



دانشگاه کاشان  
University of Kashan

مجله محاسبات نرم

## SOFT COMPUTING JOURNAL

تارنمای مجله: scj.kashanu.ac.ir



### طبقه‌بندی عیوب ترانسفورماتور با استفاده از تحلیل پاسخ فرکانسی بر پایه تکنیک همبستگی متقابل و

### ماشین بردار پشتیبان

مهدی بیگدلی<sup>۱\*</sup>، استادیار

<sup>۱</sup> دانشکده فنی و مهندسی، گروه مهندسی برق، دانشگاه آزاد اسلامی واحد زنجان، زنجان، ایران.

#### چکیده

یکی از مهم‌ترین روش‌های تشخیص عیب در ترانسفورماتورها (خصوصاً عیوب مکانیکی) روش تحلیل پاسخ فرکانسی (FRA) است. مهم‌ترین گام در فرآیند تشخیص عیب به کمک FRA، متمایز کردن عیوب و قراردادن آن‌ها در کلاس‌های متفاوت است. در این مقاله از روش هوشمند ماشین بردار پشتیبان (SVM) برای طبقه‌بندی عیوب ترانسفورماتور استفاده می‌شود. برای این منظور، دو گروه از ترانسفورماتورها مورد آزمایش قرار گرفته است. ابتدا آزمایش‌های لازم بر روی ترانسفورماتورهای مدل تحت شرایط سالم و تحت شرایط عیوب مختلف (جابجایی محوری، تغییر شکل شعاعی، تغییر فاصله بین بشقاب‌ها، اتصال کوتاه بین بشقاب‌ها و تغییر شکل هسته) انجام می‌شود. سپس با تقسیم‌بندی بازه‌های فرکانسی توابع تبدیل اندازه‌گیری شده از ترانسفورماتور، یک مشخصه جدید مبتنی بر تکنیک همبستگی متقابل برای آموزش و اعتبارسنجی SVM پیشنهاد می‌شود. بعد از انجام فرآیند آموزش، با اعمال داده‌های به‌دست آمده از ترانسفورماتورهای واقعی، عملکرد SVM در حالت‌های مختلف مورد ارزیابی و مقایسه قرار گرفته و مناسب‌ترین شاخص ارائه می‌شود.

© ۱۳۹۹ - مجله محاسبات نرم، کلیه حقوق محفوظ است.

#### اطلاعات مقاله

تاریخچه مقاله:

دریافت ۲۷ شهریور ماه ۱۳۹۹

پذیرش ۱۲ دی ماه ۱۳۹۹

کلمات کلیدی:

ترانسفورماتور

تحلیل پاسخ فرکانسی

ماشین بردار پشتیبان

تشخیص عیب

تکنیک همبستگی متقابل

#### ۱. مقدمه

ترانسفورماتورها در حین بهره‌برداری، لازم و ضروری است. این موضوع با گذشت زمان بیشتر مورد توجه قرار گرفته است به طوری که امروزه پایش وضعیت ترانسفورماتورهای متوسط و کوچک نیز از اهمیت ویژه‌ای برخوردار است. یکی از روش‌هایی که در سال‌های اخیر برای پایش وضعیت ترانسفورماتور استفاده می‌شود روش تحلیل پاسخ فرکانسی (FRA) است. روش FRA که به عنوان روش تابع تبدیل نیز شناخته می‌شود، یک روش مقایسه‌ای است [۱]. یعنی اندازه‌گیری‌هایی که از ترانسفورماتور در حالت سالم انجام می‌شود به عنوان نتایج اندازه‌گیری مرجع نزد مشتری یا کارخانه

پایداری و قابلیت اطمینان یک سیستم قدرت تا حد زیادی به وضعیت ترانسفورماتورهای آن وابسته است. ترانسفورماتورهای قدرت جزء تجهیزات مهم و گران قیمت یک شبکه تولید و انتقال برق هستند که خرابی آن‌ها باعث تحمیل هزینه‌های زیاد، کاهش قابلیت اطمینان شبکه قدرت و در نهایت خروج بخشی از شبکه از مدار خواهد شد. بنابراین مراقبت و محافظت از

✦ نوع مقاله: پژوهشی

\* نویسنده مسئول

پست(های) الکترونیکی: m.bigdeli@srbiau.ac.ir (بیگدلی)

استخراج شده و سپس این مشخصه‌ها برای آموزش و تست طبقه‌بندی کننده‌ها به کار گرفته می‌شوند. در [۹] مهم‌ترین شاخص‌های عددی، معرفی شده و با محاسبه آن‌ها در حالت‌های مختلف عیب نسبت به حالت سالم، شاخص‌هایی که از قابلیت اطمینان بیشتری برخوردار هستند شناسایی شده‌اند. در [۱۰] شاخص آماری جدیدی به نام F-test معرفی شده و نشان داده شده است که در مقایسه با سایر شاخص‌های عددی از دقت بیشتری برخوردار است. در [۱۱] با معرفی MMR که بر پایه شاخص ED بنا نهاده شده است نوع عیب سیم‌پیچ ترانسفورماتور تشخیص داده شده است. در [۱۲] با استفاده از تکنیک ویولت و امپدانس مشخصه، روش جدیدی برای طبقه‌بندی عیوب پیشنهاد شده است. با استفاده از نصب آنتن بر روی ترانسفورماتور و با تحلیل امواج الکترومغناطیسی دریافتی از ترانسفورماتور بر پایه شاخص ED تمایز بین عیوب در [۱۳] انجام شده است. در [۱۴] با استفاده از نگاشت بردار تابع تبدیل اندازه‌گیری شده از ترانسفورماتور به یک فضای دوبعدی، نوع عیب تشخیص داده شده است. در [۱۵] ابتدا تابع تبدیل ترانسفورماتور تخمین زده شده و سپس با ترسیم دیاگرام نایکوئیست، بین عیوب تمایز قائل شده است. با این حال در این تحقیقات فقط دو عیب AD و RD مورد مطالعه قرار گرفته است. مشخصه جدیدی به نام  $\alpha$  بر پایه شاخص  $\rho$  برای متمایز کردن عیوب ترانسفورماتور در [۱۶] معرفی شده است. در این تحقیق سه عیب AD، RD و DSV مورد بررسی قرار گرفته است و اثری از بررسی عیوب SC و DCS نیست. در [۱۷] با معرفی شاخص CCF عیوب مختلف ترانسفورماتور خوشه‌بندی شده است. در این مقاله نیز سه عیب AD، RD و SC خوشه‌بندی شده و DSV و DCS در فرآیند تشخیص عیب در نظر گرفته نشده است. در [۱۸] با معرفی شاخص جدیدی به نام IMGGM هر ۵ عیب اشاره شده در این تحقیق مورد بررسی قرار گرفته و طبقه‌بندی شده است. با این حال تشخیص نوع عیب به صورت احتمالی مورد بررسی قرار گرفته و با قطعیت انجام نشده است. ضمن اینکه این مقاله تأکید کرده است در کارهای آینده باید از روش‌های طبقه‌بندی کننده هوشمند برای تشخیص

