



Available in:
Journal.isrc.ac.ir

Journal of
Space Science, Technology
& Applications (Persian)

Vol. 3, No. 2, pp.: 1-12
2024

DOI:
10.22034/jssta.2023.348730.1088

Article Info

Received: 2022-6-26
Accepted: 2023-2-20

Keywords

Remaining useful lifetime estimation, Semiconductor devices, Neural Network, Failure diagnostic

How to Cite this article

Reza Amjadifard, Farhad Bagheroskouei, "Reliability Assessment of Power Electronic Converters Using Replicator Neural Networks", *Journal of Space Science, Technology and Applications*, vol 3 (2), p.: 1-12, 2024.

Reliability Assessment of Power Electronic Converters Using Replicator Neural Networks

Reza Amjadifard^{*1}, Farhad Bagheroskouei²

1,* Satellite Research Institute, Iranian Space Research Center, Tehran, Iran,
r.amjadifard@isrc.ac.ir, Corresponding author
2 Satellite Research Institute, Iranian Space Research Center, Tehran, Iran
f.bagheroskouei@isrc.ac.ir

Abstract

Reliability assessment of power converters is extremely important due to the degradation of the converter performance under the thermal and electrical stresses. The normal or abnormal operation of a converter is determined based on the quality of the manufacturing process and the environmental and operating conditions. The failure indices are based on the previous failures data which are calculated using the history of the main parameter of the converter which are strongly affected by the aging process. In this article, a new real-time indicator is introduced using the monitoring of the main parameters of the converter. Each indicator is modeled using Replicator Neural Network (RNN) and the network reconstruction coefficient or reconstruction error will be considered as the reliability index or the coefficient of anomaly of the converter. In fact, the reliability assessment is based on the comparison between a reference model of the converter in normal conditions and the estimation of abnormal operation of the converter in the future. In the proposed method, a normal distribution function on the reconstructed error signal, their fit and percentage distance are introduced as the abnormality risk coefficient. The advantages of this method include taking into account all the uncertainties in the process of Manufacturing the power switch and its working conditions, not needing the aging test process in preparing the failure data and taking into account all the failures

ارزیابی قابلیت اطمینان مبدل‌های الکترونیک قدرت مبتنی بر شبکه‌های عصبی تکثیر کننده

رضا امجدی فرد^{۱*}، فرهاد باقراسکویی^۲

۱. *، استادیار، پژوهشکده سامانه های ماهواره، پژوهشگاه فضایی ایران، تهران، ایران - r.amjadifard@isrc.ac.ir
(نویسنده مسئول)

۲. مربی، پژوهشکده سامانه های ماهواره، پژوهشگاه فضایی ایران، تهران، ایران - f.bagheroskouei@isrc.ac.ir



دسترس پذیر در نشانی:
Journal.isrc.ac.ir

دو فصلنامه
علوم، فناوری و
کاربردهای فضایی

سال سوم، شماره ۲، صفحه ۱۲-۱
پاییز و زمستان ۱۴۰۲

چکیده

سنجش قابلیت اطمینان مبدل‌های الکترونیک قدرت به دلیل عملکرد آنها تحت تنش‌های حرارتی و الکتریکی، به شدت اهمیت داشته و نیازمند کمی‌سازی است. عملکرد هنجار یا ناهنجار یک مبدل بر اساس شرایط محیطی، ساخت و بهره‌برداری تعیین می‌شود. شاخص‌های خرابی فعلی تنها مبتنی بر داده‌های خرابی‌های قبلی بوده و بر اساس اطلاعات تاریخیچه عملکرد مبدل محاسبه می‌شوند که فرایند پیرشدگی به شدت بر آنها اثرگذار است. در این مقاله، با کمک داده‌های حاصل از پایش وضعیت مبدل به صورت زمان واقعی، شاخصی جدید معرفی می‌شود. هر مبدل با استفاده از شبکه‌های عصبی تکثیرکننده مدل‌سازی شده و ضریب بازسازی شبکه یا خطای بازسازی به عنوان شاخص پایایی یا ضریب ناهنجاری مبدل لحاظ خواهد شد. در حقیقت، سنجش قابلیت اطمینان مبتنی بر قیاس بین یک مدل مرجع از شرایط سلامت مبدل و عملکرد ناهنجار آن در آینده صورت می‌پذیرد. در روش پیشنهادی، یک تابع توزیع نرمال بر روی سیگنال خطای بازسازی شده، برازش و درصد فاصله آنها به عنوان ضریب ریسک ناهنجاری معرفی می‌شود. مزایای این روش عبارتند از لحاظ نمودن تمامی عدم قطعیت‌ها در فرایند ساخت کلید قدرت و شرایط کاری آن، عدم نیاز به فرایند آزمون پیرشدگی در تهیه داده خرابی و لحاظ نمودن تمامی خرابی‌ها.

DOI:

10.22034/jssta.2023.348730.1088

تاریخچه داوری

دریافت: ۱۴۰۱/۰۴/۰۵

پذیرش: ۱۴۰۱/۱۲/۰۱

واژه‌های کلیدی

تخمین طول عمر مفید باقیمانده،
کلیدهای قدرت نیمه هادی،
شبکه‌های عصبی، تشخیص
ناهنجاری

نحوه استناد به این مقاله

رضا امجدی فرد، فرهاد باقراسکویی،
"ارزیابی قابلیت اطمینان مبدل‌های
الکترونیک قدرت مبتنی بر شبکه‌های
عصبی تکثیر کننده"، *دوفصلنامه علوم،
فناوری و کاربردهای فضایی*، جلد سوم،
شماره دوم، صفحات ۱۲-۱، ۱۴۰۲.

