

تحلیل حساسیت مشخصه‌های ارتعاشی جهت تشخیص موقعیت عیب نابالانسی جرمی پره بالگرد با استفاده از نمودار توزیع وزن‌های شبکه عصبی خود سازمان‌ده

تاریخ دریافت: ۱۴۰۱/۱۱/۰۴

تاریخ پذیرش: ۱۴۰۱/۱۲/۲۹

سیدمحمد میرمحمدی^۱، مصطفی خزائی^{۲*}، امیرمهدی شاهوردی^۳

۱ کارشناسی ارشد، دانشکده مهندسی هوافضا، دانشگاه صنعتی مالک اشتر، تهران. smmir700@gmail.com

۲ استادیار، دانشکده مهندسی هوافضا، دانشگاه صنعتی مالک اشتر، تهران. khazae_m@mut.ac.ir

۳ کارشناسی ارشد، دانشکده مهندسی هوافضا، دانشگاه صنعتی مالک اشتر، تهران. amirmahdishahverdi@gmail.com

چکیده

یکی از مباحث مهم و موانع توسعه سیستم‌های پایش سلامت وسایل پرنده، حجم بالای داده‌های مورد نیاز جهت صحت‌گذاری و اعتبارسنجی الگوریتم‌ها است. در این پژوهش راهکاری مناسب جهت کاهش تعداد سنسورها، حجم داده‌های مورد نیاز و محاسبات در سیستم پایش سلامت روتور اصلی بالگرد ارائه شده است. بدین منظور، با استفاده از شبکه‌های عصبی خودسازمان‌ده، شیوه‌ای جدید جهت تحلیل حساسیت میان مشخصه‌های استخراج شده از سیگنال‌های ارتعاشی مدل دینامیکی روتور اصلی بالگرد جهت تقلیل داده‌برداری پیشنهاد شده است. در ابتدا با استفاده از یک مدل دینامیکی غیرخطی مفصل بالگرد، سیگنال‌های متناظر با ۱۵ حالت نابالانسی جرمی به عنوان گستره‌ای از عیوب روتور شبیه‌سازی گردیده است. سپس، ۱۶ مشخصه تحلیل سیگنال ارتعاشی از شتاب‌های خطی و زاویه‌ای وارده بر هاب روتور اصلی در حالت دائمی پرواز، از طریق پیش‌پردازش و روابط مربوطه استخراج شده است. در نهایت از طریق یک شبکه عصبی خودسازمان‌ده، نمونه‌های مختلف بانک اطلاعاتی ۹۶ مشخصه ارتعاشی، خوشه‌بندی گردیده و مشخصه‌های مهم و کلیدی جهت استفاده در الگوریتم عیب‌یابی با استفاده از نمودار توزیع وزن مشخصه‌های مختلف معرفی شده است.

واژه‌های کلیدی: پایش سلامت، شبکه عصبی، پردازش داده، حساسیت سنجی، مشخصه‌های سیگنال

Sensitivity Analysis of Vibration Characteristics for Localization of Imbalance Fault on the Helicopter Blade

Seyyed Mohamad Mirmohamadi¹, Mostafa Khazae², AmirMahdi Shahverdi³

1,3 Master of Science, Faculty of Aerospace, Malek Ashtar University of Technology, Iran

2 Assistant Professor, Faculty of Aerospace, Malek Ashtar University of Technology, Iran, khazae_m@mut.ac.ir

Abstract

One of the important subjects and barriers to the development of health and usage monitoring systems for air vehicles is a large amount of required data for the algorithm validation. In this research, an appropriate solution is proposed to reduce the number of sensors, the volume of data, and the calculations in the helicopter's main rotor health monitoring system. Using the self-organizing neural network, an algorithm is developed for sensitivity analysis between vibration characteristics that are extracted from the rotor sensors to minimize the required data acquisition tests. First, a comprehensive nonlinear dynamic model of a helicopter is used for the simulation of the signals for 15 imbalance faults as an example of rotor faults. Then, 16 vibration characteristics are calculated and extracted from linear and rotational accelerations of the main rotor hub in steady flight conditions. Finally, different samples of 96 characteristics from this dataset are clustered using a self-organizing neural network, and the effective and key characteristics for fault detection are determined.

Keywords: Health Monitoring, Neural Network, Signal Processing, Sensitivity Analysis, Characteristics Signal

