

مکان‌یابی تخلیه جزئی با استفاده از مدل مشروح ترانسفورماتورها به کمک شبکه عصبی FAM و بیزین

حامد نفیسی¹، دانشجوی دکتری، مهرداد عابدی¹، استاد، گئورگ قره‌پتیان¹، استاد

۱- دانشکده مهندسی برق- دانشگاه صنعتی امیرکبیر- تهران- ایران

grptian@aut.ac.ir abedi@aut.ac.ir nafisi@aut.ac.ir

چکیده: تخلیه جزئی مهم‌ترین عامل تخریب عایق در ترانسفورماتور قدرت که یکی از مهم‌ترین اجزای سیستم‌های قدرت می‌باشد، شناخته می‌شود. بنابراین روش‌های با سرعت و دقت بالا در مکان‌یابی منشأ تخلیه جزئی دارای اهمیت خاصی برای نگهداری و تعمیر ترانسفورماتورها می‌باشد. در این مقاله دو روش نوین مبتنی بر شبکه‌های عصبی برای تشخیص مکان تخلیه جزئی در سیم‌پیچ ترانسفورماتورها ارائه شده است. جهت شبیه‌سازی ترانسفورماتور از مدل مشروح و شبیه‌سازی پدیده تخلیه جزئی در عایق بین حلقه‌ها از مدل سه‌خازنی بهره گرفته شده و این پدیده در مکان‌های مختلف سیم‌پیچ ترانسفورماتور به کمک نرم افزار EMPT شبیه‌سازی شده است. سپس آزمون ضربه به ترمینال ترانسفورماتور اعمال گردیده و سپس جریان ایجاد شده در نقطه نول اندازه‌گیری شده و جهت آموزش و آزمون شبکه‌های عصبی از آن‌ها استفاده شده است. جهت نزدیک‌تر کردن شرایط شبیه‌سازی به شرایط واقعی به دلیل وجود نویز در شرایط عملی، نویزهای مختلفی بر روی شکل موج‌های شبیه‌سازی شده اضافه شده است. سپس عملکرد شبکه‌های عصبی مورد استفاده در این مقاله شامل Fuzzy ATRmap و Bayesian جهت تشخیص صحیح مکان تخلیه جزئی با وجود نویز با یکدیگر مقایسه شده است.

واژه‌های کلیدی: تخلیه جزئی، ترانسفورماتور، شبکه بیزین، شبکه عصبی FAM، مدل مشروح

تاریخ ارسال مقاله : ۱۳۹۱/۰۴/۰۳

تاریخ پذیرش مقاله : ۱۳۹۱/۰۷/۱۰

نام نویسنده‌ی مسئول : حامد نفیسی

نشانی نویسنده‌ی مسئول : دانشکده مهندسی برق- دانشگاه صنعتی امیرکبیر ۴۲۴ خیابان حافظ، تهران، ایران. صندوق پستی ۱۵۸۷۵-۴۴۱۳.
+۹۸ (۲۱) ۶۴۵۴۳۳۷۰

۱- مقدمه

در سالیان اخیر مطالعات زیادی در زمینه رفتار سیستم‌های قدرت در فرکانس‌های بالا انجام شده است. از مهم‌ترین تجهیزات موجود در شبکه‌های قدرت، ترانسفورماتورهای فشار قوی می‌باشند که بخش مهمی از وظیفه انتقال انرژی از نیروگاه به مصرف‌کننده را بر عهده دارند. ترانسفورماتورهای قدرت یکی از مهم‌ترین تجهیزات در سیستم‌های انتقال و توزیع انرژی الکتریکی هستند که درصد بالایی از سرمایه‌گذاری در سیستم‌های الکتریکی را به خود اختصاص داده‌اند. افزایش عمر مفید ترانسفورماتورها تا حد ممکن، از لحاظ اقتصادی بسیار با ارزش است زیرا خروج آن‌ها از مدار باعث مضرات اقتصادی و کاهش ایمنی سیستم قدرت می‌شود. بنابراین عملکرد ترانسفورماتورها با قابلیت اطمینان و بازده بالا برای سالیان دراز از اصلی‌ترین دغدغه‌ها برای شرکت‌های تولید، انتقالی و توزیع توان الکتریکی است [۱].

مطالعات و بررسی‌ها بر روی علل خروج از مدار ترانسفورماتورها نشان می‌دهد که علت اصلی خطاهایی که باعث خروج ترانسفورماتورهای قدرت می‌شود، ناشی از خطاهای داخلی هستند که عمدتاً حاصل خرابی یا کاهش کیفیت سیستم عایقی ترانسفورماتور می‌باشد [۲]. بسیاری از خطاهای منجر به خروج ترانسفورماتورها مربوط به سیستم عایق‌بندی آن‌ها می‌باشد و تخلیه جزئی که به صورت تدریجی باعث نابودی عایق می‌شود، مهم‌ترین منبع خطا در عایق ترانسفورماتورها می‌باشد [۳ و ۴].

لذا تشخیص، عیب‌یابی و مکان‌یابی خطاهای عایقی بخصوص در مراحل اولیه خرابی آن‌ها که به عنوان خطاهای جزئی در ترانسفورماتورهای قدرت نامیده می‌شود، در افزایش عمر ترانسفورماتورها بسیار با اهمیت است. خطاهای جزئی به پیری و کاهش کیفیت عایق نسبت داده می‌شود و شامل خطاهایی نظیر تخلیه جزئی، تخلیه الکتریکی و اتصال کوتاه بین دیسک‌های سیم پیچ و نظایر آن می‌باشد. آشکارسازی تخلیه جزئی عمدتاً به سه دسته نوری، صوتی و الکتریکی تقسیم می‌شوند که هر یک خصوصیات و کاربرد خاص خود را دارند. مکان‌یابی تخلیه جزئی در روش نوری محدود به عایق‌های شفاف و بررسی پدیده کرونا می‌شود. در روش صوتی نیز قابلیت مکان‌یابی تخلیه جزئی وجود دارد. مزیت روش‌های صوتی، الگوریتم ساده مکان‌یابی آنهاست اما حساسیت آنها بسیار کم است. از طرفی ساختمان پیچیده ترانسفورماتور قدرت باعث می‌شود که پیدا کردن محل PD با توجه به سرعت انتشار امواج صوتی ناشی از PD دشوار گردد.

در نتیجه در سالیان اخیر تمرکز تحقیقات بیشتر بر روی روش‌های الکتریکی است. روش الکتریکی بر مبنای اخذ پالس‌های ایجاد شده در حفره‌های موجود در عایق ترانسفورماتور می‌باشد. ارزیابی تخلیه جزئی از روش الکتریکی با بکارگیری ترانسدیوسرهای جریان که در اطراف ترمینال‌های اندازه‌گیری متصل هستند، ممکن می‌باشد. در روش الکتریکی امکان آشکارسازی پالس‌های تخلیه جزئی با شدت و دامنه


کمتر نیز میسر می‌باشد. همچنین می‌توان در محدوده فرکانسی بسیار متفاوتی این سیگنال‌ها را آشکار کرد که محدوده آن تا فرکانس‌های UHF گسترده است [۵]. برای استفاده از این روش، راه‌های زیادی استفاده شده و یا در حال مطالعه می‌باشد. روش tip-up [۶ و ۷] و روش تحلیل تلفات دی‌الکتریک [۸] از جمله این روش‌ها جهت تشخیص PD می‌باشند.