۱- مقدمه


مبدل‌های الکترونیک قدرت، در طیف وسیعی از کاربردها نظیر خودروهای برقی، منابع انرژی تجدیدپذیر، درایوهای الکتریکی، سیستم‌های کشتی، کاربردهای فضایی و دفاعی و سیستم‌های قدرت انعطاف‌پذیر مورد استفاده قرار می‌گیرند [۱]. این مبدل‌ها غالباً در محیط‌های کاری سخت در حال بهره‌برداری هستند و این موضوع سبب شده تا تحت تاثیر انواع تنش‌های حرارتی، لرزش و میدان‌های الکتریکی قرار بگیرند و دچار خطای عملکرد و خرابی‌های متعدد شوند [۲]. از این‌رو، سنجش پیوسته پایایی یا قابلیت اطمینان این مبدل‌ها به منظور برنامه‌ریزی موثر برای تعمیرات و نگهداری پیشگویانه و پیشگیرانه به شدت حائز اهمیت بوده و نیاز است شاخص‌های دقیق و کارا به این منظور معرفی شوند. طبق تعریف، قابلیت اطمینان یک سیستم بر اساس توانایی آن سیستم برای عملکرد مشخص بدون خرابی تعیین می‌شود. این تعریف توسط شاخص‌های متعددی نظیر متوسط زمان بین خرابی ($MTBF^1$)، متوسط زمان تا تعمیر ($MTTR^2$)، در دسترس بودن و دیگر شاخص‌ها کمی‌سازی شده است. این شاخص‌ها همگی مبتنی بر داده‌های خرابی گذشته هستند که برای بسیاری از سیستم‌ها، دستیابی به منابع داده خرابی می‌تواند زمان‌بر و هزینه‌بر باشد [۳]. از سویی، این شاخص‌ها، تنها به عنوان پارامتری برای سنجش قابلیت اطمینان سیستم می‌توانند مورد استفاده قرار بگیرند و در سنجش کارایی استاتیکی و دینامیکی سیستم هیچ اثربخشی و کاربردی نخواهند داشت. همچنین، این شاخص‌ها هیچ‌گونه تفکیکی بین انواع خرابی‌ها قائل نیستند و هیچ دید مشخصی را نسبت به شدت و ضعف خرابی‌ها و اهمیت آنها ارائه نمی‌دهند [۴].

با ورود به نسل چهارم صنعت و اهمیت یافتن سیستم‌های مبتنی بر داده‌های پایش وضعیت در کاربردهای صنعتی، لازم است تا تغییر و تحول مشخصی در حوزه تعاریف قابلیت اطمینان ایجاد شود. به جای آنکه تعریف و شاخص‌های ارزیابی قابلیت اطمینان تنها بر داده‌های خرابی استوار باشند، لازم است این شاخص‌ها هرگونه عملکرد ناهنجار سیستم را نیز در نظر بگیرند؛ چراکه هر عمل ناهنجاری می‌تواند زمینه‌سازی یک خرابی و خطا

شود [۵]. نکته دیگر آن است که شاخص‌های ارزیابی قابلیت اطمینان مبدل‌های الکترونیک قدرت باید به صورت زمان واقعی قابل به‌روزرسانی و استفاده باشند و به داده‌های خرابی‌های گذشته حداقل وابستگی را داشته باشند. همچنین، شاخص‌های این حوزه باید بتوانند بین انواع خرابی‌ها و منشاء آنها تفکیک قائل شوند و اطلاعات کاربردی را در اختیار بهره‌بردار سیستم قرار دهند [۶]. در انتها نیز این شاخص‌ها باید هم عملکرد استاتیکی و هم عملکرد دینامیکی را تحلیل و کمی‌سازی نمایند. این قابلیت‌ها با استفاده از ابزارهای تحلیل داده و داده‌کاوی دست‌یافتنی هستند. در حال حاضر، مدل‌سازی هر سیستم فیزیکی با استفاده از داده‌های وضعیت آن امکان‌پذیر است. در حقیقت، پارامترهای کارایی هر سیستم موید رفتار آن سیستم در شرایط دینامیکی و استاتیکی هستند و چنانچه این داده‌ها در اختیار الگوریتم‌های تحلیل داده قرار بگیرند، امکان مدل‌سازی سیستم را فراهم خواهند آورد. به منظور ارائه یک شاخص بهینه برای ارزیابی و سنجش قابلیت اطمینان یک مبدل الکترونیک قدرت، لازم است تا پارامترهای کارایی آن را به صورت زمان واقعی رصد نموده و برای مدل‌سازی در اختیار یک الگوریتم تحلیل داده قرار دهیم [۷].

در ساختار مبدل‌های الکترونیک قدرت، انواع المان‌های پس‌یو و اکتیو در شرایط کاری مختلف مورد استفاده قرار می‌گیرند. طبق آمارهای تحلیلی از کاربردهای مختلف مبدل‌های الکترونیک قدرت، بالای ۸۰ درصد علت خرابی مبدل‌های الکترونیک قدرت ناشی از دو عنصر خازن (عنصر پس‌یو) و کلیدهای قدرت نیمه‌هادی (عنصر اکتیو) بوده و از این‌رو سنجش قابلیت اطمینان یک مبدل می‌تواند تنها بر اساس رفتارهای ناهنجار این دو عنصر انجام پذیرد [۸]. کلیدهای قدرت نیمه‌هادی نظیر IGBT و MOSFET به تنش‌های حرارتی حساس بوده و احتمال بروز خطا و خرابی در عملکردشان افزایش می‌یابد [۹]. به منظور رصد عملکرد این دو المان می‌توان به ترتیب پارامترهایی نظیر ولتاژ کلکتور-امیتر و مقاومت حالت وصل را مدنظر قرار داد. در مبدل‌های الکترونیک قدرت، سه نوع خازن E-Caps، MPPF و MLC-Caps به طور غالب استفاده می‌شوند [۱۰]. برای خازن‌ها نیز به طور غالب دو پارامتر ظرفیت

شاخص قابلیت اطمینان پیشنهادی کفایت می‌نماید. به منظور سهولت در پیاده‌سازی و محاسبه شاخص‌های قابلیت اطمینان، تنها کلیدهای نیمه‌هادی و آن هم کلید نیمه‌هادی IGBT در این مقاله مد نظر قرار گرفته است. طبق شکل ۱، تنش‌های حرارتی، لرزش و میدان‌های الکتریکی به عنوان مهم‌ترین دلایل بروز خرابی در مبدل‌های الکترونیک قدرت هستند و لازم است تا با معرفی شاخص‌های رصد ناهنجاری، این مقوله‌ها رصد شوند [۱۶].