۱۱۳

سال ۱۳ - شماره ۱

پیاو و تابستان ۱۴۰۳

نشریه علمی
دانش و فناوری هوافضا



نامیزانی جرمی و غیر همراستایی را مدل‌سازی نموده و تأثیر ایرادات روتور اصلی بالگرد بر روی مودهای لرزش بدنه را تجزیه و تحلیل کردند [۱]. آشکارسازی این عیوب از طریق سنسورهای ارتعاشی نصب شده در بدنه و رفتار این سیگنال‌ها تحلیل شده است. البته تلاش‌های Azzam تنها به این بخش محدود نمی‌شود و در مباحثی مانند استفاده از داده‌ها به صورت ردیفی^۴ جهت کاهش تأثیر نویز بر تشخیص عیوب [۲] و ارزیابی روش‌های تشخیص عیب با استفاده از تحلیل انواع روش‌های یادگیری با ناظر^۵، فعالیت‌های ارزنده‌ای انجام داده است [۳]. در دوره‌ای سه ساله، آقای Ganguli و همکارانش با تکمیل تلاش‌های انجام گرفته توسط Azzam با استفاده از یک مدل دینامیکی ریاضی و استفاده از تئوری جریان گردابه آزاد، روش‌های تشخیص و مدل‌سازی عیوب مختلف شامل نابالانسی جرمی، وجود ترک بر روی پره و لگ دمپر خراب را بهبود بخشیده [۴] و از روش‌هایی مانند شبکه‌های عصبی و تئوری فازی برای عیب‌یابی استفاده نمودند [۵]. این تلاش‌ها در جهت بهبود صحت عملکرد روش‌های عیب‌یابی روتور اصلی بالگرد، انجام شده است.

پس از آن، Pouradier تحت شرایط آزمایشگاهی، یک تحلیل حساسیت‌سنجی میان مشخصه‌های ارتعاشی روتور اصلی و شرایط محیط پروازی انجام داد [۶]. در ادامه نیز Decker با استفاده از تکنیک انتشار صوتی^۶، روشی عملی جهت شناسایی وجود ترک در چرخنده‌ها ارائه داد که قابل استفاده بر روی پره‌های روتور اصلی نیز می‌باشد [۷]. روش‌هایی تحت عنوان هم‌جوشی داده‌ها نیز وجود دارد که توسط Yang در همان سال به صورت ترکیب داده‌های ارتعاشی بدست آمده از روتور اصلی و بدنه ارائه شده است [۸]. Dempsey سه سال بعد با تکیه بر ترکیب داده‌های ارتعاشی بدنه و داده‌های حاصله از

مشخص کردن زمان بهینه تعویض و تعمیر قطعات سیستم‌های پیچیده مانند بالگردها، هواپیماها و موتورها، بجای تعمیرات دوره‌ای ثابت، از مهم‌ترین چالش‌های امروزی در صنایع هوایی می‌باشند. از این رو توسعه و بکارگیری سیستم‌های پایش سلامت و بهره‌برداری، اهمیت فراوانی یافته است.

نظارت بر سلامت ماشین به منظور کاهش عیوب، تشخیص مشکلات عملکردی و جلوگیری از هزینه‌های تعمیر و نگهداری مهم است. مزایای این کار برای طیف وسیعی از زمینه‌ها مانند بهبود قابلیت اطمینان و ایمنی هواپیماها و هواگردها، بهینه‌سازی فرآیندهای نگهداری، کاهش هزینه‌های عملیاتی و توسعه بانک اطلاعاتی برای اهداف طراحی، آشکار است.

۱-۱- مرور بر پژوهش‌های پیشین

در زمینه سیستم‌های پایش سلامت از سال ۱۹۹۱ تحقیقات جدی صورت گرفته است که شامل روش‌های مدل‌سازی و آشکارسازی عیوب مختلف، حساسیت‌سنجی پارامترهای ارتعاشی، مدل‌های تشخیص وضعیت و پیش‌بینی بروز خرابی می‌شود. در حوزه بالگرد، این اقدامات منجر به ساخت و توسعه محصولات مختلفی شده است که به سیستم‌های پایش سلامت بهره‌برداری^۱ یا به اختصار HUMS مشهور هستند. یکی از اجزای مهم بالگرد روتور اصلی آن می‌باشد که خود شامل تعدادی زیرسیستم مانند کنترل گام پره‌ها^۲، سیستم لگ دمپر^۳ و ساختار پره‌ها و هاب می‌باشد. روتور اصلی و زیرسیستم‌های آن از پرتنش‌ترین اجزای بالگرد هستند که وظیفه تأمین نیروی بالابر و کنترل بالگرد در پروازی و مانورها را بر عهده دارند.

در سال‌های اولیه Azzam به همراه همکارانش با استفاده از یک مدل ریاضی، دو عیب



کیفیت روغن روان کننده، عملکرد سامانه‌های پایش سلامت و بهره‌برداری را بهبود داد [۹].

Maley با انجام ساختارشناسی انواع سیستم‌های پایش سلامت و بهره‌برداری، همراه با بیان کاربردهای صنعتی و پیشرفت‌های این سیستم‌ها به بیان یک نقشه راه برای سیستم‌های پایش سلامت و بهره‌برداری از دیدگاه سازه‌ای می‌پردازد [۱۰]. Liu و Andrew با استفاده از چند نوع شبکه عصبی مصنوعی چند لایه به بررسی دقت و خطای آن‌ها جهت ارائه الگوریتمی برای تشخیص بار کاری وارد شده به مجموعه روتور اصلی و تخمین عمر باقیمانده آن‌ها پرداختند [۱۱].