سازنده نگهداری می‌شود. در هنگام بازدید سالیانه و یا زمانی که عیبی در ترانسفورماتور رخ می‌دهد دوباره همان اندازه‌گیری با شرایط مشابه اتصالات پایانه‌ها و شرایط محیطی یکسان انجام می‌شود. با مقایسه نتایج اندازه‌گیری مرجع و نتایج اندازه‌گیری‌های جدید می‌توان نوع و شدت عیب ترانسفورماتور را تعیین کرد. متأسفانه استانداردهای موجود در زمینه FRA [۳ و ۲] بیشتر در مورد الزامات اندازه‌گیری و مدارهای تست بحث نموده‌اند و هنوز استاندارد دقیقی برای تفسیر نتایج اندازه‌گیری‌های FRA تدوین نشده است. از این رو در سال‌های اخیر مطالعات زیادی در خصوص تفسیر نتایج اندازه‌گیری‌های FRA برای دستیابی به اطلاعاتی در مورد عیب ترانسفورماتور انجام شده است [۴-۸]. با توجه به اینکه در اولین گام باید بتوان نوع عیب را تشخیص داد و آن‌ها را در کلاس‌های متفاوت قرار داد، بنابراین تمرکز این مقاله بر تشخیص نوع عیب و طبقه‌بندی آن‌هاست.

مهم‌ترین عیوبی که در ترانسفورماتور اتفاق می‌افتد و با روش FRA قابل شناسایی است عبارت‌اند از [۱۷-۱]:

- جابجایی محوری سیم‌پیچ (AD)
- تغییر شکل شعاعی سیم‌پیچ (RD)
- تغییر فاصله بین بشقاب‌های سیم‌پیچ (DSV)
- اتصال کوتاه بین بشقاب‌های سیم‌پیچ (SC)

علاوه بر این، تغییر شکل ورقه‌های هسته (DCS) نیز به کمک FRA قابل شناسایی است که در مراجع، بسیار کم به آن پرداخته شده است [۱۸].

برای تشخیص نوع عیب و طبقه‌بندی آن‌ها روش‌های مختلفی در مراجع پیشنهاد شده است که می‌توان آن‌ها را در دو دسته عمده قرار داد. دسته اول روش‌هایی هستند که در آن‌ها طبقه‌بندی عیوب صرفاً بر اساس تغییرات شاخص‌های عددی (آماری و ریاضیاتی) در محدوده‌های فرکانسی خاص، انجام می‌شود [۹-۱۸]. دسته دوم روش‌هایی هستند که از طبقه‌بندی کننده‌های هوشمند برای متمایز کردن عیوب استفاده می‌کنند [۱۹-۲۵]. در این روش‌ها ابتدا مشخصه‌های لازم از پاسخ فرکانسی (که عمدتاً همان شاخص‌های آماری و عددی هستند)

نوع عیب استفاده شود.

طبقه‌بندی کننده SVM با مشخصه F7 مبتنی بر همبستگی متقابل، بهترین عملکرد حاصل می‌شود. در ضمن مقایسه نتایج طبقه‌بندی عیوب به کمک SVM با نتایج به دست آمده از ANN نشان‌دهنده دقت بالای SVM در مقایسه با ANN است.

## ۲. بیان مسئله

تشخیص نوع عیب سیم پیچ ترانسفورماتور با استفاده از تحلیل نتایج اندازه‌گیری‌های FRA یک گام مهم و اساسی در فرآیند پایش وضعیت ترانسفورماتور است. برای تشخیص نوع عیب نیاز است عیوب مختلف از یکدیگر تفکیک شده و در کلاس‌های مختلف قرار گیرند. بنابراین می‌توان گفت با یک مسئله طبقه‌بندی مواجه هستیم که برای حل آن می‌توان از روش‌های طبقه‌بندی کننده هوشمند استفاده کرد. همان‌طور که در بخش قبل ملاحظه گردید روش‌های مختلفی برای تشخیص نوع عیب ترانسفورماتورها بر پایه طبقه‌بندی کننده‌های هوشمند پیشنهاد شده است؛ ولی این مطالعات محدودیت‌هایی به شرح زیر دارند:

۱- در هیچ‌یک از مطالعات، عیب DCS در نظر گرفته نشده است و در تعداد زیادی از این مطالعات ۲ یا در نهایت ۳ عیب مورد بررسی قرار گرفته است. در حالی که با افزایش تعداد عیوبی که به کمک روش FRA قابل شناسایی است، کار طبقه‌بندی عیوب نیز سخت‌تر و پیچیده‌تر خواهد بود.

۲- در تحقیقات گذشته، تعداد مشخصه‌های استخراج شده برای آموزش طبقه‌بندی کننده‌ها محدود بوده است و هر کدام، از یک مشخصه بخصوص استفاده کرده‌اند.


۳- در مطالعات گذشته برای استخراج مشخصه، محاسبه شاخص‌ها در کل بازه فرکانسی اندازه‌گیری شده، صورت گرفته است. بدیهی است نتیجه این محاسبه فقط یک عدد خواهد بود که برای آموزش طبقه‌بندی کننده، ناکافی است.

برای رفع این محدودیت‌ها، در این مقاله هر پنج عیب مورد بررسی قرار گرفته و مشخصه‌های مختلفی نیز جهت آموزش و

در [۱۹-۲۰] بر پایه تخمین تابع تبدیل به کمک برازش برداری، مشخصه‌های لازم از توابع تبدیل اندازه‌گیری شده برای ۴ عیب AD، RD، DSV و SC استخراج شده و به کمک PNN [۱۹] و SVM [۲۰]، این ۴ عیب از هم تفکیک شده است. تمایز و طبقه‌بندی بین عیوب الکتریکی و مکانیکی (فقط AD و RD) و جریان هجومی به کمک شبکه‌های عصبی مصنوعی (ANN) و درخت تصمیم در [۲۱] انجام شده است. طبقه‌بندی عیوب RD، DSV و SC و قرار دادن آن‌ها در سه کلاس متفاوت در [۲۳-۲۲] انجام شده است. در [۲۲] پاسخ فرکانسی اندازه‌گیری شده از ترانسفورماتور به سه بازه فرکانسی تقسیم‌بندی شده و به کمک روش تصویری باینری و SVM، تفکیک بین عیوب انجام شده است. در [۲۳] از شاخص‌های آماری و عددی برای آموزش و تست SVM استفاده شده است، با این حال عمل تقسیم‌بندی فرکانسی انجام نشده است. برای تعیین نوع عیب، در [۲۴] یک روش جدید مبتنی بر پنجره‌سازی پیشنهاد شده است. بعد از پنجره‌سازی و محاسبه شاخص‌ها، برای تفکیک عیوب از روش FDA استفاده شده است. در [۲۵] از همبستگی متقابل برای استخراج مشخصه استفاده شده و این مشخصه‌ها برای آموزش و تست شبکه عصبی مصنوعی جهت تفکیک سه عیب AD، RD و SC به کار گرفته شده است. با این حال در این مطالعات، عیب DCS در نظر گرفته نشده است.