شکل ۱. عوامل غالب ایجاد خرابی در مبدل‌های الکترونیک قدرت

تنش‌های حرارتی به دو دلیل در ساختار کلیدهای قدرت ایجاد می‌شوند که عبارتند از: (۱) افزایش دمای ناشی از تلفات کلیدزنی و (۲) افزایش دمای ناشی از شرایط محیطی. افزایش دما در نهایت سبب پیرشدگی شده و روند فرسایش کلید را تشدید می‌کند. افزایش متوسط دمای پیوند و نوسانات آن دو عامل اصلی ایجاد پیرشدگی و خرابی هستند که با وجود ساختار لایه‌ای کلید و تفاوت در ضرایب انبساط حرارتی^۲ و نرخ گرادیان انباشت دما^۳، موجب تسریع در فرایند خرابی خواهند شد [۱۷]. افزایش متوسط دمای پیوند و بازه تغییرات دما، دو پارامتر کلید هستند که می‌توانند شدت فرایند پیرشدگی را مشخص کنند. نکته حائز اهمیت این است که در این مقاله رویکرد اصلی بر روی ارتقای قابلیت اطمینان بوده و از این‌رو خرابی‌هایی بررسی می‌شوند که با انباشت خرابی در کلید همراه هستند، یعنی وقوع آنها سریع یا گذرا نیست. خطاها و خرابی‌های سریع در دسته حفاظت قرار گرفته و از حیطه این مقاله خارج هستند. در ادامه، مهم‌ترین پارامترهای کارایی کلید نیمه‌هادی بررسی شده و از بین آنها بهترین پارامتر برای رصد وضعیت کلید IGBT تعیین می‌شود.

خازنی و مقاومت سری معادل به منظور پایش وضعیت این المان استفاده می‌شوند [۱۱]. برای مدل‌سازی رفتار مبدل نیز از الگوریتم شبکه‌های عصبی تکثیر کننده^۱ (RNN) استفاده خواهد شد. در این الگوریتم، پارامترهای کارایی مبدل به عنوان هم ورودی و هم خروجی به شبکه اعمال می‌شوند و شبکه عصبی مذکور اقدام به بازسازی رفتار مبدل می‌نماید [۱۲]. این بازسازی در شرایط هنجاریا نرمال مبدل صورت خواهد پذیرفت و به نحوی موید شرایط سلامت مبدل خواهد بود. از این به بعد، هر بار که پارامترهای کلید به صورت برخط نمونه‌برداری می‌شوند، از مدل توسعه داده شده عبور خواهند نمود و مجدد رفتار مبدل بازسازی می‌شود و چنان‌چه اندازه‌گیری‌های جدید با مدل انطباق کمتری داشته باشند، خطای بازسازی مدل افزایش خواهد یافت که خود به نحوی بیان کننده بروز رفتارهای ناهنجار در عملکرد مبدل است [۱۳]. خطای بازسازی توسط تابع توزیع نرمال قابل مدل‌سازی است. عدم انطباق با تابع توزیع نرمال، به عنوان شاخص قابلیت اطمینان تعریف می‌شود.

در این مقاله، یک ضریب جدید به منظور کمی‌سازی فرایند ارزیابی قابلیت اطمینان مبدل‌های الکترونیک قدرت ارائه شده است. این شاخص مبتنی بر داده‌های پایش وضعیت بوده و به صورت زمان واقعی قابل تعریف است و می‌تواند عملکرد دینامیکی و استاتیکی مبدل را نیز مشخص نماید. هم‌چنین، در این مقاله تمرکز بر روی کلیدهای قدرت است. مباحث مطرح شده ساختار مقاله به این صورت است که در بخش دوم، پارامترها و المان‌های لازم برای محاسبه شاخص قابلیت اطمینان معرفی خواهند شد. در بخش سوم، الگوریتم شبکه عصبی تکثیر کننده و خطای بازسازی معرفی شده و در بخش چهارم، نتایج شبیه‌سازی و در پایان نیز نتیجه‌گیری ارائه می‌شود.

۲- سنجش پارامترهای کارایی مبدل‌های الکترونیک قدرت

دو المان خازن و کلیدهای قدرت نیمه‌هادی، دلیل بالای ۷۰ درصد از خرابی‌های مبدل‌های الکترونیک قدرت هستند [۱۴، ۱۵]. از این‌رو، لحاظ نمودن این دو المان برای محاسبه

3 Nonlinear Temperature Gradient

1 Replicator Neural Network

2 Coefficient of Thermal Expansion

و الکترون) به دام افتاده در لایه اکسید کلید افزایش می‌یابد و این موضوع سبب افزایش ولتاژ آستانه می‌شود.


۲-۳- زمان خاموش شدن کلید

وقوع پیرشدگی در کلیدهای قدرت IGBT سبب افزایش امیدانس حرارتی شده و در نتیجه زمان بازگشت حامل‌های اقلیت افزایش یافته و همین امر در نهایت منجر به افزایش زمان خاموش شدن کلید می‌شود [۲۰]. افزایش زمان خاموش شدن کلید می‌تواند متناظر با وقوع پدیده روشن شدن ترستورهای پارازیتی (یا همان پدیده قفل‌شدگی) و افزایش جریان کلکتور ناشی از شروع شکست لایه اکسید باشد.

۲-۴- منحنی ولتاژ-جریان کلید

وقوع فرایند پیرشدگی سبب می‌شود تا منحنی ولتاژ-جریان خروجی کلید IGBT به سمت بالا شیفیت پیدا کند (با فرض اینکه ولتاژ گیت-امیتر دارای دامنه بالایی باشد، به عنوان مثال بالای ۱۰ ولت) و در نتیجه این تغییر، به ازای یک ولتاژ گیت-امیتر و کلکتور-امیتر مشخص در ناحیه خطی عملکرد کلید، دامنه جریان کلکتور بیش‌تر خواهد شد. اما برای ولتاژهای کمتر گیت-امیتر، مقدار جریان کلکتور برای کلید IGBT دچار پیرشدگی، دارای دامنه کم‌تری خواهد بود [۲۱].

