati, "A Novel Application of Wavelet Based SVM to Transient Phenomena Identification of Power Transformers," Energy Conversion and Management, Vol. 52, No. 2, pp. 1354-1363, 2011.
- [16] A. M. Gaouda and M. M. A. Salama, "DSP Wavelet-Based Tool for Monitoring Transformer Inrush Currents and Internal Faults," IEEE Transaction on Power Delivery, Vol. 25, No. 3, pp. 1258-1267, 2005.
- [17] A. A. Hossam Eldin and M. A. Refaey, "A Novel Algorithm for Discrimination Between Inrush Current and Internal Faults in Power Transformer Differential Protection Based on Discrete Wavelet Transform," Electric Power System Research, Vol. 81, No. 1, pp. 19-24, 2011.
- [18] Z. Moravej and A.A. Abdoos. "An Improved Fault Detection Scheme for Power Transformer Protection," Electric Power Components and Systems, Vol. 40, No. 10, pp. 1183-1207, 2012.
- [19] A. Koochaki, A. A. Abdoos. G. M. Rokni, "Power Transformer Protection Using Fast Discrete S-Transform and Optimized Support Vector Machine Classifier with Bee Algorithm", Computational Intelligence in Electrical Engineering, Vol. 8, No. 2, pp. 41-54, 2017.
- [20] K. Dragomiretskiy, D. Zosso "Variational Mode Decomposition," IEEE Transactions on Signal Processing, Vol. 62, No. 3, pp. 531-544, 2014.
- [21] Introduction to PSCAD/EMTDC, Manitoba HVDC Research Centre, Inc. Winnipeg, MB, Canada, 2000
- [22] U. D. Annakkage, P. G. McLaren, E. Dirks, R. P. Jayasinghe, and A. D. Parker, "A Current Transformer Model Based on the Jiles-Atherton Theory of Ferromagnetic Hysteresis," IEEE Transactions on Power Delivery, Vol. 15, No. 1, pp. 57-61, 2000.
- [23] G. B. Huang, Q. Y. Zhu, C. K. Siew, "Extreme Learning Machine: Theory and Applications," Neurocomputing, Vol. 70, pp. 489-501, 2006.
- [1] Y. G. Pathankar and S. R. Bhide, "Fundamental of power system protection," Prentice-Hall of India Pvt. Ltd, ISBN-13: 978-8120321946, 2004.
- [2] C. R. Mason, "The Art and Science of Protective Relaying," John Wiley & Sons Inc, ISBN-13: 978-0471575528, 1956.
- [3] Ziegler, G., 'Numerical Differential Protection: Principles and Applications'. 2005 Germany: Publicis Corporate Publishing. 214-229.
- [4] "IEEE Guide for Protecting Power Transformers," IEEE Std C37.91™-2008, IEEE 3 Park Avenue, New York, NY 10016-5997, USA 30, 2008.
- [5] L. G. Prez, A. J. Flechsig, J. L. Meador, and Z. Obradovic, "Training an Artificial Neural Network to Discriminate Between Magnetizing Inrush and Internal Faults," IEEE Transaction on Power Delivery, Vol. 9, No. 1, pp. 434-441, 1994.
- [6] M. Geethanjali, S. M. R. Slochanal, and R. Bhavani, "PSO Trained ANN-Based Differential Protection Scheme for Power Transformers," Neurocomputing, Vol. 71, No. 4-6, pp. 904-918, 2008.
- [7] D. V. Coury and E. C. Segatto, "An Alternative Approach Using Artificial Neural Networks for Power Transformer Protection," European Transaction on Electrical Power, Vol. 16, No. 1, pp. 63-77, 2006.
- [8] H. Balaga, N. Gupta, D. N. Vishwakarma, "A Trained Parallel Hidden Layered ANN Based Differential Protection of Three Phase Power Transformer," International Journal of Electrical Power & Energy Systems, Vol. 67, pp. 286-297, 2015.
- [9] M. Tripathy, R. P. Meheshwari, and H. K. Verma, "Power Transformer Differential Protection Based on Optimal Probabilistic Neural Network," IEEE Transactions on Power Delivery, Vol. 25, No. 1, pp. 102-112, 2010.
- [10] M. Tripathy, R. P. Meheshwari, and H. K. Verma, "Radial Basis Probabilistic Neural Network for Differential Protection of Power Transformer," IET Generation, Transmission & Distribution, Vol. 2, No. 1, pp. 218-222, 2008.
- [11] V. Malathi and N. S. Marimuthu, "Support Vector Machine for Discrimination Between Fault and Magnetizing Inrush Current in Power Transformer," Journal of computer science, Vol. 3, No. 11, pp. 894-897, 2007.
- [12] M. Tripathy, R. P. Meheshwari, and H. K. Verma, "Neuro-Fuzzy Technique for Power Transformer Protection," Electric Power

-
- ¹ Variational Mode Decomposition (VMD)
 - ² Extreme Learning Machine (ELM)
 - ³ Artificial Neural Network (ANN)
 - ⁴ Probabilistic Neural Network (PNN)
 - ⁵ Empirical Mode Decomposition (EMD)
 - ⁶ Alternate Direction Method of Multipliers (ADMM)
 - ⁷ Interior Point Method
 - ⁸ Hermitian Symmetry
 - ⁹ Single Layer Feed-forward Network (SLFN)
 - ¹⁰ Impact Factor
 - ¹¹ Moore-Penrose