XinQi و همکارانش تحقیقی مروری بر روی پژوهش‌های انجام گرفته در زمینه‌های تشخیص عیب^۷ و کنترل بازه عیب^۸ برای بالگردهای سرنشین‌دار و بدون سرنشین منتشر کردند [۱۲]. همچنین در همان سال Mylaraswamy به توصیف بانک داده Honeywell پرداخته و در بین الگوریتم‌های مختلف، سه الگوریتم را برای بررسی چگونگی تقسیم‌بندی و تجزیه و تحلیل بانک‌های داده بزرگ برای حل مشکلات حمل و نقل هوایی واقعی انتخاب کرده است، که می‌تواند دقت عملکرد الگوریتم‌ها را در مورد عیب سایش یا وجود نیاز به روغن کاری از ۳۰٪ به ۵۶٪ افزایش دهد [۱۳].

دو سال بعد Azzam با جمع‌آوری دستورالعمل‌ها و همچنین نقشه‌راه‌های مختلف ساخت و توسعه Hums، به بیان نقایص و مشکلات این سیستم‌ها پرداخته است [۱۴]. یک سال بعد Liqing بر اساس فناوری آزمایش‌پذیری، در مورد مراحل طراحی و ساخت سیستم پایش سلامت بالگرد، که شامل ۵ مرحله از جمله تعیین اهداف مورد نیاز، تعریف سیستم، طراحی سیستم و توسعه آن، تأیید و ارزیابی سیستم و ارزیابی و بهبود سیستم در حین کار است، روش‌ها و

الزاماتی را ارائه کرده است [۱۵]. روش تحلیل تابع موجک^۹ که در مباحث عیب‌یابی مورد توجه است، به عنوان نمونه در ادامه توسط Villagómez جهت بررسی و تشخیص عیب در Spindle و ارائه الگوریتم تشخیص عیب مورد استفاده قرار گرفته است [۱۶].

در پژوهش‌های صورت گرفته که مورد بررسی قرار گرفتند، تکیه بر بهبود روش‌های آشکارسازی و الگوریتم‌های شناسایی عیب بوده است. یکی از موضوعاتی که در این میان به خوبی ارزیابی نشده است، انتخاب مشخصه‌های مناسب و گویا برای استفاده در الگوریتم‌ها است. در این راستا Serafini با استفاده از مدل‌سازی آیروالاستیک روتور ایزوله بالگرد بر روی حساسیت‌سنجی دو عیب نابالاسی جرمی و وجود ترک با استفاده از مشخصه‌های خودهمبستگی^{۱۰} و تبدیل فوریه سریع^{۱۱} کار کرده است [۱۷]. نتایج حاصله تنها بر روی همین دو مشخصه، بیانگر قابلیت مشاهده بهتر تمایزات شرایط سالم و معیوب در پاسخ فرکانسی در حالت دائمی پرواز بوده است.

در ادامه توسط Mauricio و تیم تحقیقاتی‌اش پژوهشی انجام گرفت که در این پژوهش تلاش شده است تا در قدرت تشخیص سیستم Hums جهت تشخیص عیب یا تاقان سیاره‌ای MGB بهبود ایجاد شود [۱۸]. بر اساس این روش، داده‌های یک دستگاه آزمایشی ویژه شامل گیربکس اصلی هلیکوپتر SA330 تجزیه و تحلیل شده است.

یک روش جدید استفاده از الگوریتم‌های پردازش تصویر جهت عیب‌یابی سیستم‌های دوار توسط Haidong ارائه شد [۱۹]. در این پژوهش، چارچوب جدیدی بر اساس تصاویر حرارتی مادون قرمز زیروندار کوچک و ECNN منتقل شده از CAE ارائه شده است. همچنین پژوهشی نیز توسط Li و همکارانش انجام شد که در آن، یک روش تشخیص عیب شکستگی روتور حامل بار^{۱۲}





بر اساس FDEO^{۱۳} نرمال شده جریان موتور همراه با تجزیه و تحلیل طیفی پیشنهاد شده است [۲۰]. روش پیشنهادی نتایج تشخیص را با قابلیت تشخیص بالاتر برای شدت خطای BRB تحت شرایط عملیاتی مختلف، به ویژه برای شرایط بار سبک به دست می آورد.

یک سال بعد توسط Mironov و همکارانش مطالعه ای انجام گرفت که در جهت برطرف کردن مشکلات شناسایی عیب پره های دوار با استفاده از تکنیک های OMA^{۱۴} بوده است [۲۱]. این مشکلات شامل مشکلات اندازه گیری ارتعاش پره های دوار، نقض فرض OMA، تأثیر عوامل تصادفی و عملیاتی و وضوح سیستم می باشد. مشکل اندازه گیری در سیستم آزمایشی SHM ساخته شده در هلیکوپتر-نمایشگر عملیاتی حل شده است.