در این مقاله و به منظور رصد وضعیت کلید قدرت IGBT، از ولتاژ کلکتور-امیتر و سیگنال کلیدزنی استفاده می‌شود. در حقیقت، رفتار کلید قدرت IGBT بر اساس پالس‌های ورودی گیت و شکل موج‌های پارامترهای خروجی آن نظیر ولتاژ کلکتور-امیتر، جریان کلکتور و ولتاژ گیت-امیتر قابل تفسیر بوده که یک نمونه مشخصه کلیدزنی آن در شکل ۳ ارائه شده است. تغییرات دامنه، فرکانس و فاز پارامترها و همچنین زمان‌های خاموش و روشن شدن، در ۶ فاز مشخص شده در شکل ۳، بهترین معیار برای رصد نمودن عملکردهای ناهنجار است.



شکل ۲. ساختار داخلی کلید قدرت از نوع IGBT

۲-۱- ولتاژ حالت وصل یا ولتاژ اشباع کلکتور-امیتر

یکی از مدهای خرابی، وقوع شرایط مدار باز ناشی از وقوع مکانیزم‌هایی نظیر شکاف^۱ و جداسازی سیم‌های اتصال^۲، ایجاد حفره یا ورق ورق شدگی چپ است و بهترین راه تشخیص آن ولتاژ حالت وصل کلکتور-امیتر است [۱۸]. وقوع فرایند پیرشدگی ناشی از تنش‌های حرارتی منجر به افت ولتاژ کلکتور-امیتر می‌شود. در حقیقت زمانی که دمای پیوند کلید افزایش می‌یابد، میزان تمرکز و جمع‌شدگی حامل‌های ذاتی در ساختار کلید در اطراف پیوند افزایش یافته و همین امر سبب کاهش افت ولتاژ پیوند می‌شود. خرابی ناشی از روشن شدن ترستور پارازیتی درونی کلید IGBT نیز به علت تنش‌های حرارتی، یک خرابی متداول بوده که توسط این ولتاژ قابل تشخیص است. در حقیقت، افزایش دمای پیوند کلید سبب می‌شود تا جریانی که در آن پدیده قفل‌شدگی^۳ رخ می‌دهد، کاهش یابد و این موضوع سبب افزایش احتمال بروز این پدیده می‌شود.

۲-۲- ولتاژ آستانه گیت امیتر


یکی دیگر از مدهای خرابی وقوع اتصال کوتاه بوده که می‌تواند سبب از دست رفتن کلید، افزایش جریان نشتی گیت و شکست عایقی دی‌الکتریک شود. بهترین پارامتر برای تشخیص آن، رصد ولتاژ آستانه گیت است [۱۹]. به طور نرمال، باید با افزایش دمای پیوند، مقدار ولتاژ آستانه کلید کاهش یابد. وقوع پیرشدگی در کلید IGBT همراه با فرسایش لایه اکسید کلید است که به تبع آن ولتاژ آستانه گیت-امیتر افزایش می‌یابد. در حقیقت با شروع روند پیرشدگی، درصد بارهای الکتریکی (حفره

3 Latch-up

1 Crack


2 Bondwire

مبنای تشخیص ناهنجاری‌ها در عملکرد آن خواهد بود. در ادامه، هر واحد داده جدیدی که وارد شبکه عصبی آموزش دیده شده و در لایه خروجی به خوبی بازسازی شود، هنجار است و داده‌هایی که فاصله بین مقادیر اصلی آن در لایه ورودی و مقادیر بازسازی شده آن در لایه خروجی زیاد باشد به عنوان داده ناسازگار تلقی خواهد شد. در واقع، قدر مطلق خطای بازسازی به عنوان رتبه ناهنجاری مورد استفاده قرار می‌گیرد.



شکل ۴. ساختار نمونه شبکه عصبی تکثیرکننده

ساختار شبکه عصبی RNN به صورت Feed-Forward Multi-Layer Perceptron بوده و دارای سه لایه میانی محصور مابین لایه‌های ورودی و خروجی است. لایه‌های ورودی و خروجی دارای تعداد نورون‌های برابر با تعداد ویژگی‌های ورودی هستند. این ساختار پس از آنکه با استفاده از داده‌های حالت نرمال آموزش‌یافت، برای هر نمونه داده جدید، معیار ناهنجار بودن را در قالب خطای بازتولید محاسبه می‌نماید و هر چه این خطا بیش‌تر باشد، احتمال ناهنجار بودن داده نیز افزایش می‌یابد. در حقیقت، پس از آموزش مدل، هر چه داده‌های ورودی به حالت نرمال نزدیک‌تر باشد، مدل آنها را بهتر بازتولید می‌کند و این به معنای پایین بودن خطای باز تولید است. برای ایجاد شبکه عصبی مورد نظر، فرض می‌کنیم که n ویژگی در داده‌های آموزش وجود دارد و در نتیجه لایه ورودی دارای n نورون است. انتخاب تعداد نودها (گره‌ها) یا نورون‌های موجود در هر لایه میانی به صورت تجربی بوده و لازم است به قسمی انتخاب شوند که میانگین خطای بازتولید به ازای داده‌های آموزش حداقل شود. خروجی نورون k ام از لایه k ام بر حسب ورودی‌ها و ضرایب وزنی به صورت معادله زیر است:



شکل ۳. منحنی خاموش و روشن شدن کلید قدرت IGBT

۳- شبکه عصبی تکثیردهنده

یکی از رویکردهای اخیر در تشخیص عملکردهای ناهنجار در سیستم‌های مکانیکی و الکتریکی، مدل‌سازی عملکرد سیستم در شرایط سالم و سپس استفاده از آن برای سنجش و تشخیص حالت‌های ناهنجار است [۲۲]. در این رویکرد، فرض می‌شود که سیستم مورد مطالعه در ابتدای بهره‌برداری یا پس از تعمیرات اساسی، دارای شرایط نرمال و سالم بوده و سپس از داده‌های عملکردی آن برای مدل‌سازی رفتار استفاده می‌شود. مدل استخراج شده به صورت مداوم با داده‌های آتی نمونه‌برداری شده مقایسه شده و به هر نمونه یک نمره خرابی داده می‌شود [۲۳]. در این رویکرد نیازی به داده‌های خرابی‌های قبلی سیستم نیست و صرفاً شرایط سالم یا نرمال آن مبنای تصمیم‌گیری در خصوص شرایط خرابی و محاسبه شاخص‌های قابلیت اطمینان است. در این مقاله، روش استفاده شده شبکه‌های عصبی تکثیرکننده بوده که در آن بردارهای ورودی به عنوان بردارهای خروجی نیز استفاده می‌شوند و الگوریتم RNN برای باز تولید الگوهای ورودی در خروجی مورد استفاده قرار می‌گیرند [۲۴]. ساختار نوعی یک نمونه شبکه عصبی RNN در شکل ۴ ارائه شده است.