در این مقاله با انجام آزمایش‌های لازم بر روی ترانسفورماتورهای مختلف در حالت سالم و حالت‌های مختلف عیب (AD، RD، DSV، SC و DCS) توابع تبدیل مورد نیاز استخراج می‌شود. برای طبقه‌بندی عیوب و قرار دادن آن‌ها در پنج کلاس متفاوت از طبقه‌بندی کننده هوشمند SVM استفاده می‌شود. با محاسبه شاخص‌های مبتنی بر تکنیک همبستگی متقابل، یک مشخصه مناسب برای آموزش و اعتبارسنجی SVM پیشنهاد می‌شود. برای ارزیابی عملکرد SVM، داده‌های به دست آمده از ترانسفورماتورهای واقعی به آن اعمال می‌شود. تحلیل نتایج نشان می‌دهد که با تقسیم‌بندی بازه‌های فرکانسی توابع تبدیل اندازه‌گیری شده به ۱۰ بازه مساوی و استفاده از

مطالعات آزمایشگاهی مورد استفاده قرار می‌گیرد. مزیت عمده ترانسفورماتورهای مدل این است که اتصالات مختلف از سیم‌پیچ‌های آن در دسترس بوده و امکان اعمال عیوب مختلف به صورت عمدی بر روی ترانسفورماتور وجود دارد تا از این طریق بانک اطلاعاتی کامل‌تری حاصل شود. این گروه از ترانسفورماتورها با ساختارهای تقریباً مشابه مورد آزمایش قرار گرفته و بر روی هر یک از آن‌ها یکی از عیوب مورد مطالعه (AD, RD, DSV, SC و DCS) اعمال شده است. نحوه اعمال عیب بر روی این ترانسفورماتورها به شرح زیر است.



شکل (۱): مدار اندازه‌گیری تابع تبدیل

**Case 1:** برای مطالعه‌ی جابجایی محوری سیم‌پیچ‌ها نسبت به همدیگر، یک ترانسفورماتور متشکل از یک سیم‌پیچ فشار قوی ساخته شده از ۳۱ جفت بشقاب شش حلقه‌ای و یک سیم‌پیچ فشار ضعیف ساخته شده از چهار لایه‌ی ۹۹ حلقه‌ای مورد استفاده قرار گرفته است. توان و ولتاژ نامی این ترانسفورماتور به ترتیب ۱/۳ MVA و ۱۰ kV است. در آزمایش‌های انجام شده، سیم‌پیچ لایه‌ای داخلی نسبت به سیم‌پیچ بشقابی خارجی در ۸ مرحله (هر مرحله یک سانتی‌متر) جابجا شده است.

**Case 2:** ترانسفورماتور مورد آزمایش برای مطالعه RD دارای یک سیم‌پیچ فشار قوی تشکیل شده از ۳۰ جفت بشقاب ۱۱ حلقه‌ای و یک سیم‌پیچ فشار ضعیف ساخته شده از یک لایه‌ی ۲۳ حلقه‌ای است. توان و ولتاژ نامی این ترانسفورماتور به

اعتبارسنجی به کار گرفته می‌شود. بنابراین نوآوری‌های این مقاله را می‌توان به شرح زیر بیان کرد:

- ۱- پیشنهاد یک مشخصه جدید مبتنی بر تکنیک همبستگی متقابل برای آموزش و آزمایش SVM: اگرچه تکنیک همبستگی متقابل در کاربردهای مختلف به کار گرفته شده است ولی در این مقاله از این تکنیک برای تحلیل نتایج FRA جهت تفکیک عیوب ترانسفورماتور استفاده می‌شود.
- ۲- تقسیم‌بندی بازه‌های فرکانسی نتایج اندازه‌گیری‌های FRA به ۱۰ بازه مساوی جهت استخراج تعداد کافی از مشخصه‌ها
- ۳- مقایسه عملکرد مشخصه‌های مختلف مبتنی بر تکنیک همبستگی متقابل و تعیین مطمئن‌ترین شاخص در طبقه‌بندی عیوب به کمک FRA
- ۴- در نظر گرفتن عیب DCS در فرآیند طبقه‌بندی عیوب ترانسفورماتور

### ۳. ایجاد بانک اطلاعات

به منظور ارزیابی عملکرد SVM، لازم است یک بانک اطلاعات از وضعیت حالت سالم و معیوب ترانسفورماتورها (در شدت‌های مختلفی از عیب) ایجاد شود. برای این منظور در این تحقیق دو گروه از ترانسفورماتورها مورد آزمایش قرار گرفته‌اند. در اندازه‌گیری‌های انجام شده در این تحقیق، از مدار شکل (۱) استفاده شده است [۳]. ذکر این نکته ضروری است که در شکل (۱) به جای ولتاژ خروجی ( $V_{out}$ ) می‌توان جریان خروجی را اندازه‌گیری نمود که در این صورت تابع تبدیل از جنس ادمیتانس خواهد بود.

#### ۳.۱. گروه اول از ترانسفورماتورها

گروه اول از ترانسفورماتورها، از نوع ترانسفورماتورهای مدل هستند. منظور از ترانسفورماتور مدل ترانسفورماتوری است که ساختار آن دقیقاً مشابه ترانسفورماتور واقعی است ولی ممکن است سطح ولتاژ و توان آن واقعی نباشد. بنابراین صرفاً جهت

میزان ۱۰ درصد شعاع هسته انجام می‌شود.

### ۳.۲. گروه دوم از ترانسفورماتورها

گروه دوم، ترانسفورماتورهایی هستند که در حین کار دچار عیب شده و در ابتدا نوع عیب آن‌ها مشخص نبوده و بعد از باز کردن متعلقات آن، نوع عیب مشخص شده است. البته لازم به ذکر است که قبل از باز کردن اکتیو پارت ترانسفورماتور، تابع تبدیل آن اندازه‌گیری شده است. اطلاعات این ترانسفورماتورها به شرح زیر است:

**Case 6:** یک ترانسفورماتور توزیع 20/0.4 kV و 0.4 MVA با سیم‌پیچ فشار قوی ساخته شده از ۴۰ بشقاب ۱۷ حلقه‌ای و سیم‌پیچ فشار ضعیف ساخته شده از ۲ لایه‌ی ۹ حلقه‌ای است. به دلیل حمل و نقل نامناسب ترانسفورماتور از محل تولید تا محل نصب، ترانسفورماتور دچار عیب AD شده است.

**Case 7:** یک ترانسفورماتور توزیع 20/0.4 kV و 1 MVA که سیم‌پیچ فشار قوی آن از ۵۰ بشقاب ۱۱ حلقه‌ای و سیم‌پیچ فشار ضعیف آن از ۲ لایه‌ی ۱۱ حلقه‌ای ساخته شده است. این ترانسفورماتور به دلیل اتصال کوتاه نزدیک پایانه ترانسفورماتور، دچار عیب RD شده است.

**Case 8:** یک ترانسفورماتور فوق توزیع 63/20 kV و 30 MVA شامل سیم‌پیچ فشار قوی ساخته شده از ۸۰ بشقاب ۱۵ حلقه‌ای و سیم‌پیچ فشار ضعیف ساخته شده از ۵ لایه‌ی ۶۴ حلقه‌ای است. به دلیل تصادف وسیله نقلیه حمل‌کننده ترانسفورماتور، عیب DSV رخ داده است.