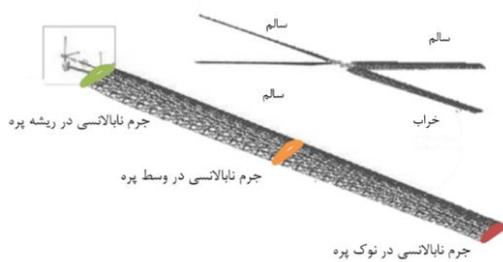
یک سال بعد توسط Ruiz-Carcel پژوهشی ارائه شده است که بر روی اعتبارسنجی تجربی یک حسگر باند پهن برای نظارت بر سیستم انتقال قدرت هواگرد متمرکز است [۲۲]. روش این مقاله، ترکیب قابلیت های AE و نظارت بر ارتعاش در یک حسگر واحد می باشد. اعتبارسنجی نتایج آن از طریق مقایسه سنسور انتخاب شده با یک شتابسنج معمولی انجام گرفته است، که هر دو بر روی یک دنده اختصاصی که در بارهای مختلف کار می کند، مورد آزمایش قرار گرفته است. همچنین پژوهشی نیز توسط Leoni و همکارانش در جهت ارائه الگوریتمی بهینه تر جهت تشخیص مانورهای پروازی بالگرد صورت گرفته است [۲۳]. در این پژوهش با استفاده از داده های تجربی جمع آوری شده توسط شرکت هلیکوپتری لئوناردو، یک سیستم تشخیص رژیم بدون نظارت پیشنهاد شده است که قادر به مدیریت بهتر طیف استفاده واقعی از هلیکوپتر است. الگوی یادگیری استفاده شده از نوع بدون نظارت می باشد، که از یک تکنیک طبقه بندی

عضویت نرم استفاده می کند تا حتی برای رژیم ها و انتقال های مختلط نیز محاسبه شود. سیستم پیشنهادی بر روی داده های تجربی جمع آوری شده توسط شرکت هلیکوپتر لئوناردو آزمایش شده است و قابلیت های برجسته ای را در تشخیص درست رژیم ها و شرایط گذرای استاندارد و مختلط ارزیابی کرده است.

یکی دیگر از پژوهش های مهم اخیر توسط Gildish صورت گرفته است که توانسته است عیب شل شدگی یک پیچ در دم یک بالگرد را شبیه سازی کرده و با استفاده از تکنیک یادگیری ماشین، الگوریتمی جهت تشخیص آن پیشنهاد دهد [۲۴]. در این پژوهش، الگوریتمی جدید برای تشخیص شل شدن پیچ با استفاده از ارتعاشات و یادگیری ماشین (ML) توسعه یافته و بر روی داده های میدانی ثبت شده توسط IAF HUMS آزمایش شده است. تفاوت معناداری در عملکرد بین سه مدل ML شامل مدل نایو^{۱۵}، جنگل جداسازی^{۱۶} و رمزگذار خودکار^{۱۷} یافت نشده است. ارزیابی عملکرد مدل ها به دلیل چالش های مجموعه داده، به صورت محدود صورت گرفته است. همچنین در این پژوهش اثبات شده است که استفاده از فیلترینگ هارمونیک^{۱۸} به عنوان مرحله پیش پردازش، نرخ مثبت واقعی^{۱۹} مدل را به ویژه برای نرخ های مثبت کاذب^{۲۰} پایین که در آن مدل مورد توجه اپراتورها است، بهبود می بخشد.

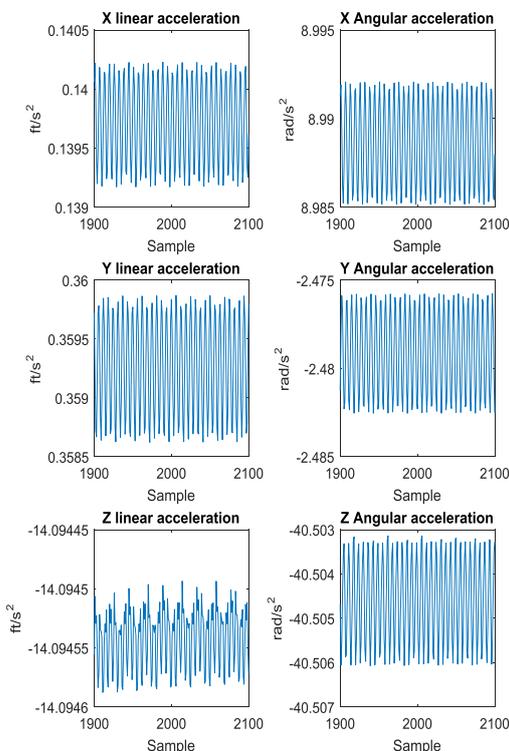
۱-۲- تعریف مساله

پژوهش های انجام گرفته بر روی سیستم های پایش سلامت و بهره برداری بالگرد، بیشتر شامل مباحث مربوط به بهبود الگوریتم های تشخیصی با استفاده از الگوریتم های متنوع و روش های محاسباتی نوین هستند. اما یافتن مشخصه های گویاتر با حساسیت بالاتر نسبت به خرابی های رایج سیستم موضوعی می باشد که هرچند اهمیت



شکل ۱. شماتیک پره روتور اصلی بالگرد UH-60 و نحوه قرارگیری اجرام نابالانسی

این مدل‌سازی‌ها با استفاده از کدنویسی در نرم افزار متلب، در سه ارتفاع از سطح دریا تا ۳ کیلومتری به صورت گام‌های ۱.۵ کیلومتری انجام شده است. نمونه‌ای از سیگنال‌های شتاب استخراج شده از مدل دینامیکی در ارتفاع ۳ کیلومتری در شکل ۲ قابل مشاهده است. نتایج شبیه‌سازی به صورت کامل با نتایج [۲۶] که از کد مدل‌سازی مشابهی استفاده می‌کند مطابقت دارد.