ساختار الگوریتم RNN به این صورت است که با دریافت هر ورودی سعی می‌کند تا با استخراج الگوها و روابط بین ورودی‌ها، همان روابط را در خروجی خود باز تولید نماید به قسمی که حداقل خطای باز تولید را در پی داشته باشد. در این صورت، هر چه الگوهای ورودی متداول‌تر باشند، در خروجی بهتر بازتولید می‌شوند و مدل سیستم دقیق‌تر خواهد بود. در نهایت این شبکه عصبی یک مدل از سیستم را ارائه خواهد داد که

سبب می‌شود تا داده‌های ورودی به صورت خوشه‌هایی تفکیک شوند که داده‌های سالم ورودی به صورت غالب در خوشه‌های مشخصی قرار بگیرند و از این‌رو می‌توانند از داده‌های ناهنجار تمیز داده شوند. انتخاب تعداد خوشه‌های لایه میانی یا همان پارامتر N بسیار کلیدی است. در خصوص تابع فعال‌سازی انتخاب شده برای لایه خروجی نیز، در این مقاله از تابع Sigmoid استفاده شده است.

$$S_5(I_{ki}) = \frac{1}{1 + e^{-a_5 I_{ki}}} \quad (4)$$

پس از مدل‌سازی شبکه عصبی، باید برای هر نمونه یک ضریب ناهنجاری تعریف کنیم. ضریب ناهنجاری برای آامین نمونه به صورت متوسط خطای بازتولید تمامی ویژگی‌ها به صورت زیر محاسبه می‌شود:

$$OF_i = \frac{1}{n} \sum_{j=1}^n (x_{ij} - o_{ij})^2 \quad (5)$$

که در آن n تعداد ویژگی‌های ورودی است. در این مقاله نورون‌های هر لایه به صورت آزمون و خطا (تجربی) انتخاب می‌شوند. پس از محاسبه خطای بازسازی، به ازای هر سیکل نمونه‌برداری از داده‌های اندازه‌گیری از مبدل الکترونیک قدرت، باید شاخص‌های پایایی بر اساس این پارامتر محاسبه شوند. اولین شاخص با عنوان ریسک ناهنجاری (RoA) شناخته می‌شود و برابر است با مقدار نرمالیزه شده خطای بازسازی بر حسب درصد. هر قدر این پارامتر بیش‌تر باشد، احتمال وقوع ناهنجاری نیز بیش‌تر خواهد بود. برای هر مبدل، این پارامتر دارای آستانه‌ای متفاوت است. پارامتر بعدی، نرخ وقوع ناهنجاری (AR) است و به صورت تعداد ناهنجاری در k نمونه قبل تعریف می‌شود (در این مقاله k برابر با تعداد نمونه‌های هر سیکل کلیدزنی است). این پارامتر به معنای تعداد ناهنجاری‌های به وقوع پیوسته در یک بازه زمانی مشخص است. بر اساس دو پارامتر معرفی شده، یعنی شاخص‌های نرخ وقوع ناهنجاری (AR_k) و ریسک ناهنجاری (RoA) می‌توان شاخص قابلیت اطمینان پیشنهادی را برای ارزیابی برخط شرایط مبدل طبق فرمول زیر محاسبه نمود:

$$\text{شاخص قابلیت اطمینان پیشنهادی} = \frac{1}{RoA \times (1 + AR_k)} \quad (6)$$

$$I_{ki} = \sum_{j=0}^{l_{k-1}} w_{kij} y_{(k-2)j} \quad (1)$$


که در آن y_{kj} خروجی نورون k ام از لایه k ام، w_{kij} ضریب وزنی گذر از نورون k ام به نورون $k-1$ ام، l_{k-1} تعداد نورون‌ها در لایه k ام و I_{ki} مجموع وزنی ورودی‌ها به نورون k ام از لایه k ام هستند. برای دو لایه بیرونی از لایه‌های میانی، تابع فعال‌سازی به صورت زیر فرض می‌شود:

$$F_k(I_{ki}) = \tanh(a_k I_{ki}) \quad k = 2 \text{ and } 4 \quad (2)$$

که در آن $a_k I_{ki}$ پارامتر تنظیم بوده که در این مقاله برابر یک در نظر گرفته می‌شود. اما برای تابع فعال‌سازی لایه وسطی در لایه‌های میانی، به صورت یک تابع پلکانی با تعداد N سطح به صورت زیر لحاظ می‌شود:

$$F_k(I_{ki}) = 0.5 + \frac{1}{2(k-1)} \sum_{j=1}^{N-1} \tanh \left[a_k \left(I_{ki} - \frac{j}{N} \right) \right] \quad \text{for } k = 3 \quad (3)$$


که در آن پارامتر a_k برای کنترل سرعت (نرخ) گذار از یک لایه به لایه دیگر است که در این مقاله مقدار بزرگ نظیر ۱۰۰ برای آن فرض شده و با فرض $N = 4$ ، تابع فعال‌سازی به صورت شکل ۵ و سطوح فعال‌سازی لایه‌های میانی به N سطح گسسته به صورت $0, \frac{1}{N-1}, \frac{2}{N-1}, \dots, 1$ خواهد بود.