**Case 9:** ترانسفورماتور توزیع 20/0.4 kV و 0.5 MVA با سیم‌پیچ فشار قوی ساخته شده از ۴۵ بشقاب ۱۳ حلقه‌ای و سیم‌پیچ فشار ضعیف ساخته شده از ۲ لایه‌ی ۱۰ حلقه‌ای است. این ترانسفورماتور در حین سوار شدن بر روی وسیله نقلیه حمل‌کننده به زمین پرتاب شده و عیب DSV در آن رخ داده است.

**Case 10:** ترانسفورماتوری با مشخصات مشابه ترانسفورماتور Case 9 که به دلیل تخریب عایق دور سیم‌پیچ، عیب SC در آن رخ داده است.


ترتیب MVA ۱/۲ و ۱۰ kV است. در این آزمایش، سیم‌پیچ بشقابی در ۴ مرحله در جهت شعاعی تغییر شکل داده شده است.

**Case 3:** ترانسفورماتور این بخش دقیقاً مشابه Case 2 است. برای مطالعه‌ی اثر تغییر فاصله‌ی بین بشقاب‌ها، سیم‌پیچ سالم دیگری که فاصله‌ی بین بشقاب‌های آن در حالت سالم و طبیعی ۵ mm است، انتخاب شده است و جهت بررسی اثر عیب روی توابع تبدیل، این فاصله به ۷/۵، ۱۰، ۱۵، ۲۰ و ۲۵ میلی‌متر تغییر داده شده است. برای مطالعه‌ی بهتر اثر عیب، تغییر فاصله‌ی بین بشقاب‌ها در ۳ محل (بشقاب‌های ۲، ۴ و ۱۶) انجام شده است.

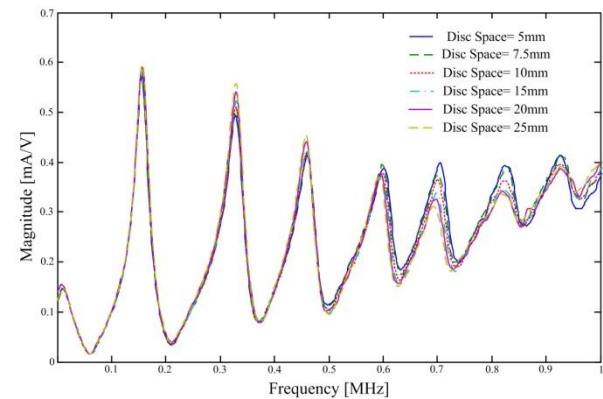
**Case 4:** در این بخش سیم‌پیچ فشار قوی یک ترانسفورماتور ۱۰ kV و ۱/۲ MVA مورد آزمایش قرار گرفته است. این سیم‌پیچ از نوع زوج دیسک واژگون ۶۰ بشقابی بوده که هر بشقاب دارای ۹ حلقه است. تمامی بشقاب‌های سیم‌پیچ دارای یک انشعاب قابل دسترس می‌باشند که اندازه‌گیری توابع تبدیل در مکان‌های مختلف در طول سیم‌پیچ را امکان‌پذیر می‌نماید.

**Case 5:** به منظور بررسی اثر تغییر شکل ورقه‌های هسته (DCS) در پاسخ فرکانسی، یک ترانسفورماتور نمونه شامل یک سیم‌پیچ فشار قوی ساخته شده از ۱۰ بشقاب ۱۱ حلقه‌ای با سطح توان 1 MVA و ۱ سطح ولتاژ ۲۰ kV به کار گرفته شده است. این سیم‌پیچ بر روی هسته‌ای سوار شده که تابع تبدیل این سیم‌پیچ در دو حالت (ابتدا در حالت سالم و سپس با دفورمه کردن هسته) اندازه‌گیری شده است. در مطالعاتی که در زمینه تشخیص عیب DCS به کمک FRA انجام شده است [۱۸]، تغییر شکل‌های با شدت کم مورد بررسی قرار گرفته است. در عمل نیز تغییر شکل بسیار شدید در هسته به ندرت اتفاق می‌افتد. از طرف دیگر، چون هسته نسبت به سیم‌پیچ ساختار بسیار ساده‌تری دارد بحث محل تغییر شکل در آن، مورد علاقه محققین نیست. اینکه کجای هسته دچار تغییر شکل شده، از اهمیت کمتری برخوردار است و بیشتر شدت عیب در آن مهم است. بنابراین برای مطالعه اثر DCS بر روی پاسخ فرکانسی، در این مقاله تغییر شکل هسته از یک طرف آن و به


نیست و هدف آن هم یافتن بهترین مرز در بین داده‌هاست به گونه‌ای که بیشترین فاصله ممکن را از تمام دسته‌ها (بردارهای پشتیبان آن‌ها) داشته باشد.



Case 2 (الف)



Case 3 (ب)



Case 8 (ج)

شکل (۲): تعدادی از توابع تبدیل اندازه‌گیری شده

عمل تفکیک داده‌ها می‌تواند هم به صورت خطی و هم غیرخطی انجام شود. در حالت غیرخطی، فضای ورودی به

**Case 11:** ترانسفورماتوری با مشخصات مشابه Case 7 است که دچار عیب DCS شده است.

نتایج اندازه‌گیری تعدادی از این ترانسفورماتورها در شکل (۲) نشان داده شده است. این اندازه‌گیری‌ها نشان می‌دهند که با افزایش میزان تغییرات در ساختار سیم‌پیچ به واسطه یک عیب، تغییرات ایجادشده در شکل تابع تبدیل نسبت به مقدار مرجع نیز افزایش خواهد یافت. اما از روی شکل ظاهری این توابع تبدیل نمی‌توان به تشخیص عیب پرداخت. از این رو در بخش‌های بعدی مقاله بر اساس این اندازه‌گیری‌ها، یک سیستم هوشمند تشخیص عیب پیشنهاد خواهد شد.

#### ۴. ماشین بردار پشتیبان

در این مقاله برای تشخیص نوع عیب ترانسفورماتور از روش SVM استفاده می‌شود. تئوری این روش به‌طور مبسوط در مراجع مختلف [۲۶-۳۱] مورد بررسی قرار گرفته است. توانایی این روش نیز در حل مسائل طبقه‌بندی عیوب ترانسفورماتورها به اثبات رسیده است [۲۰، ۲۲-۲۳]. بنابراین در این بخش به‌طور مختصر در مورد آن بحث می‌شود.