شکل ۲. سیگنال‌های شتاب استخراج شده از مدل دینامیکی

بالایی در کاهش هزینه توسعه الگوریتم‌ها و سیستم‌های پایش سلامت دارد اما کم‌تر مورد استقبال قرار گرفته است. در این مقاله با استفاده از یک شبکه عصبی خوشه‌بندی، تلاش شده است تا الگوریتمی جهت شناسایی و تفکیک مشخصه‌های مهم سیگنال‌های ارتعاشی توسعه داده شود. با استفاده داده‌های پردازش شده حاصله از مدل دینامیکی بالگرد UH-60 امکان آموزش شبکه مورد نظر امکان پذیر خواهد بود. این کار به این دلیل که در سرعت انجام محاسبات الگوریتم‌های تشخیصی مؤثر بوده و حجم محاسبات را کاهش می‌دهد و همچنین به دلیل به حداقل رساندن سنسورهای داده برداری که باعث کاهش هزینه‌های توسعه سیستم می‌شود، دارای اهمیت زیادی است.

۲. مدل‌سازی

برای ایجاد بانک داده مورد نیاز، روتور اصلی بالگرد UH-60 مورد استفاده قرار گرفته است. این روتور از نوع تمام لولا می‌باشد که به صورت کوپل با بدنه و سطوح دمی بر اساس گزارش Howlett مدل‌سازی شده است [۲۵]. این مدل دینامیکی در بسیاری از پژوهش‌های بالگردی مورد استفاده قرار گرفته و مبنای توسعه شبیه‌ساز پرواز Flight Lab می‌باشد.

۲-۱- روند مدل‌سازی عیب نابالانسی جرمی

یکی از رایج‌ترین عیوب روتور اصلی که در اکثر پژوهش‌ها به آن پرداخته شده است عیب نابالانسی جرمی می‌باشد. همانطور که در شکل شماره ۱ قابل مشاهده است، پنج جرم نابالانسی از یک تا پنج گرم در سه ناحیه از یک پره روتور اصلی قرار گرفته و شتاب‌های خطی و زاویه‌ای وارد شده حول هاب^{۲۱}، از مدل دینامیکی استخراج شده است.

۳. معرفی مشخصه‌های سیگنالی مورد نظر

در این پژوهش تعداد ۱۶ مشخصه مختلف جهت انجام پردازش بر روی سیگنال‌های خروجی حاصله از مدل دینامیکی روتور، انتخاب شده و از آن‌ها در تشخیص وضعیت سیستم استفاده شده است. این مشخصه‌های ارتعاشی در ادامه معرفی شده‌اند.

- پیک ^{۲۲}

$$\text{Peak} = \frac{1}{2} [\max\{V[n]\} - \min\{V[n]\}] \quad (1)$$

- میانگین ^{۲۳}

$$A = \frac{1}{N} \sum_{n=1}^N V[n] \quad (2)$$

- میانگین مطلق ^{۲۴}

$$AA = \frac{[\max\{V[n]\} - \min\{V[n]\}]}{\min\{V[n]\}} \quad (3)$$

- انرژی ^{۲۵}

$$E = \frac{1}{N} \sum_{n=1}^N |V[n]|^2 \quad (4)$$

- انرژی نرمالایز شده ^{۲۶}

$$NE = \frac{1}{N * \min\{V[n]\}} \sum_{n=1}^N |V[n]|^2 \quad (5)$$

- کوارینانس ^{۲۷}

$$C = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (V[n] - \bar{V})^2} \quad (6)$$

- نسبت پیک ^{۲۸} به میانگین ^{۲۹}

$$PAR = \frac{1}{|\bar{V}|} \max\{|V[n]|\} \quad (7)$$

- ریشه میانگین مربعات ^{۳۰}

$$RMS = \sqrt{\frac{\sum_{n=1}^N (V[n])^2}{N-1}} \quad (8)$$

- فاکتور قله ^{۳۱}

$$CF = \frac{\Delta V}{RMS} \quad (9)$$

- فاکتور ضربه ^{۳۲}

$$IF = \frac{\Delta V}{|\bar{V}|} \quad (10)$$

- فاکتور شکل ^{۳۳}

$$SF = \frac{RMS}{|\bar{V}|} \quad (11)$$

- مقدار اوج ^{۳۴}

$$Kv = \frac{\frac{1}{N} \sum_{n=0}^{N-1} (V[n] - \bar{V})^4}{RMS^4} \quad (12)$$