شکل ۵. ساختار پلکانی تابع فعال‌سازی لایه میانی شبکه عصبی RNN

علت انتخاب ساختار پلکانی برای تابع فعال‌سازی لایه میانی آن است که داده‌های دارای توزیع پیوسته را به تعدادی بردارهای گسسته تقسیم‌بندی نماییم تا از این طریق، فرایند فشرده‌سازی داده امکان‌پذیر شود. این ساختار پلکانی برای تابع فعال‌سازی

آموزش شبکه عصبی مورد نظر از الگوریتم Back-Propagation استفاده شده و در هر بار اجرای الگوریتم، داده‌های مربوط به یک سیکل کامل کلیدزنی^۱ به عنوان ورودی الگوریتم شبکه عصبی ارائه خواهد شد تا وزن‌های اتصالات را از طریق کمینه‌سازی خطای بازآفرینی تصحیح و تنظیم نماید. تعداد تکرارهای آموزش^۲ نیز برابر ۱۰۰ لحاظ می‌شود. داده‌های ورودی به دو قسمت آموزش و تست تقسیم شده و پس از اجرای فرایند آموزش به کمک داده‌های فوق، شبکه آموزش دیده شده توسط داده‌های تست، مورد ارزیابی قرار خواهد گرفت. در شکل ۹، خطای بازسازی برای ۴ نمونه کلید یکسان ارائه شده است. همان‌گونه که از این شکل قابل برداشت است، با وجود یکسان بودن کلیدها، خطای بازسازی آنها در بازه‌های متفاوتی تغییرات داشته که دال بر این موضوع است که فرایند ساخت و بهره‌برداری کلیدها متفاوت بوده و از این‌رو رفتار آنها نیز متفاوت است. این موضوع سبب برتری الگوریتم پیشنهادی است که می‌تواند تفاوت‌های ذاتی کلیدها را نیز مدل کند. همچنین، خطای بازسازی دارای بازه تغییرات محدودی است که مبنای مدل نرمال (سالم یا مرجع) سیستم است.




شکل ۷. مدار اینورتر و لینک DC در لکوموتیو باری ALSTOM AD43C



شکل ۸. کلید قدرت IGBT و خازن لینک DC


این دو شاخص کلیدی به نحوی مبتنی بر میانگین و واریانس تابع توزیع نرمال خطای بازسازی قابل تفسیر هستند که برای سنجش قابلیت اطمینان هر مبدل تعریف شده‌اند. در شکل ۶، ساختار تابع توزیع نرمال به صورت نوعی نشان داده شده است. پارامتر اول بر اساس نسبتی از مساحت زیر این منحنی استخراج خواهد شد. به این صورت که سیگنال خطای بازسازی به بازه ۰ الی ۱ نرمال شده و سپس پس از انطباق یک تابع توزیع نرمال به این داده‌ها، مساحت زیر منحنی توزیع نرمال حد فاصل ± 0.1 محاسبه خواهد شد. هرچه پایایی سیستم کم‌تر شود، این مساحت نیز کم‌تر خواهد شد. پارامتر دوم بر اساس تغییرات میانگین سیگنال خطای بازسازی محاسبه می‌شود. قدر مطلق واریانس میانگین تغییرات سیگنال خطای بازسازی به عنوان یک مولفه همواره مثبت از مساحت محاسبه شده در بخش قبل کم خواهد شد و به این ترتیب شاخص نهایی استخراج می‌شود.



شکل ۶. ساختار نمونه تابع توزیع نرمال و محاسبه شاخص ریسک ناهنجاری

۴- شبیه‌سازی


به منظور سنجش و ارزیابی پارامترهای معرفی شده، یک نمونه اینورتر با ۶ کلید و لینک DC آن با کاربرد ترکشن (لکوموتیو قطارهای باری ALSTOM AD43C) مورد بررسی قرار گرفته است که ساختار مداری آن در شکل ۷ ارائه شده است. در این مدار، از ولتاژ کلکتور-امیتر کلیدها نمونه‌برداری شده است. این کلید دارای ولتاژ نامی ۱۸۰۰ ولت و جریان نامی ۱۲۰۰ آمپر است که تصویر آن در شکل ۸ نشان داده شده است. خازن لینک DC دارای ظرفیت ۳ میلی فاراد و ولتاژ ۱۸۰۰ ولت است. برای



شکل ۱۱. میانگین خطای مطلق تلفات شبکه به ازای داده‌های آموزش و اعتبارسنجی

یکی از مشکلاتی که روش‌های مبتنی بر خطای بازسازی با آن روبرو هستند، تعیین یک حد آستانه مناسب برای تفکیک نقاط هنجار و ناهنجار است. نکته مهم دیگر توجه ویژه به آن است که حد آستانه خرابی به نحوی باید تعیین شود که اولاً نویزهای اندازه‌گیری در تشخیص خرابی اثر منفی نگذارند و ثانیاً حداکثر دقت در تشخیص، تضمین شود. در صورتی که این عدد را به شکل سخت‌گیرانه‌ای بزرگ در نظر بگیریم، دقت روش افزایش می‌یابد، اما جامعیت آن کم می‌شود؛ یعنی احتمالاً بیش‌تر نقاط کشف شده ناهنجار هستند، اما بخش بزرگی از نقاط ناهنجار، به عنوان هنجار در نظر گرفته خواهند شد. در طرف مقابل، انتخاب یک حد آستانه پایین، باعث افزایش جامعیت و کاهش دقت می‌شود؛ یعنی احتمالاً بیش‌تر نقاط ناهنجار کشف خواهند شد، اما تعدادی از نقاط هنجار نیز به عنوان ناهنجاری برچسب می‌خورند. بدین منظور می‌توان از تابع توزیع فراوانی میانگین خطای مطلق داده‌های آموزش مطابق شکل ۱۲ استفاده نمود. چنانچه در این شکل قابل مشاهده است، تمرکز اصلی فراوانی حول مقدار ۰.۰۸ بوده و برای دستیابی به یک دقت مناسب، می‌توان حد آستانه را بر اساس مقدار انتهایی تابع توزیع برابر با ۰.۲۷۵ در نظر گرفت.


در شکل ۱۳، میزان حد آستانه مشخص شده در بخش قبل با مقدار خطای بازسازی سیگنال مقایسه شده است. چنانچه در این شکل مشاهده می‌شود، مقدار حد آستانه به طور مناسبی با رفتار قبل و بعد از خرابی کلید سازگار است.



شکل ۹. خطای بازسازی ۴ نمونه کلید IGBT


به منظور بررسی صحت عملکرد و کارایی الگوریتم مورد استفاده برای عیب‌یابی، از داده‌های آزمون به شرح شکل ۱۰ استفاده شده است. چنانچه قابل مشاهده است، پس از بروز خرابی در رفتار کلید IGBT، میزان دامنه ولتاژ کلکتور-امیتر به تدریج برای همه کلیدها شروع به افزایش می‌نماید تا آنکه با رسیدن سطح خرابی به مقدار بحرانی خود، کلید کارایی خود را به صورت کامل از دست می‌دهد. نکته مهم دیگر تفاوت و تمایز در رفتار کلیدها به هنگام بروز خرابی است. این موضوع نشان می‌دهد که باید در تشخیص خرابی از مدل‌هایی استفاده نمود که اولاً متناسب با رفتارهای ذاتی کلید توسعه یافته‌اند و ثانیاً شرایط بهره‌برداری و محیطی را نیز در دل خود مدل نموده باشند.