مکان‌یابی پالس‌های تخلیه جزئی که یک مرحله بعد از آشکارسازی و اندازه‌گیری این پالس‌ها، در مرحله آنالیز مطرح می‌شود، اهمیتی ویژه در حفاظت، عیب‌یابی، تعمیر و نگهداری دارد. منظور از مکان‌یابی، تعیین محل تقریبی منبع پالس‌های تخلیه جزئی است که توسط سنسورها، اندازه‌گیری می‌شوند. تعیین محل تقریبی، خصوصاً در تعمیر و نگهداری بسیار کارساز می‌باشد. مکان‌یابی تخلیه جزئی به روش‌های مختلفی بر اساس توابع تبدیل جزء به جزء سیم‌پیچ [۹]، صفر و قطب‌های طیف فرکانسی سیگنال‌ها [۱۰]، تبدیل موجک [۱۱] و شبکه‌های عصبی [۱ و ۲] صورت گرفته است. این مقاله روشی نوین مبتنی بر شبکه عصبی Fuzzy ARTmap و Bayesian و آزمون ضربه برای تشخیص مکان تخلیه جزئی ارائه می‌کند. نوآوری این مقاله در استفاده از شبکه‌های FAM و بی‌زین در مکان‌یابی تخلیه جزئی می‌باشد که در تشخیص دسته‌بندی الگو بسیار کارا می‌باشند و همچنین استفاده همزمان از مدل مشروح ترانسفورماتور و مدل سه خازنی جهت شبیه‌سازی پدیده تخلیه جزئی می‌باشد. به علاوه با اضافه کردن نویزهای فرکانس بالا به شکل موج‌های بدست آمده از شبیه‌سازی‌های انجام گرفته، شرایط شبیه‌سازی به شرایط واقعی نزدیک‌تر شده است تا کارایی شبکه‌های عصبی استفاده شده نشان داده شود.

در بخش بعد پدیده تخلیه جزئی و روش مدل‌سازی آن ارائه شده و سپس مدل مشروح سیم‌پیچ ترانسفورماتور با در نظرگیری تخلیه جزئی بکمک نرم‌افزار EMTP پرداخته شده است. بخش چهارم و پنجم مقاله شبکه عصبی Fuzzy ARTmap و Bayesian را ارائه می‌کند و در بخش آخر مطالعه‌ای موردی انجام گرفته است.

۲- تخلیه جزئی و مدل‌سازی آن

در این قسمت هدف مدل‌سازی و شبیه‌سازی مکانیزم دقیق پدیده تخلیه جزئی می‌باشد. بنابراین از مدل سه خازنی ارائه شده در شکل (۱) برای تحلیل پالس‌های جریان PD استفاده شده است [۱۲].



شکل (۱): مدل سه خازنی تخلیه جزئی

در این مدل:

- C_g : خازن ناحیه‌ای است که تخلیه در آن اتفاق می‌افتد.
- C_b : خازن ناحیه‌ای ایست که با C_g سری است.
- C_a : خازن عایق تحت آزمایش است که بین دو الکتروود قرار می‌گیرد.


زمانی که تخلیه جزئی در C_g اتفاق می‌افتد I_d در ترمینال‌های خارجی و از طریق خازن‌های C_a و C_b جریان می‌یابد. با استفاده از نرم افزار EMTP (و به کمک مدول‌های TACS (MODELS) برنامه‌ای نوشته شده که مکانیزم تخلیه جزئی را مدل می‌کند.

۳- مدل‌سازی سیم‌پیچ ترانسفورماتور با

در نظرگیری تخلیه جزئی بکمک نرم افزار EMTP

مدار معادل ساده ترانسفورماتور، مدل ترانسفورماتور جهت محاسبات اتصال کوتاه و پخش بار و یا مدل آن جهت تحلیل هارمونیک‌ها نمی‌تواند جهت انجام بررسی‌های حالات گذرا بکار رود و باید مدل‌های مناسبی در این راستا مطرح نمود.

کوچکترین جزء یک سیم‌پیچ فشار قوی، حلقه‌های آن است. از روی هم قرار گرفتن حلقه‌ها در جهت افقی، دیسک‌ها بوجود می‌آیند. از اتصال دیسک‌ها در جهت عمودی سیم‌پیچ فشار قوی حاصل می‌آید. هر دو دیسک مجاور که بر روی هم قرار گرفته‌اند، تشکیل یک زوج دیسک را می‌دهند. در مدل‌سازی مشروح، اجزاء مدل در رابطه مستقیم با این واقعیت فیزیکی می‌باشند [۴]. یعنی سیم‌پیچ فشار قوی در مدل به اجزائی قسمت می‌شود که هر جزء آن دارای مفهوم فیزیکی است. این اجزاء را واحد سیم‌پیچ می‌نامیم. شکل (۲) چنین مدلی را برای واحد سیم‌پیچ نمایش می‌دهد.



شکل ۲: نمایش مدل مشروح یک ترانسفورماتور

که با توجه به شکل (۲) داریم:

L_i : اندوکتانس معادل واحد i ام سیم‌پیچ است که شار پراکندگی حلقه‌های واحد i ام را نمایش می‌دهد.

L_{ij} : القای متقابل بین واحد i و j است.


K_i : ظرفیت طولی معادل برای واحد i ام می‌باشد. این ظرفیت تمامی ظرفیت‌های خازنی موجود بین حلقه‌های واحد i ام را بصورت یک خازن بازنمایی می‌کند.

C_e : ظرفیت خازنی بین واحد i ام و پتانسیل زمین است.

R_i : تلفات الکتریکی را در عایق واحد i ام مدل می‌کند.

R_{Si} : مقاومت سیم‌پیچ واحد i ام می‌باشد.

با در نظر گرفتن مدل مشروح برای واحد سیم‌پیچ فشار قوی و سیم‌پیچ فشار ضعیف ترانسفورماتور و در نظرگیری ظرفیت و القای متقابل بین آن‌ها، مدل مشروح یک ترانسفورماتور دو سیم‌پیچ به صورت شکل (۳) خواهد بود.



شکل ۳: نمایش مدل مشروح یک ترانسفورماتور

در این مقاله جهت تحلیل تخلیه جزئی در سیم‌پیچ ترانسفورماتور از مدل مشروح استفاده شده است. به طوری که با مدل‌سازی پدیده تخلیه جزئی مطابق مطالب ارائه شده در بخش قبل و جایگزینی آن مدل با خازن‌های بین حلقه‌ها، تخلیه جزئی در مکان‌های مختلف سیم‌پیچ ترانسفورماتور به کمک نرم افزار EMTP شبیه‌سازی شده است.

۴- شبکه عصبی Fuzzy ARTmap

شبکه عصبی مورد استفاده در این مقاله از خانواده تئوری تشدید تطبیقی (ART: Adaptive Resonance Theory) می‌باشد. اعضای این خانواده بصورت کلی شامل ART1، ART2 [۱۳]، ART3 [۱۴]، ARTmap [۱۵]، Fuzzy ART [۱۶] و Fuzzy ARTmap [۱۷] است.