SVM به‌عنوان یک ابزار استاندارد برای یادگیری ماشین و داده‌کاوی شناخته می‌شود که مبتنی بر پیشرفت در تئوری یادگیری آماری است. SVM در ابتدا فقط برای حل مسائل طبقه‌بندی باینری استفاده می‌شد اما با گسترش استفاده از آن، نسخه طبقه‌بندی کننده چند کلاسه آن نیز توسعه یافت. ماشین بردار پشتیبان، یک دسته‌بند مرزی است که با معیار قرار دادن بردارهای پشتیبان، بهترین دسته‌بندی و تفکیک بین داده‌ها را مشخص می‌کند. بردارهای پشتیبان به زبان ساده، مجموعه‌ای از نقاط در فضای  $n$  بعدی از داده‌ها هستند که مرز دسته‌ها را مشخص می‌کنند و مرزبندی و دسته‌بندی داده‌ها بر اساس آن‌ها انجام می‌شود و با جابجایی یکی از آن‌ها، خروجی دسته‌بندی ممکن است تغییر کند. در SVM فقط داده‌های قرار گرفته در بردارهای پشتیبان مبنای یادگیری ماشین و ساخت مدل قرار می‌گیرند و این الگوریتم به سایر نقاط داده حساس

مشخصه به صورت زیر استخراج کرد:

$$F_1 = E_{max} \quad (۳)$$

$$F_2 = \frac{\sum_{n=-W}^W n E_n}{E_{max}} \quad (۴)$$

$$F_3 = \frac{\sum_{n=-W}^W n^2 E_n}{\sum_{n=-W}^W E_n} \quad (۵)$$

$$F_4 = \frac{\sum_{n=-W}^W |n| E_n}{\sum_{n=-W}^W E_n} \quad (۶)$$

$$F_5 = \sqrt{\frac{\sum_{n=-W}^W n^2 E_n}{\sum_{n=-W}^W E_n}} \quad (۷)$$

$$F_6 = \sum_{n=-W}^W \frac{E_n}{2W + 1} \quad (۸)$$

$$F_7 = \sqrt{\frac{\sum_{n=-W}^W (E_n - F_6)}{2W + 1}} \quad (۹)$$

بعد از محاسبه شاخص‌های فوق در ۱۰ بازه فرکانسی از توابع تبدیل اندازه‌گیری شده، این مشخصه‌ها به‌عنوان ورودی به SVM اعمال می‌شوند. بنابراین ماتریس ورودی برای هر مشخصه را می‌توان به صورت زیر تعریف کرد:

$$I_p = \begin{bmatrix} F_{p1,AD_i} & F_{p1,RD_j} & F_{p1,DSV_k} & F_{p1,SC_l} & F_{p1,DCS_l} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ F_{pq,AD_i} & F_{pq,AD_j} & F_{pq,DSV_k} & F_{pq,SC_l} & F_{pq,DCS_l} \end{bmatrix} \quad (۱۰)$$

که  $i$  نمایانگر شدت AD از ۱ تا ۸ سانتی‌متر،  $j$  درجه RD از ۱ تا ۴،  $k$  شدت DVS از ۷/۵ تا ۲۵ میلی‌متر و برای ۳ محل ۲، ۴ و ۱۶،  $l$  محل اتصال کوتاه و  $m$  شدت DCS می‌باشند.  $p$  نشان‌دهنده شماره مشخصه است که در این مقاله ۷ مشخصه معرفی شد.  $q$  نیز نشان‌دهنده تعداد بازه‌های فرکانسی است که در این مقاله برابر ۱۰ است.

خروجی SVM می‌تواند اعداد ۱ تا ۵ باشد که به ترتیب به AD، RD، DSV، SC و DCS اختصاص دارد. بنابراین می‌توان بردار خروجی را به صورت زیر تعریف کرد (رابطه ۱۱):

کمک توابع کرنل به فضای ویژگی منتقل می‌شود. یکی از بهترین توابع کرنلی که در SVM استفاده می‌شود، تابع گوسین است که به صورت زیر تعریف می‌شود [۲۷]:

$$K(X, Y) = \exp\left(-\frac{1}{2\sigma^2} \|X - Y\|^2\right) \quad (۱)$$

که  $X$  و  $Y$  به ترتیب بردارهای ورودی و خروجی بوده و  $\sigma$  نیز یک مقدار ثابت بوده که با توجه به نوع داده‌ها مشخص می‌شود. علاوه بر این، SVM پارامتری دیگری به نام  $C$  دارد که میزان over-fit یا under-fit شدن را کنترل می‌کند. تعیین دقیق پارامترهای  $\sigma$  و  $C$  بسیار مهم است و معمولاً به روش سعی و خطا تعیین می‌شود.

## ۵. روش پیشنهادی برای استخراج ویژگی

یکی از بخش‌های مهم در هر سیستم تشخیص الگو، بخش استخراج ویژگی است. در تشخیص عیوب ترانسفورماتور، استخراج ویژگی‌ها مبتنی بر استفاده از اطلاعات مقایسه تابع تبدیل جدید با تابع تبدیل مرجع است. یکی از بهترین روش‌های ممکن برای مقایسه‌ی تابع تبدیل جدید با تابع تبدیل مرجع، استفاده از شاخص‌های مبتنی بر همبستگی متقابل است. بنابراین در این مقاله پیشنهاد می‌شود که از این شاخص‌ها به‌عنوان مشخصه استفاده شود.

همبستگی متقابل یک تکنیک ریاضی است که میزان تشابه دو سیگنال وابسته را مشخص می‌نماید. اگر تابع تبدیل مرجع را با  $A(n)$  و تابع تبدیل جدید را با  $B(n)$  نشان دهیم به کمک رابطه زیر می‌توان همبستگی متقابل این دو سیگنال را محاسبه کرد [۲۵]:

$$\hat{E}_{AB}(m) = \begin{cases} \sum_{n=0}^{W-m-1} A_{n+m} B_n & m \geq 0 \\ \hat{E}_{BA}(-m) & m < 0 \end{cases} \quad (۲)$$

که  $m = -W, \dots, -1, 0, 1, \dots, W$  پارامتر شیفت زمانی بوده و  $W$  نیز تعداد نمونه‌ها در سیگنال‌های اندازه‌گیری شده است. بنابراین سیگنال همبستگی متقابل دارای  $2W + 1$  نمونه خواهد بود. بعد از حصول سیگنال همبستگی، می‌توان  $W$

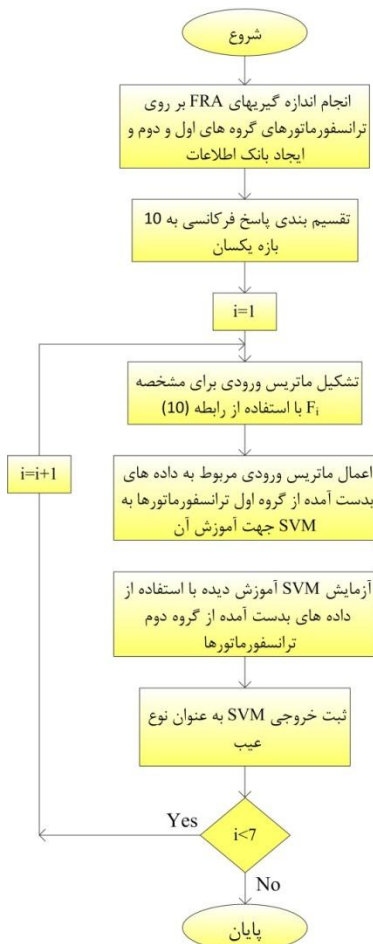
هیپربولیک (که در جعبه ابزار شبکه‌های عصبی در نرم‌افزار MATLAB با نام *tansig* شناخته می‌شود) و تابع محرک لایه‌ی خروجی نیز یک تابع خطی (که در جعبه ابزار شبکه‌های عصبی در نرم‌افزار MATLAB با نام *purelin* شناخته می‌شود) در نظر گرفته شده است.

$$O = \begin{bmatrix} AD_1 \dots AD_i RD_1 \dots RD_j DSV_1 \dots DSV_k \\ SC_1 \dots SC_l DCS_1 \dots DCS_m \end{bmatrix} \quad (11)$$

در شکل (۳) فرآیند طبقه‌بندی عیوب ترانسفورماتور با استفاده از روش پیشنهادی آورده شده است.