- ریشه مربع دامنه ^{۳۵}

$$SRA = \left(\frac{\sum_{n=1}^N \sqrt{|V[n]|}}{N} \right)^2 \quad (13)$$

- فاکتور روزنه ^{۳۶}

$$CLF = \frac{\Delta V}{SRA} \quad (14)$$

- حداکثر مقدار تبدیل فوریه سریع ^{۳۷}

$$MF = \max\{FFT(V[n])\} \quad (15)$$

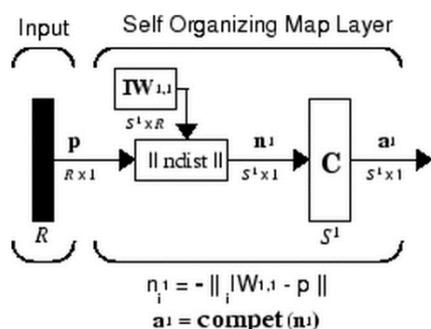


- حداکثر مقدار طیف تراکم قدرت^{۳۸}

$$MP = \max\{PSD(V[n])\} \quad (16)$$

لازم به ذکر است که $V[n]$ در روابط بالا، دنباله عددی حاصل از اعمال تابع خودهمبستگی بر شتاب‌های مختلف خطی و زاویه‌ای خروجی از مدل دینامیکی می‌باشند. همچنین n در بازه یک تا N که شماره آخرین داده سیگنال شتاب استخراج شده از مدل دینامیکی می‌باشد، قرار دارد. پارامترهای عنوان شده همه جزو پارامترهای استاتیکی می‌باشند و به همین جهت می‌توانند مرجع مناسبی جهت تشخیص وضعیت سیستم باشند.

داده‌های ورودی داده می‌شود. بنابراین، از تمام داده‌های بانک اطلاعاتی برای آموزش شبکه استفاده می‌شود.



شکل ۳- ساختار شماتیک یک شبکه عصبی خود سازمان ده [۲۷]

۴. شبکه‌های عصبی خود سازمان‌ده (SOM)^{۳۹}

شبکه‌های عصبی خودسازمان‌ده یاد می‌گیرند که داده‌ها را بر اساس شباهت و توپولوژی، با ارجحیت تخصیص تعداد نمونه‌های مشابه به هر کلاس، خوشه‌بندی کنند. نقشه‌های خودسازمان‌ده هم برای خوشه‌بندی داده‌ها و هم برای کاهش ابعاد داده‌ها استفاده می‌شود. آنها از نقشه‌برداری حسی و حرکتی در مغز پستانداران الهام گرفته شده‌اند، که به نظر می‌رسد به طور خودکار اطلاعات را به صورت مکان‌شناسی^{۴۰} سازماندهی می‌کند [۲۷].

همانطور که در شکل شماره ۳ مشخص است، لایه SOM تنها شامل وزن نورو و تابع انتقال بوده و فاقد بایاس می‌باشد. نوروهای موجود در یک لایه شبکه عصبی SOM در اصل در موقعیت‌های فیزیکی مطابق با یک تابع توپولوژی مرتب شده‌اند. توابع hextop, gridtop یا randtop می‌تواند نوروها را در یک توپولوژی شبکه‌ای مربعی، شش ضلعی یا تصادفی مرتب کند. داده‌های آموزش به صورت بسته‌ای یا به عبارت دیگر به صورت کامل به شبکه به عنوان

۴-۱- نحوه آموزش شبکه عصبی SOM

یک شبکه عصبی SOM، یک نورو برنده i^* را با استفاده از همان شیوه‌ای که توسط یک لایه رقابتی^{۴۱} به کار گرفته شده است، شناسایی می‌کند. با این حال، به جای آن که فقط نورو برنده را به روزرسانی کند، همه نوروهای موجود در یک همسایگی مشخص $Ni^*(d)$ از نورو برنده را با استفاده از قانون کوهونن^{۴۲} به روزرسانی می‌کند. به طور خاص، تمام نوروهای $i \in Ni^*(d)$ به صورت روابط ۱۷ و ۱۸ تنظیم می‌شوند [۲۷]:

$$w_i(q) = w_i(q-1) + \alpha(P(q) - w_i(q-1)) \quad (17)$$

$$w_i(q) = (1 - \alpha)w_i(q-1) + \alpha P(q) \quad (18)$$

برای همه نوروهایی که در شعاع d از نورو برنده i^* قرار دارند، شاخصی به نام شاخص همسایگی $Ni^*(d)$ وجود دارد. از این رو، هنگامی که بردار q ارائه می‌شود، وزن نورو برنده و همسایگان نزدیک آن به سمت q حرکت می‌کند.

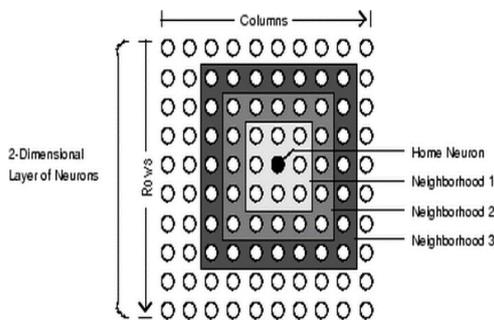
در نتیجه، پس از ارائه‌های فراوان، نورون‌های همسایه بردارهای مشابه یکدیگر را می‌آموزند [۲۷].