شبکه‌های ART1 و ARTmap الگوهای ورودی باینری را دسته‌بندی می‌کنند و شبکه‌های ART2، ART3، Fuzzy ART و Fuzzy ARTmap علاوه بر الگوهای باینری قادر به دسته‌بندی الگوهای

صورت $x^b = \{x_1^b, \dots, x_{2Mb}^b\}$ و برای F_2^b به صورت $y^b = \{y_1^b, \dots, y_{Nb}^b\}$ و بردار $w_k^b = \{w_{k1}^b, \dots, w_{k2Mb}^b\}$ را که دلالت بر k^{th} بردار وزن دارد، در نظر می‌گیریم. برای میدان نگاشت، بردار خروجی F^{ab} به صورت $x^{ab} = \{x_1^{ab}, \dots, x_{Na}^{ab}\}$ و بردار وزن گذاری از j^{th} گره F_2^a به F^{ab} به فرم $w_j^{ab} = \{w_{j1}^{ab}, \dots, w_{jNb}^{ab}\}$ می‌باشد.

۴-۲- میدان نگاشت F^{ab}

میدان نگاشت F^{ab} زمانی که هر دسته از شبکه ART_a با شبکه ART_b فعال باشد، فعال خواهد بود. اگر گره j^{th} از لایه F_2^a انتخاب شود، سپس وزن آن w_j^{ab} در لایه F^{ab} فعال می‌شود. اگر گره k^{th} در F_2^b فعال شود، سپس گره k^{th} در لایه F^{ab} به صورت یک به یک بین مسیر F_2^b و F^{ab} برقرار می‌شود. اگر هر دو شبکه ART_a و ART_b فعال باشند، سپس F^{ab} فقط اگر ART_a همان دسته را در ART_b پیشگویی نماید، از طریق وزن‌های w_j^{ab} فعال می‌شود.

بردار خروجی x^{ab} در لایه F^{ab} از روال زیر پیروی می‌کند:

$$\begin{cases}
 y^b \wedge w_j^{ab} & \text{If the } j^{th} F_2^a \text{ is active and} \\
 & F_2^b \text{ is active.} \\
 w_j^{ab} & \text{If the } j^{th} F_2^a \text{ is active and} \\
 & F_2^b \text{ is inactive.} \\
 y^b & \text{If the } j^{th} F_2^a \text{ is inactive and} \\
 & F_2^b \text{ is active.} \\
 0 & \text{If the } j^{th} F_2^a \text{ is inactive and} \\
 & F_2^b \text{ is inactive.}
 \end{cases} \quad (1)$$

از رابطه فوق نتیجه می‌شود که، در صورتیکه پیشگویی مشخص شده w_j^{ab} توسط y^b تأیید نشود، $x^{ab} = 0$ خواهد بود. در چنین زمانی در شبکه ART_a الگوی بهتری را جستجو می‌نماید.

۴-۳- ردیابی تطبیقی

در زمان شروع ارائه ورودی، پارامتر مراقبت ρ_a معادل یک پارامتر مبنایی ρ_a می‌باشد. پارامتر مراقبت در لایه نگاشت معادل ρ_{ab} است.

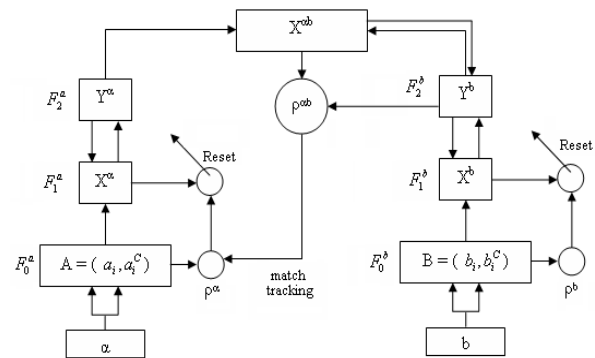
$$\text{If } |x^{ab}| < \rho_{ab} \cdot |y^b| \quad (2)$$

سپس ρ_a تا زمانی که کمی بیشتر از $|A \wedge w_j^a| |A|^{-1}$ شود، افزایش می‌یابد، در اینجا A ورودی به لایه F_1^a ، که به صورت کد شده متمم می‌باشد، و

$$|x^a| = |A \wedge w_j^a| < \rho_a |A| \quad (3)$$

آنالوگ نیز می‌باشند. شبکه‌های ART و کوهونن و مانند آن‌ها تنها جهت کلاسه‌بندی یا دسته‌بندی یک‌سری الگو که ممکن است نویزی نیز باشند کاربرد فراوان دارند. شبکه Fuzzy ARTmap دارای الگوریتم آموزش باناظر است که منطق فازی و تئوری تشدید و فقی را با یکدیگر تلفیق می‌کند. از این شبکه عصبی جهت تشخیص دسته‌بندی الگو و نگاشت چند بعدی به‌ازای بردارهای ورودی استفاده می‌شود. این شبکه از قانون آموزشی minmax بهره می‌برد. هدف از این قانون تلفیق حداقل خطای پیشگویی همراه با حداکثر فشردگی می‌باشد. بنابراین می‌توان همه الگوها را که از دسته‌های عمومی به وجود آمده‌اند را یک شکل یا یک دسته نامید. جهت دستیابی به این موضوع از فرآیند ردیابی تطبیقی استفاده شده است که در آن با افزایش پارامتر مراقبت ART (درجه فازی تابع عضویت ورودی‌ها جهت نسبت به الگوهای درون یک دسته) حداقل مقدار مورد نیاز جهت خطای پیشگویی صحیح تأمین می‌گردد.

شبکه مذکور دو شبکه Fuzzy ART_a و Fuzzy ART_b را با یکدیگر ترکیب می‌کند. ساختار این شبکه‌ها به‌طور نوعی در شکل (۴) نشان داده شده است و اساساً این ساختارها یکسان می‌باشند [۱۷].



شکل ۴: ساختار شبکه Fuzzy ARTmap

جهت ارتباط دو شبکه بلوک سومی موجود است که MAP FILED نامیده می‌شود و اساس کار FAM در همین بلوک است. وظیفه این بلوک نگاشت اطلاعات طبقه‌بندی شده FA_a و FA_b بر روی یکدیگر است. لایه نگاشت بین این شبکه‌ها F^{ab} نامیده می‌شود. مشخصات مربوط به بخش‌های مختلف این شبکه شامل موارد زیر است.

۴-۱- شبکه‌های ART_a و ART_b

ورودی به ART_a و ART_b به صورت متمم می‌باشند: برای ART_a ، $I = A = (a, a^c)$ ، و برای ART_b ، $I = B = (b, b^c)$ ، متغیرها به ترتیب برای شبکه‌های ART_a و ART_b معادل "a" و "b" می‌باشند. برای ART_a بردار خروجی F_1^a را به صورت $x^a = \{x_1^a, \dots, x_{2Ma}^a\}$ و برای F_2^a به صورت $y^a = \{y_1^a, \dots, y_{Na}^a\}$ و بردار $w_j^a = \{w_{j1}^a, \dots, w_{j2Ma}^a\}$ را که دلالت بر j^{th} بردار وزن دارد، در نظر می‌گیریم. برای ART_b بردار خروجی F_1^b را به

۴-۵- آزمون شبکه عصبی

در مرحله آزمون شبکه‌های عصبی FAM به طور معمول، ابتدا پارامتر نگهبان شبکه ART_a برای عمل پیش‌گویی به صورت ثابت مشخص می‌گردد. سپس الگوهای ورودی مورد نظر به شبکه ارائه شده و پس از تعیین تابع انتخاب در زیرشبکه ART_a، معیار نگهبان امتحان می‌گردد. در صورتی که معیار نگهبان ارضا نشود، تعیین تابع انتخاب و معیار نگهبان تا زمانی که معیار نگهبان ارضا شده و یا انتخاب کلیه دسته‌ها انجام شود، این روند ادامه خواهد یافت. در صورتی که معیار نگهبان ارضا شد بردار خروجی y^a در آخرین لایه زیرشبکه ART_a تعیین می‌گردد و سپس ضرایب وزن لایه نگاشت را بدست خواهیم آورد:

$$W_j^{ab} = y^a \times W^{ab} \quad (7)$$

پس از تعیین W_j^{ab} ، نوبت به پیش‌گویی بردار خروجی بصورت زیر می‌رسد:

$$W_k^b = W_j^{ab} \times W_k^b \quad (8)$$

که بردار W_k^b همان بردار پیش‌گویی است.