## ۶. تحلیل نتایج

در این بخش با اعمال مشخصه‌های استخراج‌شده از توابع تبدیل به SVM، عملکرد آن مورد ارزیابی قرار می‌گیرد. محاسبه مشخصه‌های  $F_1$  تا  $F_7$  می‌تواند در بازه‌های فرکانسی مختلف انجام شود. اگر محاسبه در کل محدوده فرکانسی اندازه‌گیری شده صورت گیرد، فقط یک مقدار عددی حاصل می‌شود که برای آموزش SVM ناکافی است. برای رفع این مشکل، از تقسیم پاسخ فرکانسی به بازه‌های مختلف استفاده می‌شود. این تقسیم‌بندی فرکانسی باید به گونه‌ای باشد که اولاً تعداد داده‌ها زیاد نباشد چون باعث می‌شود تصمیم‌گیری برای SVM سخت شده و سرعت آن نیز کاهش یابد. ثانیاً اگر تعداد داده‌ها از حد مشخصی کمتر باشد SVM به‌خوبی آموزش نخواهد دید و خروجی نادرست تولید خواهد کرد. بنابراین در این مقاله با سعی و خطا، حالت‌های مختلف بررسی شد. در جدول (۱) میزان دقت مشخصه‌ها به ازای تقسیم‌بندی‌های مختلفی از بازه فرکانسی اندازه‌گیری شده، آورده شده است. ملاحظه می‌شود که بالاترین دقت مربوط به حالتی است که بازه فرکانسی اندازه‌گیری شده به ۱۰ قسمت مساوی تقسیم شود.



شکل (۳): فلوچارت روش پیشنهادی برای طبقه‌بندی عیوب ترانسفورماتور

در جدول (۲) خطای حاصل از اعمال داده‌های اعتبارسنجی و تست به SVM و ANN به ازای تمام شاخص‌ها آورده شده است.

بررسی نتایج جدول‌های (۱) و (۲) نشان می‌دهد که:

۱- برای استخراج مشخصه‌ها می‌توان آن‌ها را در بازه‌های فرکانسی مختلف محاسبه کرد. بالاترین دقت وقتی

در ادامه، به منظور اثبات قابلیت SVM مقایسه‌ای با نتایج شبکه عصبی کلاسیک انجام می‌شود. شبکه عصبی پرسپترون با الگوریتم پس انتشار خطا یکی از بهترین روش‌های حل مسائل طبقه‌بندی است [۲۶]. بنابراین در این بخش، این روش برای تشخیص نوع عیب به کار گرفته می‌شود. شبکه‌ی مورد استفاده در این تحقیق یک شبکه‌ی MLP سه لایه است که از یک لایه‌ی ورودی، یک لایه‌ی مخفی و یک لایه‌ی خروجی تشکیل شده است. برای آموزش شبکه از قانون پس انتشار خطا استفاده شده است. تابع محرک (انتقال) لایه‌ی مخفی، تانژانت



این، خطای طبقه‌بندی در این مشخصه‌ها در داده‌های اعتبارسنجی نیز بالای ۱۰ درصد است.

۴- مشخصه‌های  $F_5$  تا  $F_7$  دارای خطای کمتری نسبت به مشخصه‌های  $F_1$  تا  $F_4$  (خطای اعتبارسنجی کمتر از ۶ درصد و خطای تست کمتر از ۲۰ درصد) هستند.

بر اساس تحلیل‌های فوق می‌توان نتیجه گرفت برای استخراج مشخصه بهتر است از مشخصه‌های  $F_5$  تا  $F_7$  استفاده شود. بنابراین نتایج مربوط به این شاخص‌ها با جزئیات بیشتری بررسی می‌شود.

برای جلوگیری از وقوع پدیده *Over-fitting*، علاوه بر داده‌های تست، بخشی از داده‌های ترانسفورماتورهای مدل نیز برای اعتبارسنجی SVM به کار گرفته می‌شود. برای این منظور از روش *K-Fold Cross Validation* استفاده می‌شود. در این روش، طبقه‌بندی  $K$  بار انجام می‌شود و در هر بار  $1/K$  برابر داده‌ها برای اعتبارسنجی و بقیه برای آموزش طبقه‌بندی کننده استفاده می‌شود. سپس میانگین خطاها به‌عنوان خطای محاسبات برگردانده می‌شود. در این مقاله مقدار  $K$ ، ۵ در نظر گرفته شده است. در شکل (۴) دقت حاصل از اعمال داده‌های اعتبارسنجی به SVM برای ۳ مشخصه  $F_5$  تا  $F_7$  به تفکیک هر کلاس آورده شده است. در هر خانه مربعی شکل، دو عدد آورده شده است که یکی از آن‌ها مربوط به تعداد حالت‌های مورد بررسی بوده و دیگری که برحسب درصد بیان شده، مربوط به دقت مشخصه در تفکیک عیوب است. برای مثال در مشخصه  $F_5$  از ۳۶ حالت بررسی شده، ۲ مورد اشتباه تشخیص داده شده است. بنابراین دقت کل  $94/4$  درصد خواهد بود که در خانه مربعی شکل جداگانه‌ای نشان داده شده است. در ضمن این مشخصه در تشخیص عیب کلاس ۱ (که مربوط به عیب AD است) از ۸ مورد بررسی شده، فقط ۱ مورد را نادرست تشخیص داده است بنابراین دقت آن  $87/5$  درصد خواهد بود. بررسی‌های بیشتر نشان می‌دهد که در مشخصه  $F_5$  در ۲ مورد تشخیص نادرست صورت گرفته است که مربوط به عیوب AD و RD است. در مشخصه  $F_6$  فقط یک مورد از

حاصل می‌شود که تابع تبدیل اندازه‌گیری شده به ۱۰ بازه فرکانسی مساوی تقسیم شود. بنابراین پیشنهاد می‌شود استخراج مشخصه بر اساس محاسبه شاخص‌های عددی در ۱۰ بازه فرکانسی مساوی از تابع تبدیل اندازه‌گیری شده، انجام گیرد.

۲- در ANN برای هیچ شاخصی خطای داده‌های تست کمتر از ۳۰ درصد نیست. ضمن اینکه خطای اعتبارسنجی نیز همواره بالای ۱۰ درصد است. بنابراین در حل مسئله طبقه‌بندی مطرح شده در این مقاله، استفاده از ANN توصیه نمی‌شود.