در حین فرایند آموزش شبکه عصبی تحت مطالعه برای عیب‌یابی، بررسی تلفات شبکه بر حسب میانگین خطای مطلق (MAE) بسیار ضروری است. چنانچه در شکل ۱۱ مشاهده می‌شود، خطای تلفات مدل برای داده‌های آموزش و اعتبارسنجی، پس از قریب ۱۰ سیکل به کم‌تر از ۰.۱۵ رسیده که دال بر آموزش و خروجی مطلوب مدل است.




شکل ۱۰. داده‌های آزمون (مقدار نرمال‌سازی شده ولتاژ کلکتور-امیتر) برای ۴ کلید تحت مطالعه


نقاطی را در فاصله کوچک‌ترین تا بزرگ‌ترین رتبه (معمولاً ۰ تا ۱) انتخاب می‌کنند و پس از انتصاب هر نقطه به عنوان حد آستانه، نسبت نمونه‌های ناهنجاری که به درستی به عنوان ناهنجاری در نظر گرفته شده‌اند و نسبت نمونه‌های ناهنجاری که به غلط به عنوان ناهنجار طبقه‌بندی شده‌اند را محاسبه می‌کنند. سپس، در یک نمودار دو بعدی که محور عمودی آن TPR^2 و محور افقی آن FPR^3 است، این نقاط را به هم متصل می‌نمایند تا در نهایت نمودار ROC حاصل شود. در شکل ۱۸، پارامتر ROC برای دو نمونه کلید نمایش داده شده است. چنانچه در این شکل قابل مشاهده است، مدل پیشنهادی دارای دقت مناسبی است (به این معنا که نسبت تشخیص درست نمونه‌های خرابی به تشخیص نادرست عدد بالایی است).




شکل ۱۴. تغییرات داده‌های آموزش (حالت نرمال کلید قبل از وقوع خرابی)




شکل ۱۵. داده‌های آزمون (قبل و بعد از خرابی)



شکل ۱۶. حد آستانه خرابی مبتنی بر توزیع فراوانی میانگین خطای مطلق تلفات شبکه عصبی (۰.۳)



شکل ۱۷. تعیین مقدار حد آستانه تشخیص خرابی به کمک خطای تلفات شبکه عصبی



شکل ۱۸. مقایسه مقدار آستانه خرابی با خطای بازسازی کلید

برای صحت‌سنجی دقیق‌تر مدل و بررسی حالات مختلف، ۴ نمونه کلید دیگر با شرایط آزمون مشابه لحاظ شده‌اند که نتایج مرتبط با داده‌های آموزش (حالت نرمال کلید)، داده‌های خرابی (داده آزمون)، میانگین خطای مطلق تلفات شبکه و میزان حالت آستانه تشخیص خرابی به ترتیب در شکل‌های ۱۴ الی ۱۷ نمایش داده شده‌اند. درست است که در کشف ناهنجاری، داده‌ها به دو طبقه یا کلاس هنجار و ناهنجار تقسیم می‌شوند، اما داده‌های ناهنجار معمولاً نادر و کم تعداد هستند و به همین دلیل اندازه طبقات یاد شده، متوازن نیست. این موضوع باعث می‌شود تا معیارهای رایج در ارزیابی روش‌های طبقه‌بندی، مثل دقت، صحت و جامعیت کارایی خود را از دست بدهند. در نتیجه، معیارهای رایج سنجش مثل دقت، صحت، جامعیت و حتی معیار $F1$ (ترکیبی از معیارهای دقت و صحت) که معمولاً برای تحلیل روش‌های طبقه‌بندی مورد استفاده قرار می‌گیرند، در حوزه کشف ناهنجاری از انعطاف و کارایی لازم برخوردار نیستند [۲۵]. به همین دلیل، اغلب تحقیقاتی که در حوزه یاد شده صورت پذیرفته است، از معیار دیگری به نام منحنی مشخصه عملکرد سیستم^۱ (ROC) استفاده کرده‌اند. برای ترسیم منحنی ROC،

3 False Positive Rate

1 Receiver Operating Characteristic Curve


2 True Positive Rate

تعارض منافع


هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.

مراجع

- [1] R. Alizadeh and H. Alan Mantooh, "A Review of Architectural Design and System Compatibility of Power Modules and Their Impacts on Power Electronics Systems," in *IEEE Transactions on Power Electronics*, vol. 36, no. 10, pp. 11631-11646, Oct. 2021.
- [2] S. Peyghami, P. Palensky and F. Blaabjerg, "An Overview on the Reliability of Modern Power Electronic Based Power Systems," *IEEE Open Journal of Power Electronics*, vol. 1, pp. 34-50, 2020.
- [3] S. Peyghami, Z. Wang and F. Blaabjerg, "A Guideline for Reliability Prediction in Power Electronic Converters," *IEEE Transactions on Power Electronics*, vol. 35, no. 10, pp. 10958-10968, Oct. 2020.
- [4] J. Harikumar et al., "Failure Modes and Reliability Oriented System Design for Aerospace Power Electronic Converters," *IEEE Open Journal of the Industrial Electronics Society*, vol. 2, pp. 53-64, 2021.
- [5] B. Wang, J. Cai, X. Du and L. Zhou, "Review of power semiconductor device reliability for power converters," *CPSS Transactions on Power Electronics and Applications*, vol. 2, no. 2, pp. 101-117, 2017.
- [6] Y. Luo, F. Xiao, B. Wang and B. Liu, "Failure analysis of power electronic devices and their applications under extreme conditions," *Chinese Journal of Electrical Engineering*, vol. 2, no. 1, pp. 91-100, June 2016.
- [7] V.S.B. Kurukuru, A. Haque, R. Kumar, M.A. Khan and A.K. Tripathy, "Machine Learning based Fault Classification Approach for Power electronic converters," 2020 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES), 2020.
- [8] K. Fischer et al., "Field-Experience Based Root-Cause Analysis of Power-Converter Failure in Wind Turbines," in *IEEE Transactions on Power Electronics*, vol. 30, no. 5, pp. 2481-2492, May 2015.
- [9] S. Peyghami, F. Blaabjerg and P. Palensky, "Incorporating Power Electronic Converters