در این نحوه آزمون، شبکه عصبی هیچ‌گونه نظارتی بر روی خروجی پیش‌گویی شده انجام نمی‌دهد. این موضوع بدین معنی است که به‌ازای ارائه هر الگوی ورودی یک الگو در خروجی پیشنهاد خواهد شد و این پیشنهاد صرفاً پس از عبور از یک شرط (حداقل خطا با الگوهای خروجی موجود) صورت خواهد گرفت، که این موضوع باعث سرعت پاسخگویی خواهد شد ولی از دقت آن خواهد کاست، زیرا ممکن است خطاها بگونه‌ای دسته‌بندی شده باشند که دسته‌های آن‌ها بسیار به یکدیگر نزدیک بوده و در چنین مواردی صرف نزدیکی الگوی تخمین زده شده با هر یک از الگوهای خروجی، ممکن است باعث کاهش دقت در پیش‌گویی گردد، لذا امکان وجود خطا تا حدودی وجود خواهد داشت. الگوریتم آزمون به‌صورت شکل (۶) می‌باشد.

۵- شبکه Bayesian

یادگیری بیزین بر مبنای این مفهوم اساسی بنا نهاده شده که تمامی اشکال عدم قطعیت بهتر است که در قالب احتمالات نشان داده شوند [۱۸]. در اوایل دهه ۹۰ و ویگند [۱۹] با به کار بردن یادگیری بیزین برای شبکه عصبی نشان دادند که چه مزایایی به همراه دارد. مک کی این کار را با تقریب گوسی انجام داده است. نیل، در [۲۰] با معرفی روش هایبرید مونت کارلو در یادگیری بیزین زمینه ساز تحولی بزرگ در این راه بوده است. پس از آن مولر [۲۱]، و هولمز و مالیک [۲۲]، مسئله انتخاب تعداد نورون‌های میانی را مورد توجه قرار داده‌اند. همچنین کارهایی برای انتخاب مدل به کمک محک‌های اطلاعاتی صورت گرفته است [۲۳]. در این بخش، مفاهیم اولیه در یادگیری بیزین برای وزن‌های شبکه مطرح می‌شود. برای مطالعه بیشتر در این زمینه می‌توان به مراجع [۲۴] رجوع کرد.

در اینجا، زاندیس گره فعال F_2^a می‌باشد. زمانی که رابطه فوق برقرار شود، یا F_2^a گره در لایه F_2^a با شرایط زیر فعال می‌شود:

$$|x^a| = |A \wedge w_j^a| \geq \rho_a |A| \quad (4)$$

و

$$|x^a| = |y^b \wedge w_j^{ab}| \geq \rho_a |y^b| \quad (5)$$

یا، اگر چنین گرهی وجود نداشته، الگوی ورودی در لایه F_2^a مطابق با هیچ الگویی نبوده و به‌عنوان الگوی جدید دسته‌بندی می‌شود.

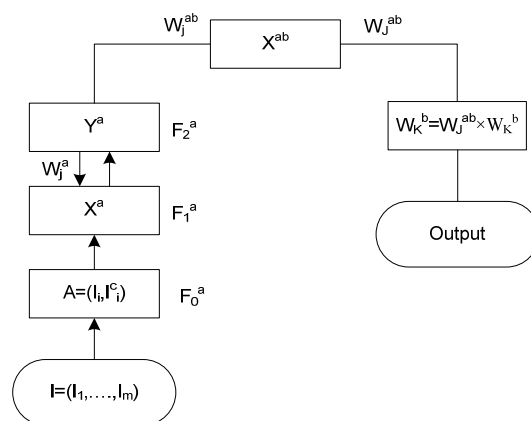
۴-۴- آموزش لایه نگاشت

قوانین آموزش چگونگی تغییرات وزن‌های لایه نگاشت w_{jk}^{ab} را در طول زمان آموزش تعیین می‌کند، وزن‌های w_{jk}^{ab} از طریق مسیر $F_2^a \rightarrow F^{ab}$ با توجه به رابطه زیر، تنظیم می‌شود:

$$w_{ab}(J_a^{new}, k) = \beta (x_b \wedge w_{ab}(J_a^{old}, k)) + (1 - \beta) (w_{ab}(J_a^{old}, k)) \quad (6)$$

در طول زمان تشدید با فعال شدن دسته J در شبکه ART_a، بردار لایه نگاشت x^{ab} معادل w_j^{ab} خواهد شد. در زمان آموزش سریع یک‌بار گره J دسته k از شبکه ART_b را پیش‌بینی می‌کند، که ارتباط بین این دو گره به‌صورت دائم معادل $w_{jk}^{ab} = 1$ خواهد شد.

در زمان آزمون در شبکه‌های Fuzzy ARTmap ابتدا پس از این‌که الگوی باینری ورودی به شبکه ارائه گردید، الگوهای آموزش داده شده با الگوی ورودی مقایسه خواهند شد، در صورتی که الگوی ورودی با الگوهای آموزش دیده شده مطابقت نداشته باشد، الگوهای دیگر مورد بررسی قرار می‌گیرند، در صورتی که الگوی ورودی همراه با نویز باشد، این الگو ممکن است با دو الگوی آموزش دیده شده شبکه تشابه یکسانی داشته باشد، در چنین حالتی نرون الگویی در بخش آموزش برنده خواهد شد که دارای اندیس کمتری باشد، این اندیس کمتر، مبین این است که الگوی مذکور ابتدا به شبکه آموزش داده شده است و الگوی با اندیس بیشتر پس از آن آموزش داده شده است. بلوک دیگرام نحوه آزمون معمول در شبکه FAM در شکل (۵) آورده شده است.



شکل ۵: بلوک دیگرام آزمون شبکه FAM

همان‌طور که گفته شد، این کار با در نظر گرفتن مقادیر کوچک برای وزن‌های شبکه امکان‌پذیر است. در واقع تابع توزیع گوسی مانند فانکشنال تنظیم کاهش وزن عمل می‌کند. α نیز معکوس واریانس توزیع پیشین وزن‌های شبکه است و نقشی مشابه ضریب تنظیم را بر عهده دارد. از آن‌جا که این ضریب، کنترل توزیع پارامترهای دیگر مثل وزن‌ها و بایاس‌ها را بر عهده دارد، به آن ابر پارامتر می‌گویند. در قدم بعدی لازم است که مدلی برای نویز جمع‌شونده در خروجی در نظر بگیریم. در حالت کلی می‌توانیم، تابع احتمال وقوع $P(D|w)$ را به فرم نمایشی زیر در نظر بگیریم:

$$p(D|w) = \frac{1}{Z_D(\beta)} \exp(-\beta E_D) \quad (11)$$

در رابطه اخیر تابع خطا و β ابر پارامتر دیگری است که مدل نویز را کنترل می‌کند. $Z_D(\beta)$ نیز عامل نرمال‌ساز است و به طریق زیر محاسبه می‌شود:

$$Z_D(\beta) = \int \exp(-\beta E_D) dD \quad (12)$$

اگر نویز جمع‌شونده در خروجی را گوسی در نظر بگیریم، برای یک زوج داده یادگیری مثل (y, x) می‌توان نوشت:

$$p(y|x, w) \propto \exp\left(-\frac{\beta}{2}(y-f(x, w))^2\right) \quad (13)$$

که f نشان‌دهنده نگاشتی از فضای ورودی به خروجی شبکه عصبی است. β معکوس واریانس نویز است و از همین طریق مدل نویز را کنترل می‌کند. اگر برای همه داده‌ها نویز را گوسی و آن‌ها را مستقل از هم فرض کنیم، می‌توان نوشت:

$$p(D|w) = \prod_{i=1}^n p(y_i|x_i, w) = \frac{1}{Z_D(\beta)} \exp\left(-\frac{\beta}{2} \sum_{i=1}^n (y_i - f(x_i, w))^2\right) \quad (14)$$