جدول (۱): دقت مشخصه‌ها در تشخیص نوع عیب با احتساب بازه‌های فرکانسی مختلف (برحسب درصد)

| شاخص  | تعداد بازه‌ها |      |      |      |      |
|-------|---------------|------|------|------|------|
|       | 3             | 5    | 10   | 15   | 20   |
| $F_1$ | 80.6          | 88.9 | 91.7 | 86.1 | 83.3 |
| $F_2$ | 83.3          | 88.9 | 94.4 | 88.9 | 80.6 |
| $F_3$ | 75            | 88.9 | 91.7 | 86.1 | 80.6 |
| $F_4$ | 80.6          | 86.1 | 88.9 | 86.1 | 80.6 |
| $F_5$ | 80.6          | 88.9 | 94.4 | 88.9 | 80.6 |
| $F_6$ | 86.1          | 88.9 | 97.2 | 88.9 | 80.6 |
| $F_7$ | 86.1          | 88.9 | 97.2 | 88.9 | 80.6 |

جدول (۲): خطای حاصل از اعمال داده‌های اعتبارسنجی و تست به طبقه‌بندی کننده‌ها (برحسب درصد)

| مشخصه | نوع طبقه‌بندی کننده |      |            |      |
|-------|---------------------|------|------------|------|
|       | SVM                 |      | ANN [۲۵]   |      |
|       | اعتبارسنجی          | تست  | اعتبارسنجی | تست  |
| $F_1$ | 11.1                | 33.3 | 16.7       | 50   |
| $F_2$ | 13.9                | 50   | 19.4       | 50   |
| $F_3$ | 11.1                | 33.3 | 16.7       | 50   |
| $F_4$ | 11.1                | 50   | 19.4       | 50   |
| $F_5$ | 5.6                 | 16.7 | 13.9       | 33.3 |
| $F_6$ | 2.8                 | 16.7 | 11.1       | 33.3 |
| $F_7$ | 2.8                 | 0    | 11.1       | 33.3 |

۳- میزان خطای طبقه‌بندی برای مشخصه‌های  $F_1$  تا  $F_4$  در داده‌های تست بیش از ۳۰ درصد است. علاوه بر

روش پیشنهادی و عمومیت دادن به آن، باید داده‌های مختلفی از ترانسفورماتورهای گوناگون مورد بررسی قرار گیرد. به همین منظور داده‌های اندازه‌گیری شده از گروه دوم ترانسفورماتورها به منظور آزمایش و تأیید (راست آزمایی) روش پیشنهادی به کار گرفته می‌شود. در جدول (۳) نتایج حاصل از تست SVM برای سه مشخصه  $F_5$  تا  $F_7$  نشان داده شده است. ملاحظه می‌شود که SVM در مشخصه  $F_5$  و  $F_6$  نتوانسته است عیب RD را به درستی تشخیص دهد. در حالی که در مشخصه  $F_7$ ، تمام حالت‌های عیب به درستی تشخیص داده شده است.

جدول (۳): عملکرد مشخصه‌ها در پاسخ به داده‌های تست


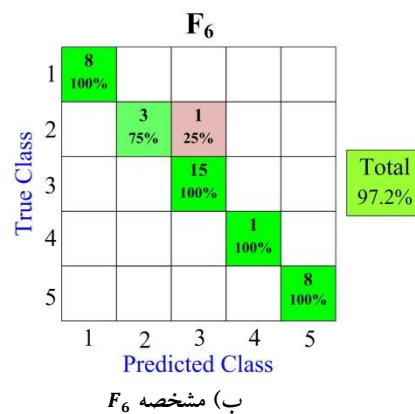

| نوع واقعی خطا | تشخیص به کمک مشخصه |       |       |
|---------------|--------------------|-------|-------|
|               | $F_5$              | $F_6$ | $F_7$ |
| AD (Case 6)   | AD                 | AD    | AD    |
| RD (Case 7)   | SC                 | DSV   | RD    |
| DSV (Case 8)  | DSV                | DSV   | DSV   |
| DSV (Case 9)  | DSV                | DSV   | DSV   |
| SC (Case 10)  | SC                 | SC    | SC    |
| DCS (Case 11) | DCS                | DCS   | DCS   |

نتایج تحلیل‌های فوق نشان می‌دهد که برای ترانسفورماتورهای بررسی شده در این تحقیق، مشخصه  $F_7$  دارای بهترین عملکرد در طبقه‌بندی عیوب سیم‌پیچ ترانسفورماتور به کمک SVM است.

## ۷. نتیجه‌گیری

با توجه به استفاده روزافزون از FRA در تشخیص عیب ترانسفورماتور و افزایش تعداد عیوبی که به کمک FRA قابل شناسایی است، ارائه روشی مطمئن برای طبقه‌بندی عیوب ضروری است. از این رو در این مقاله یکی از پرکاربردترین طبقه‌بندی‌کننده‌های هوشمند (به نام SVM) برای طبقه‌بندی عیوب مورد استفاده قرار گرفت. برای آموزش و تست SVM، ۷ مشخصه جدید ( $F_1$  تا  $F_7$ ) بر پایه همبستگی متقابل پیشنهاد شد. در مشخصه پیشنهادی، محاسبات در ۱۰ بازه فرکانسی مساوی از تابع تبدیل اندازه‌گیری شده، انجام شدند. داده‌های

عیب RD به صورت DSV تشخیص داده شده است، در حالی که در مشخصه  $F_7$  این تشخیص نادرست در مورد عیب AD (فقط یک مورد) رخ داده است.



شکل (۴): اعتبارسنجی عملکرد شاخص‌ها به کمک K-FOLD CROSS VALIDATION

با وجود نتایج خوبی که در مرحله آموزش و اعتبارسنجی مشخصه‌های  $F_5$  تا  $F_7$  حاصل شد ولی برای اثبات قابلیت‌های

## ۸. واژه‌های اختصاری

| علامت اختصاری | توضیح                       |
|---------------|-----------------------------|
| AD            | Axial Displacement          |
| ANN           | Artificial Neural Network   |
| DCS           | Deformation of Core Sheets  |
| DSV           | Disc Space Variation        |
| FRA           | Frequency Response Analysis |
| RD            | Radial Deformation          |
| SC            | Short Circuit               |
| SVM           | Support Vector Machine      |

تعارض منافع: نویسندگان اعلام می‌کنند که هیچ تعارض منافی ندارند.

لازم برای استخراج مشخصه‌ها، با انجام اندازه‌گیری‌ها بر روی ترانسفورماتورهای مختلف، در حالت سالم و همچنین حالت‌های مختلف عیب (AD، RD، DSV، SC و DCS) به دست آمدند. با اعمال مشخصه‌ها به SVM، عملکرد آن‌ها مورد ارزیابی قرار گرفت. نتیجه حاصله این بود که سه مشخصه  $F_5$ ،  $F_6$  و  $F_7$  در مقایسه با سایر مشخصه‌ها خطای کمتری دارند. از بین این‌ها نیز مشخصه  $F_7$  به ترتیب دقت ۹۷/۲ درصدی و ۱۰۰ درصدی در تشخیص داده‌های اعتبارسنجی و تست دارد. بنابراین استفاده از آن به‌عنوان یک روش قابل اطمینان در صنعت توصیه می‌شود.