شکل ۱۷. مقایسه خطای بازسازی شبکه با حد آستانه تشخیص خرابی



شکل ۱۸. مقدار ROC برای دو نمونه کلید برای سنجش دقت مدل

۵- نتیجه‌گیری

در این مقاله با هدف توسعه مدل داده‌محور برای تشخیص خرابی‌های رایج در کلیدهای نیمه هادی، از الگوریتم‌های یادگیری ماشین با نام شبکه عصبی تکثیرکننده استفاده شده است. در روش پیشنهادی، با ایجاد یک مدل داده‌محور از کلید، تمامی رفتارهای آن حین کلیدزنی از جمله نرخ تغییرات، میانگین سیگنال و غیره در مدل گنجانده شده و این مدل به عنوان مرجع برای کاربردهای آتی استفاده می‌شود. با مقایسه هر بردار نمونه‌برداری با مدل مرجع، خطای بازسازی یا بازتولید رفتار مبدل تولید شده و به عنوان نمره ناهنجاری مورد استفاده قرار می‌گیرد. این نمره ناهنجاری با قیاس با یک حد آستانه، هنجار یا ناهنجار بودن نمونه را مشخص می‌نماید. نکته کلیدی در رویکرد این مقاله، مدل‌سازی شرایط نرمال کلید بوده و از داده‌های خرابی هیچ استفاده‌ای نشده است. نتایج شبیه‌سازی حاکی از آن است که تشخیص رفتارهای ناهنجار برای ۴ نمونه کلید تحت بررسی به خوبی انجام شده و مدل مرجع توسعه یافته می‌تواند به صورت برخط و زمان واقعی مورد استفاده قرار گیرد.

- [19] H. Oh, B. Han, P. McCluskey, C. Han and B. D. Youn, "Physics-of-Failure, Condition Monitoring, and Prognostics of Insulated Gate Bipolar Transistor Modules: A Review," *IEEE Transactions on Power Electronics*, vol. 30, no. 5, pp. 2413-2426, May 2015.
- [20] V. Smet et al., "Ageing and Failure Modes of IGBT Modules in High-Temperature Power Cycling," *IEEE Transactions on Industrial Electronics*, vol. 58, no. 10, pp. 4931-4941, Oct. 2011.
- [21] U. Choi, F. Blaabjerg and K. Lee, "Study and Handling Methods of Power IGBT Module Failures in Power Electronic Converter Systems," *IEEE Transactions on Power Electronics*, vol. 30, no. 5, pp. 2517-2533, May 2015.
- [22] T.J. Lee, et al. "Greenhouse: A zero-positive machine learning system for time-series anomaly detection." *arXiv* 2018, arXiv: 1801.03168.
- [23] B.F. Lammers, "Replicator Neural Networks for Anomaly Detection," Ph.D. Thesis, School of Economic, Erasmus University, Rotterdam, Netherland, 2018.
- [24] G. Pang, C. Shen, L. Cao and A.V. D. Hengel, "Deep learning for anomaly detection: A review," *ACM Computing Surveys*, vol. 54. No. 2, pp. 1-38, March 2021.
- [25] S. Thudumu, P. Branch, J. Jin and J. Singh, "A comprehensive survey of anomaly detection techniques for high dimensional big data," *Journal of Big Data*, vol. 7, pp. 1-30, 2020.
- Reliability into Modern Power System Reliability Analysis," *IEEE Journal of Emerging and Selected Topics in Power Electronics*, vol. 9, no. 2, pp. 1668-1681, April 2021.
- [10] D. Ronanki and S. S. Williamson, "Failure Prediction of Submodule Capacitors in Modular Multilevel Converter by Monitoring the Intrinsic Capacitor Voltage Fluctuations," *IEEE Transactions on Industrial Electronics*, vol. 67, no. 4, pp. 2585-2594, April 2020.
- [11] Y. Chen, H. Wu, M. Chou and K. Lee, "Online Failure Prediction of the Electrolytic Capacitor for LC Filter of Switching-Mode Power Converters," *IEEE Transactions on Industrial Electronics*, vol. 55, no. 1, pp. 400-406, Jan. 2008.
- [12] Dau, Hoang Anh, Vic Ciesielski, and Andy Song. "Anomaly detection using replicator neural networks trained on examples of one class." Asia-Pacific Conference on Simulated Evolution and Learning. Springer, Cham, 2014.
- [13] Hawkins, Simon, et al. "Outlier detection using replicator neural networks." International Conference on Data Warehousing and Knowledge Discovery. Springer, Berlin, Heidelberg, 2002.
- [14] S. Peyghami, Z. Wang and F. Blaabjerg, "A Guideline for Reliability Prediction in Power Electronic Converters," *IEEE Transactions on Power Electronics*, vol. 35, no. 10, pp. 10958-10968, Oct. 2020.
- [15] J. Harikumar et al., "Failure Modes and Reliability Oriented System Design for Aerospace Power Electronic Converters," *IEEE Open Journal of the Industrial Electronics Society*, vol. 2, pp. 53-64, 2021.
- [16] H. Wang et al., "Transitioning to Physics-of-Failure as a Reliability Driver in Power Electronics," *IEEE Journal of Emerging and Selected Topics in Power Electronics*, vol. 2, no. 1, pp. 97-114, March 2014.
- [17] H. Wang, J. Przybilla, H. Zhang and J. Schiele, "A new press pack IGBT for high reliable applications with short circuit failure mode," *CPSS Transactions on Power Electronics and Applications*, vol. 6, no. 2, pp. 107-114, June 2021.
- [18] A. Abuelnaga, M. Narimani and A. S. Bahman, "A Review on IGBT Module Failure Modes and Lifetime Testing," *IEEE Access*, vol. 9, pp. 9643-9663, 2021.



COPYRIGHTS

© 2024 by the authors. Licensee Iranian Space Research Center of Iran. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) (<https://creativecommons.org/licenses/by/4.0/>)