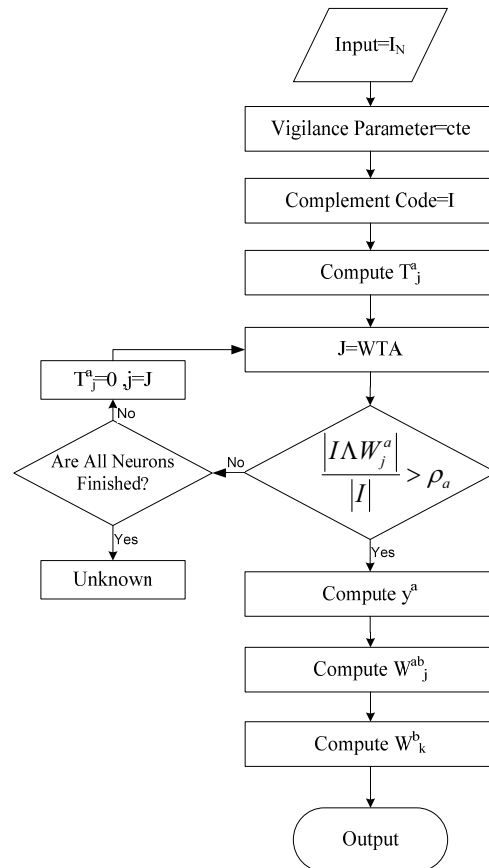
همان‌طور که مشاهده می‌شود، با فرض نویز گوسی در خروجی شبکه، تابع خطای E_D به صورت مجموع مربعات خطا روی داده‌های یادگیری خواهد بود. ثابت نرمال‌ساز نیز برابر خواهد بود با:

$$Z_D(\beta) = \left(\frac{2\pi}{\beta}\right)^{N/2} \quad (15)$$

اکنون می‌توان نشان داد که روش مرسوم یادگیری در شبکه‌های عصبی که با استفاده از الگوریتم‌های مبتنی بر گرادینت، تابع هزینه را حداقل می‌کند و به نوعی بیان‌گر تخمین بیشترین احتمال وقوع (w_{ML}) می‌باشد.

۵-۲- تابع توزیع پسین

برای یافتن تابع توزیع پسین، وزن‌های شبکه، کافی است که روابط (۹) و (۱۴) را در قانون بیز جایگذاری می‌کنیم. در این صورت داریم:



شکل (۶): الگوریتم آزمون معمول شبکه FAM

۵-۱- تابع توزیع پیشین

تابع توزیع پیشین، بازتابی از ذهنیت قبلی ما راجع به مقادیری است که آن کمیت اختیار می‌کند. ولی در مورد وزن‌های شبکه‌های عصبی، ذهنیتی راجع به این‌که چه مقداری باید داشته باشند نداریم. نیل در [۲۵] نشان داد که برای شبکه عصبی با یک لایه مخفی که توابع تحریک تانژانت هیپربولیک دارند، استفاده از توزیع گوسی برای تابع توزیع پیشین وزن‌های لایه مخفی به خروجی، به یک پروسه گوسی برای تابع خروجی منجر خواهد شد. ما نیز از ساده‌ترین و یکی از کارآمدترین توابع، یعنی تابع توزیع گوسی با میانگین صفر برای وزن‌های شبکه استفاده کرده و آن را به این شکل نمایش می‌دهیم:

$$p(w) = \frac{1}{Z_w(\alpha)} \exp\left(-\frac{\alpha}{2} \|w\|^2\right) \quad (9)$$

که $Z_w(\alpha)$ ثابت نرمال‌سازی است و به گونه‌ای محاسبه می‌شود که $p(w)$ تابع توزیع باشد و به صورت زیر محاسبه می‌شود:

$$Z_w(\alpha) = \left(\frac{2\pi}{\alpha}\right)^{N/2} \quad (10)$$

در بحث توازن میان بایاس، واریانس توابع هموار قدرت تعمیم پذیر بیشتری نسبت به انواع پیچیده‌تر دارند. یکی از دلایل استفاده از تکنیک تنظیم نیز رسیدن به نگاشتی هموار برای شبکه عصبی است.

با توجه به رابطه اخیر، می‌توانیم رابطه (۱۸) را بازنویسی می‌کنیم:

$$P(y_{n+1}|x_{n+1}, D) = \int_{R^N} P(y_{n+1}|x_{n+1}, D, w)P(w|D)dw \quad (20)$$

عبارت اول داخل انتگرال، همان مدل نویز برای داده تست بوده که در رابطه (۱۳) بیان شد و عبارت دوم نیز تابع توزیع پسین وزن‌های شبکه می‌باشد. می‌توانیم میانگین تابع اخیر را به عنوان خروجی نقطه‌ای در نظر بگیریم:

$$\hat{y} = E\{P(y_{n+1}|x_{n+1}, D)\} = \int_{R^N} P(y_{n+1}|x_{n+1}, D, w)P(w|D)dw \quad (21)$$

برای محاسبه تابع توزیع پیش‌بینی خروجی (رابطه (۲۱)) به کمک تقریب گوسی می‌توانیم بنویسیم:

$$P\left(y_{n+1}|x_{n+1}, D\right) \propto \int_{R^N} \exp\left(-\frac{\beta}{2}\left(y_{n+1}-f\left(x_{n+1}, w\right)\right)^2\right) \exp\left(-\frac{1}{2}\Delta w^T A \Delta w\right) dw \quad (22)$$

اگر عرض تابع توزیع پسین را خیلی باریک فرض کنیم، می‌توانیم از تقریب مرتبه اول تابع غیرخطی f ، حول w_{MP} استفاده کنیم. به این ترتیب می‌توانیم رابطه (۲۲) را به این شکل بنویسیم:

$$P(y_{n+1}|x_{n+1}, D) = \frac{1}{(2\pi\sigma^2)^{1/2}} \exp\left(-\frac{(y_{n+1}-f(x_{n+1}, w_{MP}))^2}{2\sigma^2}\right) \quad (23)$$

که در آن واریانس برابر است با:

$$\sigma^2 = \frac{1}{\beta} + g^T A^{-1} g \quad (24)$$

و g گرادیان تابع f در w_{MP} است. عبارت (۲۴) از دو بخش تشکیل شده است. بخش اول به مشخصات نویز خروجی بستگی دارد و بخش دوم آن ناشی از عرض تابع توزیع پسین پارامترهای شبکه است. اگر نویز خروجی خیلی زیاد (یعنی β کم باشد) و یا توزیع پسین خیلی باریک باشد، در این صورت عامل غالب بخش اول است و واریانس تابع توزیع پیش‌بینی خروجی توسط واریانس نویز تعیین می‌شود. ولی اگر میزان نویز کم (β بزرگ) و یا توزیع پسین خیلی گسترده باشد، در این صورت عامل غالب بخش دوم بوده و واریانس تابع توزیع پیش‌بینی خروجی توسط عرض توزیع پسین مشخص می‌گردد.