## مراجع

- [1] Rahimpour E., Christian J., Feser K., Mohseni H., "Transfer function method to diagnose axial displacement and radial deformation of transformer winding", IEEE Transaction on Power Delivery, 18(2):493-505, 2003.
- [2] IEEE Guide for the Application and Interpretation of Frequency Response Analysis for Oil-Immersed Transformers, IEEE Std C57.149, 2012.
- [3] IEC Standard on Power Transformers, Part 18: Measurement of Frequency Response, IEC 60076-18, 2012.
- [4] Abu-Siada A., Mosaad M. I., Kim D. W., El-Naggar M., F., "Estimating Power Transformer High frequency Model Parameters using Frequency Response Analysis", IEEE Transactions on Power Delivery (Early Access), 2020.
- [5] Samimi M. H., Hillenbrand P., Tenbohlen S., Akmal A. A. S., Mohseni H., Faiz J., "Investigating the applicability of the finite integration technique for studying the frequency response of the transformer winding", International journal of Electrical Power and Energy Systems, 110:411-418, 2019.
- [6] Jianqiang N., Zhongyong Z., Shan T., Yu C., Chenguo Y., Chao T., "The actual measurement and analysis of transformer winding deformation fault degrees by FRA using mathematical indicators", Electric Power Systems Research, 184:1-11, 2020.
- [7] Zhao X., Yao C., Zhou Z., Li C., Wang X., Zhu T., Abu-Siada A., "Experimental Evaluation of Transformer Internal Fault Detection Based on V-I Characteristics", IEEE Transactions on Industrial Electronics, 67(5):4108-4119, 2020.
- [8] Shamlou A., Feyzi M. R., Behjat, V., "Interpretation of frequency response analysis of power transformer based on evidence theory", IET Generation, Transmission & Distribution, 13(17):3879-3887, 2019.
- [9] Samimi M. H., Tenbohlen S., Akmal A. A. S., Mohseni H., "Evaluation of numerical indices for the assessment of transformer frequency response", IET Generation, Transmission & Distribution, 11(1): 218-227, 2017.
- [10] Behjat V., Mahvi M., "Statistical approach for interpretation of power transformers frequency response analysis results", IET Science, Measurement & Technology, 9(3): 367-375, 2015.
- [11] Pourhossein K., Gharehpetian G. B., Rahimpour E., Araabi B. N., "A Probabilistic Feature to Determine Type and Extent of Winding Mechanical Defects in Power Transformers", Electric Power Systems Research, 82:1-10, 2012.
- [12] Ghanizadeh A. J., Gharehpetian G. B., "Application of Characteristic Impedance and Wavelet Coherence Technique to Discriminate Mechanical Defects of Transformer Winding", Electric Power Components and Systems, 41:868-878, 2013.
- [13] Rahbarimaghham H., Esmaeili S., Gharehpetian G. B., "Discrimination between Radial Deformation and Axial Displacement in Power Transformers Using Analysis of Electromagnetic Waves", IEEE Sensors Journal, 17(16):5324-5331, 2017.

- [14] Pourhossein K., Gharehpetian G. B., Rahimpour E., Araabi B. N., "A Vector-based Approach to Discriminate Radial Deformation and Axial Displacement of Transformer Winding and Determine Defect Extent", *Electric Power Components and Systems*, 40:597-612, 2012.
- [15] Karimifard P., Gharehpetian G. B., Ghanizadeh A. J., "Estimation of simulated transfer function to discriminate axial displacement and radial deformation of transformer winding", *COMPEL: The International Journal for Computation and Mathematics in Electrical and Electronic Engineering*, 31(4):1277-1292, 2012.
- [16] Rahimpour E., Jabbari M., Tenbohlen S., "Mathematical Comparison Methods to Assess Transfer Functions of Transformers to Detect Different Types of Mechanical Faults", *IEEE Transactions on Power Delivery*, 25(4): 2544-2555, 2010.
- [17] Abbasi A. R., Mahmoudi M. R., Avazzadeh Z., "Diagnosis and Clustering of Power Transformer Winding Fault Types by Cross-Correlation and Clustering Analysis of FRA Results", *IET Generation, Transmission & Distribution*, 12(19): 4301-4309, 2018.
- [18] Bigdeli M., Azizian D., Gharehpetian G. B., "Detection of Probability of Occurrence, Type and Severity of Faults in Transformer Using Frequency Response Analysis Based Numerical Indices", *Measurement*, 168:108322, 2021.
- [19] Bigdeli M., Vakilian M., Rahimpour E., "A Probabilistic Neural Network Classifier Based Method for Transformer Winding Fault Identification through its Transfer Function Measurement", *International Transactions on Electrical Energy Systems*, 23(3), 2013.
- [20] Bigdeli M., Vakilian M., Rahimpour E., "Transformer Winding Faults Classification Based on Transfer Function Analysis by Support Vector Machine", *IET Electric Power Applications*, 6(5), 2012.
- [21] Bagheri S., Moravej Z., Gharehpetian G. B., "Classification and Discrimination among Winding Mechanical Defects, Internal and External Electrical Faults, and Inrush Current of Transformer", *IEEE Transactions on Industrial Informatics*, 14(2): 484-493, 2018.
- [22] Zhao Z., Yao C., Tang C., Li C., Yan F., Islam S., "Diagnosing Transformer Winding Deformation Faults Based on the Analysis of Binary Image Obtained From FRA Signature", *IEEE Access*, 7:40463-40474, 2019.
- [23] Liu J., Zhao Z., Tang C., Yao C., Li C., Islam S., "Classifying Transformer Winding Deformation Fault Types and Degrees using FRA based on Support Vector Machine", *IEEE Access*, 7:112494-112504, 2019.
- [24] Tarimoradi H., Gharehpetian G. B., "A Novel Calculation Method of Indices to Improve Classification of Transformer Winding Fault Type, Location and Extent", *IEEE Transactions on Industrial Informatics*, 13(4):1531-1540, 2017.
- [25] Ghanizadeh A. J., Gharehpetian G. B., "ANN and Cross-correlation based Features for Discrimination between Electrical and Mechanical Defects and their Localization in Transformer Winding", *IEEE Transactions on Dielectrics and Electrical Insulation*, 21(5): 2374-2382, 2014.
- [26] Haykin S., "Neural Networks and Learning Machines Third Edition", Pearson, Prentice Hall publication, 2009.
- [27] Vapnik V. N., "Statistical Learning Theory", Wiley Publication, 1998.
- [28] Wu X., Kumar V., Quinlan J. R., Ghosh J., Yang Q., Motoda H., McLachlan G. J., Ng A. F. M., Liu B., Yu P. S., Zhou Z.-H., Steinbach M. S., Hand D. J., Steinberg D., "Top 10 algorithms in data mining", *Knowledge and Information Systems*, 14(1): 1-37, 2008.
- [۲۹] شیخان م.، جعفری‌نسب ز.، «آموزش شبکه عصبی مصنوعی با نسخه آشوب‌گونه الگوریتم جستجوی گرانشی و کاربرد آن در پیش‌بینی آلاینده‌های هوا: مطالعه قیاسی» مجله محاسبات نرم، جلد ۵، شماره ۲، ص. ۶۵-۸۱، ۱۳۹۵.
- [۳۰] وثیقی‌ذاکرا ا.، جلیلی س.، «پیش‌بینی ژن‌های بیماری با استفاده از دسته‌بند تک‌کلاسی ماشین بردار پشتیبان» مجله محاسبات نرم، جلد ۴، شماره ۱، ص. ۷۴-۸۳، ۱۳۹۴.
- [۳۱] ویسی ه.، قایدشرف ح.، ابراهیمی م.، «بهبود کارایی الگوریتم‌های یادگیری ماشین در تشخیص بیماری‌های قلبی با بهینه‌سازی داده‌ها و ویژگی‌ها»، جلد ۸، شماره ۱، ص ۸۵-۷۰، ۱۳۹۸.