نسخه دیگری از آموزش SOM به نام الگوریتم مجموعه‌ای^{۴۳}، کل مجموعه داده‌ها را قبل از به‌روزرسانی وزن‌ها، به شبکه ارائه می‌دهد. سپس الگوریتم یک نورون برنده را برای هر بردار ورودی تعیین کرده، سپس هر بردار وزنی به موقعیت میانگین بردارهای ورودی که به ازای آنها برنده است یا در همسایگی آن برنده است، حرکت می‌کند [۲۷]. برای نشان دادن مفهوم همسایگی، شکل ۴ را در نظر بگیرید.

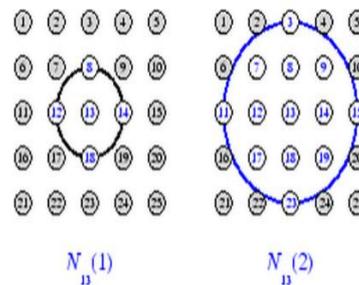
آرایش‌های مستطیلی و شش ضلعی استفاده کرد. قابل ذکر است که عملکرد کلی شبکه به شکل دقیق آرایش‌ها حساس نیست.

۴-۲- توابع فاصله

چهار روش برای محاسبه فاصله یک نورون خاص تا همسایگانش وجود دارد. هر روش محاسبه با یک تابع خاص شامل $dist$ ، $linkdist$ ، $mandist$ و $boxdist$ اجرا می‌شود که از آن میان $linkdist$ رایج‌ترین تابع می‌باشد. شکل ۵ یک نورون خانگی را در یک لایه دو بعدی از نورون‌ها نشان می‌دهد.



شکل ۵- طرح شماتیک دوبعدی یک شبکه SOM [۲۷]



شکل ۴- مفهوم همسایگی حول یک نورون [۲۷]

در شکل ۴ نمودار سمت چپ یک همسایگی دو بعدی با شعاع $d = 1$ را در اطراف نورون شماره ۱۳ نشان می‌دهد. نمودار سمت راست همسایگی حول نورون ۱۳ را با شعاع $d = 2$ نشان می‌دهد، که به صورت روابط ۱۹ و ۲۰ قابل نوشتن است.

$$N_{13}(1) = \{8 \text{ و } 12 \text{ و } 13 \text{ و } 14 \text{ و } 18\} \quad (19)$$

$$N_{13}(2) = \{3 \text{ و } 7 \text{ و } 8 \text{ و } 9 \text{ و } 11 \text{ و } 12 \text{ و } 13 \text{ و } 14 \text{ و } 15 \text{ و } 17 \text{ و } 18\} \quad (20)$$

نورون‌ها را در یک شبکه خودسازمان‌ده می‌توان در چیدمان‌های یک بعدی یا سه بعدی یا بیشتر، مکان‌یابی کرد. به عنوان مثال در یک شبکه SOM یک بعدی، برای یک نورون فقط دو همسایه در شعاع ۱ وجود دارد اما می‌توان فاصله را به روش‌های مختلف تعریف کرده و از

نورون خانگی دارای همسایگی‌هایی با قطر فزاینده است که اطراف آن را احاطه کرده اند. همسایگی با قطر ۱ شامل نورون خانه و همسایگان مستقیم آن است. همسایگی قطر ۲ شامل نورون‌های قطر ۱ و همسایگان بلافاصله آن می‌شود [۲۷].

تابع $dist$ فاصله اقلیدسی از یک نورون خانگی یا مرجع تا هر نورون دیگری را محاسبه می‌کند. با استفاده از تابع $boxdist$ نیز فاصله پله‌ای یا جعبه‌ای هر یک از نورون‌ها که رابطه مستقیم با شماره هر یک از نورون‌ها دارد، محاسبه خواهد شد. توابع $linkdist$ و $mandist$ نیز به ترتیب فاصله لایه‌ای و فاصله منتهن^{۴۴} نورون‌ها نسبت به یک دیگر را محاسبه می‌کنند که الزامات هر کدام از روش‌ها به ترتیب در روابط ۲۱ و ۲۲ شرح داده شده است [۲۷].



z	CF-۵۴	z	peak-۶
z	IF-۵۵	z	A-۷
y	IF-۵۶	y	A-۸
x	IF-۵۷	x	A-۹
y	IF-۵۸	y	A-۱۰
x	IF-۵۹	x	A-۱۱
z	IF-۶۰	z	A-۱۲
z	SF-۶۱	z	AA-۱۳
y	SF-۶۲	y	AA-۱۴
x	SF-۶۳	x	AA-۱۵
y	SF-۶۴	y	AA-۱۶
x	SF-۶۵	x	AA-۱۷
z	SF-۶۶	z	AA-۱۸
z	Kv-۶۷	z	E-۱۹
y	Kv-۶۸	y	E-۲۰
x	Kv-۶۹	x	E-۲۱
y	Kv-۷۰	y	E-۲۲
x	Kv-۷۱	x	E-۲۳
z	Kv-۷۲	z	E-۲۴
z	SRA-۷۳	z	NE-۲۵
y	SRA-۷۴	y	NE-۲۶
x	SRA-۷۵	x	NE-۲۷
y	SRA-۷۶	y	NE-۲۸
x	SRA-۷۷	x	NE-۲۹
z	SRA-۷۸	z	NE-۳۰
z	CIF-۷۹	z	C-۳۱
y	CIF-۸۰	y	C-۳۲
x	CIF-۸۱	x	C-۳۳
y	CIF-۸۲	y	C-۳۴
x	CIF-۸۳	x	C-۳۵
z	CIF-۸۴	z	C-۳۶
z	MF-۸۵	z	PAR-۳۷
y	MF-۸۶	y	PAR-۳۸
x	MF-۸۷	x	PAR-۳۹
y	MF-۸۸	y	PAR-۴۰
x	MF-۸۹	x	PAR-۴۱
z	MF-۹۰	z	PAR-۴۲
z	MP-۹۱	Z	RMS-۴۳
y	MP-۹۲	Y	RMS-۴۴
x	MP-۹۳	X	RMS-۴۵
y	MP-۹۴	y	RMS-۴۶
x	MP-۹۵	x	RMS-۴۷
z	MP-۹۶	z	RMS-۴۸