در هر صورت نکته مهم این است که برخلاف روش‌های قبلی که یک وزن بهینه را در نظر می‌گرفتند، در این‌جا طبق رابطه (۱۸) اثر همه وزن‌ها در محاسبه خروجی دخالت داده می‌شود. در حالتی نیز که از تقریب گوسی استفاده می‌شود، ابتدا با حداقل کردن تابع خطای $S(w)$ ، وزن w_{MP} یافته می‌شود، سپس از طریق رابطه (۲۴) واریانس تابع توزیع پیش‌بینی خروجی محاسبه می‌شود.

$$p(w|D) = \frac{1}{Z_S(\alpha, \beta)} \exp(-\beta E_D - \alpha E_w) \quad (16)$$

$$= \frac{1}{Z_S(\alpha, \beta)} \exp(-S(w))$$


که در آن Z_s ثابت نرمال‌ساز است و S نیز عبارت است از:

$$S(w) = \beta E_D + \alpha E_w \quad (17)$$

$$= \frac{\beta}{2} \sum_{i=1}^n (y_i - f(x_i, w))^2 + \frac{\alpha}{2} \sum_{i=1}^N w_i^2$$

در این مرحله، یافتن یک مقدار یکتا (w_{MP}) به عنوان بهترین وزن شبکه، معادل حداقل کردن مجموع مربعات خطا به همراه فانکشنال تنظیم کاهش وزن است که در قسمت قبل به آن اشاره شد. با دقت در عبارت (۱۷) ملاحظه می‌شود که مقدار بخش اول، با افزایش داده‌های یادگیری زیاد می‌شود، در صورتی که بخش دوم ثابت باقی می‌ماند. بنابراین می‌توان گفت که اگر α و β ثابت باشند، با افزایش داده‌های یادگیری تخمین w_{ML} به سمت w_{MP} خواهد رفت. ولی اگر تعداد داده‌های یادگیری کم باشد، بخش دوم عبارت (۱۷) که مربوط به دانش قبلی در مورد وزن‌های شبکه است در یافتن w_{MP} یاری خواهد کرد

یادگیری بیزین با توابع توزیع گوسی پیشین را می‌توان به صورت شماتیک به صورت شکل (۷) نمایش داد. همان‌طور که دیده می‌شود، واریانس تابع پسین نسبت به پیشین کاهش یافته است. مقدار w_{MP} جایی است که توزیع پسین حداکثر می‌شود. ولی در عمل ممکن است این توزیع بیش از یک مقدار بیشینه داشته باشد.



شکل (۷): یادگیری بیزین برای وزن‌های شبکه

۵-۳- تابع توزیع خروجی شبکه

اگر ورودی تست x_{n+1} باشد، خروجی آن برابر خواهد بود با:


$$P(y_{n+1}|x_{n+1}, D) = \int_{R^N} P(y_{n+1}|x_{n+1}, D, w)P(w|D, x_{n+1})dw \quad (18)$$

چون تابع توزیع پسین فقط از روی داده‌های یادگیری به دست می‌آید، بنابراین داریم:

$$P(w|D, x_{n+1}) = P(w|D) \quad (19)$$


۶- مطالعه موردی

پارامترهای مدل جریان صاعقه از [۲۷] اخذ شده است که در آن $I_m=20kA$ و $\alpha=4.4 \times 10^4$ و $\beta=4.6 \times 10^5$ تعریف شده‌اند. در شکل (۸) جریان نقطه نول سیم‌پیچی زمانی که سیم‌پیچ سالم تحت تست ضربه قرار می‌گیرد، نشان داد شده است.




شکل ۸: جریان نقطه نول برای سیم‌پیچ سالم

به عنوان نمونه جریان نقطه نول زمانی که مدل تخلیه جزئی در دیسک‌های ۱ و ۲۳ قرار دارد به ترتیب در شکل‌های (۹) و (۱۰) نشان داده شده است.



شکل ۹: جریان نقطه نول تخلیه جزئی در دیسک ۱



شکل ۱۰: جریان نقطه نول تخلیه جزئی در دیسک ۲۳

۶-۳- شبکه Fuzzy ARTmap

همان‌گونه که اشاره شد، شبیه‌سازی‌های لازم مربوط به ترانسفورماتور مورد نظر و شبکه عصبی بررسی شده به ترتیب در نرم‌افزارهای EMTP و MATLAB انجام شده است. نتایج حاصله از شبیه‌سازی‌های انجام شده به ازای نرخ‌های آموزش و پارامترهای نگهبان مختلف لایه نگاشت در جدول (۲) ارائه شده است.

همان‌طور که در بخش‌های قبلی اشاره شد، از مدل مشروح ترانسفورماتور و مدل سه خازنی جهت شبیه‌سازی تخلیه جزئی در نرم‌افزار EMTP استفاده شده و این مدل PD بین خازن سیم‌پیچ‌های ترانسفورماتور در نظر گرفته شده است.

۶-۱- مشخصات ترانسفورماتور مورد مطالعه

سیم‌پیچ فشار قوی اصلی مربوط به ترانسفورماتوری با نسبت تبدیل $220kV/35kV$ و قدرت $50MVA$ می‌باشد. جزئیات مربوط به ابعاد این سیم‌پیچ و مدل مربوط به بدنه ترانسفورماتور در [۴] آورده شده است.

آزمونه شامل ۵۶ دیسک است. ۶ زوج دیسک اول از نوع درهم و ۲۲ زوج دیسک دیگر از نوع واژگون است. ابعاد تمامی زوج دیسک‌ها در جدول (۱) آورده شده است.

جدول ۱: اطلاعات فنی سیم‌پیچ فشار قوی

ارتفاع × پهنا	تعداد حلقه‌ها در هر دیسک	شماره دیسک از- تا	تعداد دیسک‌ها	روش سیم‌پیچی
۳/۰×۱۵/۰	$13 \frac{18}{20}$	۰۱-۰۵	۴	درهم
۲/۸×۱۳/۲	$12 \frac{18}{20}$	۰۵-۱۳	۸	درهم
۲/۵×۱۷/۰	$15 \frac{18}{20}$	۱۳-۱۷	۴	واژگون
۲/۰×۲۳/۰	$19 \frac{17}{20}$	۱۷-۴۵	۲۸	واژگون
۲/۰×۱۷/۰	$19 \frac{18}{20}$	۴۵-۵۴	۹	واژگون
۲/۵×۱۷/۰	$15 \frac{18}{20}$	۵۴-۵۶	۳	واژگون
	۱۰۰۵		۵۶	مجموع

۶-۲- نتایج شبیه‌سازی

مدل سه خازنی تخلیه جزئی ذکر شده در نقاط مختلف سیم‌پیچی قرار داده می‌شود و آزمون ضربه با مشخصات زیر به ترمینال سیم‌پیچ تزریق می‌شود و جریان‌های تولید شده در نقطه نول ثبت می‌شوند. در این حالت قطر حفره برابر با $0/5$ میلی‌متر در نظر گرفته شده است [۲۶]. بنابراین مقدار خازن C_g حدوداً $0/05$ پیکوفاراد محاسبه خواهد شد. حال دیسک معیوب را در طول سیم‌پیچ تغییر مکان داده و سیم‌پیچ را تحت آزمایش ضربه شبیه‌سازی می‌کنیم. هر بار جریان نقطه نول سیم‌پیچ ذخیره شده و سپس توسط شبکه عصبی FAM و شبکه بیزین مورد بررسی قرار می‌گیرد. برای مدل‌سازی صاعقه از شکل موج جریان صاعقه با معادله زیر استفاده شده است [۲۷]:

$$i(t) = I_m (e^{-\alpha t} - e^{-\beta t}) \quad (25)$$

جدول ۲: نتایج آزمون شبکه عصبی

صحت (درصد)	تعداد دسته‌ها	پارامتر نگهبان	نرخ آموزش
۸۲	۳۵	۰/۹	۰/۹۵
۸۵	۶۲	۰/۹۵	
۹۳	۲۰۸	۰/۹۸	
۸۸	۵۰	۰/۹	۰/۹۳
۹۶	۸۹	۰/۹۵	
۹۷	۲۸۸	۰/۹۸	
۸۶	۶۹	۰/۹	۰/۹
۸۹	۱۰۳	۰/۹۵	
۹۱	۳۰۱	۰/۹۸	

۶-۴ - شبکه Bayesian

همان‌گونه که اشاره شد، از یک شبکه عصبی MLP با یادگیری بیزین جهت مکان‌یابی تخلیه جزئی استفاده می‌شود و مانند شبکه عصبی Fuzzy ARTmap از جریان‌های ثبت شده در نقطه نول ترانسفورماتور جهت آموزش این شبکه استفاده شده است. نتایج پیش‌بینی شبکه Bayesian در این حالت در جدول (۴) آورده شده است.

جدول ۴: نتایج آزمون شبکه Bayesian

گرده شده خروجی	خروجی شبکه بیزین	PD در گره
۵	۵/۰۱	۵
۸	۸/۱	۸
۱۲	۱۲/۲۰	۱۲
۱۴	۱۴/۱۳	۱۴
۲۱	۲۰/۵۹	۲۰
۲۶	۲۶/۳۱	۲۶

همان‌طور که از جدول (۴) مشاهده می‌شود اگر خروجی شبکه بیزین را گرد کنیم، این شبکه ۹۸ درصد مکان وقوع تخلیه جزئی را تشخیص داده است.

در این شبکه نیز با توجه به این‌که در واقعیت و در عمل شکل موج‌های جریان اندازه‌گیری شده دارای نویز هستند و با مقادیر شبیه‌سازی شده متفاوت می‌باشند. به همین برای پیاده سازی نویز، ۱ درصد تا ۱۰ درصد ماکزیمم مقدار دامنه شکل موج شبیه‌سازی شده متفاوت می‌باشند. به همین برای پیاده سازی نویز، ۱۰ درصد تا ۱۰۰ درصد ماکزیمم مقدار دامنه شکل موج جریان شبیه‌سازی شده در دو سر سیم‌پیچی با تغییرات ۱ درصد به صورت موجی سینوسی با فرکانس‌هایی برابر با ۱۰ تا ۱۰۰ پیکوهرتز با پله‌های ۱۰ پیکوهرتز به موج شبیه‌سازی شده اضافه می‌شود. بدین ترتیب با در نظر گرفتن نویز، پاسخ شبکه بیزین به ورودی‌های جدید با مقدار درستی تشخیص تخلیه جزئی به میزان ۹۱ درصد حاصل شده است. همان‌طور که مشاهده می‌شود نتایج حاصل از شبکه بیزین با در نظر گیری اثر نویز بهتر از نتایج شبکه عصبی FAM می‌باشد و می‌توان در حالتی که سیگنال‌های جریان ثبت شده دارای نویز می‌باشند از این شبکه‌ها جهت مکان‌یابی تخلیه جزئی با دقت بالایی که وجود دارد، بهره جست.

همان‌طور که دیده شد تخلیه جزئی مهمترین منبع خطا در انواع عایق‌ها و به خصوص عایق‌های مایع می‌باشد. همچنین این پدیده مهمترین منبع خرابی در روغن ترانسفورماتورها می‌باشد. لذا بررسی این پدیده بسیار حائز اهمیت می‌باشد. اما با توجه به محدوده فرکانسی پدیده تخلیه جزئی باید گفت که مبنای مکان‌یابی صحیح و قابل قبول پالس‌های تخلیه جزئی در ترانسفورماتور، مدل‌سازی سیم‌پیچ در فرکانس‌های بالا می‌باشد.

همان‌گونه که در جدول (۲) مشاهده می‌شود، به ازای نرخ آموزش ۰/۹۳ و پارامتر نگهبان لایه نگاشت ۰/۹۸ بالاترین مقدار درستی تشخیص مکان تخلیه جزئی به میزان ۹۷ درصد می‌باشد. تعداد دسته‌های به وجود آمده در این حالت به ترتیب برابر ۲۸۸ دسته می‌باشد.

با توجه به این‌که در واقعیت و در عمل شکل موج‌های جریان اندازه‌گیری شده دارای نویز هستند و با مقادیر شبیه‌سازی شده متفاوت می‌باشند. به همین دلیل شبکه عصبی با پارامترهای نرخ آموزش‌هایی که در جدول (۲) آورده شده است، تحت آزمون دیگری قرار می‌گیرند.

برای پیاده سازی نویز، ۱ درصد تا ۱۰ درصد ماکزیمم مقدار دامنه شکل موج جریان شبیه‌سازی شده در دو سر سیم‌پیچی با تغییرات ۱ درصد به صورت موجی سینوسی با دوره تناوبی برابر با ۱ تا ۱۰ میکروثانیه با پله‌های ۱ میکروثانیه به موج شبیه‌سازی شده اضافه می‌شود. بدین ترتیب با در نظر گرفتن نویز، پاسخ شبکه عصبی به ورودی‌های جدید به ازای بهترین نرخ آموزش و پارامترهای نگهبان مختلف لایه نگاشت بدست آمده از مرحله قبل، در جدول (۳) ارائه شده است.

جدول ۳: نتایج آزمون شبکه عصبی

صحت (درصد)	تعداد دسته‌ها	پارامتر نگهبان	نرخ آموزش
۸۰	۸۶	۰/۹	۰/۹۵
۷۵	۲۰۱	۰/۹۵	
۸۶	۳۰۵	۰/۹۸	
۷۳	۹۹	۰/۹	۰/۹۳
۸۶	۳۰۷	۰/۹۵	
۹۰	۶۵۰	۰/۹۸	
۷۹	۱۹۲	۰/۹	۰/۹
۷۶	۴۸۱	۰/۹۵	
۸۸	۹۸۶	۰/۹۸	

با وجود نویز و با در نظرگیری حالت‌های مختلف در شکل موج جریان مطابق با جدول (۳)، به ازای نرخ آموزش ۰/۹۳ پارامتر نگهبان لایه نگاشت ۰/۹۸ بیشترین مقدار درستی تشخیص تخلیه جزئی به میزان

۷- نتیجه گیری

در این مقاله از شبکه عصبی FAM و بیزین به عنوان ابزاری در جهت مکان یابی تخلیه جزئی در سیم پیچ ترانسفورماتور استفاده شده است. مزیت این شبکه نسبت به سایر شبکه‌های دیگر این خانواده از شبکه‌های عصبی در سرعت بالای یادگیری و دقت آن می‌باشد. علاوه بر این، خودکار بودن بهینه‌سازی پارامتر نگهبان لایه ورودی‌ها نیز از مزایای این شبکه می‌باشد. همچنین همان‌طور که نشان داده شد، پاسخ شبکه بیزین در حضور نویز پاسخ بهتری خواهد بود. در ابتدا مدل‌سازی تخلیه جزئی در سیم پیچ ترانسفورماتور به کمک مدل مشروح ارائه شد، سپس ویژگی‌های شبکه FAM و بیزین مورد تجزیه و تحلیل قرار گرفت. در ادامه با تغییر پارامترهای شبکه عصبی میزان دقت پیش‌بینی شبکه مورد بررسی قرار گرفت و بهترین حالت ممکن بدست آمد. همچنین این شبکه با در نظرگیری نویز در شکل موج جریان مورد آزمون قرار گرفت که نتایج بدست آمده مشاهده گردید که تشخیص مکان تخلیه جزئی به کمک شبکه‌های عصبی ذکر شده، از دقت بسیار بالایی برخوردار است.

مراجع

- [1] Hamed Nafisi, Mehrdad Abedi, and Gevorg B. Gharehpetian, "Comparison of Bayesian and Fuzzy ARTmap Networks in Transformers PD Localization", International Review of Electrical Engineering, Vol. 6, No. 2, pp. 1051-105, 2011.
- [2] Nafisi, H.; Davari, M.; Abedi, M.; Gharehpetian, G.B.; , "Using Fuzzy ARTmap neural network for determination of partial discharge location in power transformers", PowerTech, 2009 IEEE Bucharest, 2009.
- [3] Okabe, S.; Ueta, G.; Wada, H., "Partial discharge signal propagation characteristics inside the winding of oil-immersed power transformer - using the three-winding transformer model in air", Dielectrics and Electrical Insulation, IEEE Transactions on , vol.18, no.6, pp.2024-2031, 2011.
- [4] حامد نفیسی، امیرحسین آقاخانی، مهرداد عابدی، گنورگ قره‌پتیان، امیرحسام حسامی‌نیا، "کاربرد شبکه عصبی Fuzzy ARTmap برای مکان‌یابی تخلیه جزئی در ترانسفورماتورها"، بیست و دومین کنفرانس بین‌المللی برق، آذرماه ۱۳۸۷، تهران، ایران.
- [5] P. J. Moore, I. E. Portugues, and I. A. Glover, "Partial Discharge Investigation of a Power Transformer Using Wireless Wideband Radio-Frequency Measurements", IEEE Transaction on Power Delivery, Vol. 21, No. 1, January 2006.
- [6] "IEEE Recommended Practice for Measurement of Power-Factor Tip-Up of Rotating Machinery Stator Coil Insulation", IEE No. 286.
- [7] Findley D.A., Brearly R.G.A. and Louttit C.C. "Evaluation of the Internal Insulation of Generator Coils Based on Power Factor Measurements", AIEE Transactions (Power Apparatus and Systems), Vol. 78, pp. 268-279, 1959.
- [8] Y. Kamata, "Diagnostic Methods for Power Transformer Insulation", IEEE Transaction on Electrical Insulation, Vol.EI-21, No.6, pp. 1045-1048, 1986.
- [9] A. Akbari, P. Werle, H. Borsi, E. Gockenbach, "Transfer Function-based Partial Discharge Localization in Power Transformers: a Feasibility Study", IEEE Electrical Insulation Magazine, Volume 18, Issue 5, pp. 22 - 32, 2002.
- [10] S.N. Hettiwatte, Z.D. Wang, P.A. Crossley, A. Darwin, G. Edwards, "Experimental Investigation into the Propagation of Partial Discharge Pulses in Transformers", IEEE Power Engineering Society Winter Meeting, Volume: 2, pp. 1372- 1377, 2002.
- [11] K.N. Smith, R.A. Perez, "Locating Partial Discharges in a Power Generating System using Neural Networks and Wavelets", Annual Report Conference on Electrical Insulation and Dielectric Phenomena, 2002, Volume , Issue, pp.458 - 461, 2002.
- [12] Jufeng Gui, Wensheng Gao, Kexiong Tan, Shengyou Gao, "Locating Partial Discharge in Power Transformer by Electrical Method". Proceeding of the 7th International Conference on Properties and Application of Dielectric Materials, June 1-5, 2003.
- [13] Carpenter, G.A. & Grossberg, S., "ART2: Self-organization of Stable Category Recognition Codes for Analog Input Patterns", Applied Optics, No. 26 vol. 23, pp. 4919-4930, 1987.
- [14] Carpenter, G.A. & Grossberg, S., "ART3: Hierarchical Search using Chemical Transmitters in Self-organizing Pattern Recognition Architectures", Neural Networks (Publication), 3, pp. 129-152, 1990.
- [15] Carpenter, G.A., Grossberg, S., & Reynolds, J.H., "ARTMAP: "Supervised Real-time Learning and Classification of Nonstationary Data by a Self-organizing Neural Network", Neural Networks (Publication), 4, pp. 565-588, 1991.
- [16] Carpenter, G.A., Grossberg, S., & Rosen, D.B., "Fuzzy ART: Fast Stable learning and Categorization of Analog Patterns by an Adaptive Resonance System", Neural Networks (Publication), 4, pp. 759-771, 1991.
- [17] Carpenter, G.A., Grossberg, S., Markuzon, N., Reynolds, J.H., & Rosen, D.B., "Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps", IEEE Transactions on Neural Networks, 3, pp. 698-713, 1992.
- [18] S. James Press, "Subjective and Objective Bayesian Statistics", 2nd Ed. John Wiley and Sons, 2003.
- [19] W.L. Buntine, A.S. Weigend, "Bayesian Back-Propagation", Complex Systems, Vol. 5, pp. 603-643, 1991.
- [20] R.M. Neal, "Bayesian Learning for Neural Networks", Lecture Notes in Statistics No. 118, Springer-Verlag, New York, 1996.
- [21] P. Muller, Rios Insua, "Issues in Bayesian Analysis of Neural Network", Neural Computations, Vol. 10, pp. 571-592, 1998.
- [22] C.C. Holmes, B.K. Mallick, "Bayesian Radial Basis Functions of Variable Dimension", Neural Computations, Vol. 10, No. 5, pp. 1217-1233, 1998.
- [23] C. Haefke, C. Helmenstein, "The Applicability of Information Criteria for Neural Network Architecture Selection", pp. 293-301, 1996.
- [24] S. James Press, "Subjective and Objective Bayesian Statistics", 2nd Ed. John Wiley and Sons, 2003.
- [25] R.M. Neal, "Prior for Infinite Networks", Technical Report CRG-TR-94-1, Toronto, 1994.

- [26] Seung-Ik Jeon, Doo-Sung Shin, Do-Hong Yun, Key-Man Han, Min-Koo Han, "A Study on the Partial Discharge Characteristics According to the Distribution Pattern of Voids within an Insulation", 5th International Conference on Conduction and Breakdown in Solid Dielectrics, pp. 398-402, 1995.
- [27] M. H. Nazemi, G.B. Gharehpetian, M. Shafiee, A.R. Allami, "Transformation of Detailed Model Transformer Winding to Its Terminal Model", XIII-th International Symposium on High Voltage Engineering", ISH 2003, Delft, Netherlands, August 2003.