$$LD_{ij} = 0 \text{ if } i = j \quad (21)$$

$$LD_{ij} = 1 \text{ if } \sqrt{\sum ((P_i - P_j)^2)}$$

$$LD_{ij} = 2 \text{ if } k \text{ exists and } D_{ik} = D_{kj} = 1$$

$$LD_{ij} = 3 \text{ if } k_1 \text{ and } k_2 \text{ exist and } D_{ik_1} = D_{k_1 k_2} = D_{k_2 j} = 1$$

$$LD_{ij} = N \text{ if } k_1 \text{ and } \dots \text{ and } k_N \text{ exist and } D_{ik_1} = D_{k_1 k_2} = \dots = D_{k_N j} = 1$$

$$LD_{ij} = S$$

$$MD = \sum_{i=1}^n |\vec{P}_1 - \vec{P}_2| \quad (22)$$

در رابطه شماره ۲۱ منظور از LD فاصله لایه‌ای بین نورون i و j، بردار مکان مربوطه به هر نورون، N تعداد نورونی که به ازای آن شرط برقرار است، S تعداد کل نورون‌ها و k نورونی غیر از آن دو نورونی است که قرار است فاصله لایه‌ای میان آن دو محاسبه شود. همچنین در رابطه شماره ۲۲ منظور از MD فاصله منتهن است که در واقع حاصل جمع مقدار مطلق تفاضل بردار مکانی دو نورون مد نظر می‌باشد [۲۷].

جدول ۱- لیست مشخصه‌های سیگنالی مورد بررسی

شماره	راستا	شماره	راستا
peak-۱	z	CF-۴۹	z
peak-۲	y	CF-۵۰	y
peak-۳	x	CF-۵۱	x
peak-۴	حول y	CF-۵۲	حول y
peak-۵	حول x	CF-۵۳	حول x



۳-۴- ساختار بانک اطلاعاتی

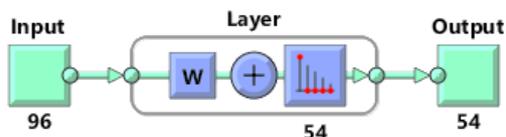
در این پژوهش، تعداد ۱۶ پارامتر یا به عبارت دیگر مشخصه استاتیکی سیگنال مورد بررسی قرار گرفته است این ۱۶ پارامتر از هر ۳ سیگنال شتاب خطی و سه سیگنال شتاب زاویه‌ای حول محور اصلی روتور بالگرد مدل‌سازی شده استخراج می‌شوند که در نتیجه، ۹۶ پارامتر حاصل می‌شود. به عبارت دیگر هر کدام از ۱۶ مشخصه معرفی شده بر ۶ سیگنال مختلف اعمال می‌شود. در جدول شماره ۱ مشخصه‌های محاسبه شده، مرتب شده اند.

۵. نتایج

ساختار شبکه عصبی مورد استفاده شامل یک لایه با ۵۴ نورون می‌باشد که از تابع انتقال *compet* استفاده می‌کنند. تعداد نورون‌ها از تعداد حالات پروازی مدل‌سازی شده بدست آمده است. همانطور که بیان شد حالات مدل‌سازی شده شامل سه مکان مختلف و پنج جرم نابالانسی به همراه حالت سالم است که در سه ارتفاع مختلف انجام شده است. لازم به ذکر است که داده‌های حالت سالم به جهت توازن با حالات دارای نابالانسی جرمی، ۹ بار تکرار شده اند. از این رو ۵۴ حالت وجود خواهد داشت که برای تعریف آن در شبکه با ساختار شش ضلعی از ترتیب ۶ ستون در ۹ ردیف استفاده شده است.

تعداد مشخصه‌های سیگنالی مورد بررسی ۱۶ عدد می‌باشد که برای هر سیگنال شتاب خروجی از مدل دینامیکی پس از اعمال تابع خود همبستگی بر روی داده‌ها قابل محاسبه می‌باشد. همچنین شتاب‌های خروجی شامل سه شتاب خطی و سه شتاب زاویه‌ای خواهد بود. بنابراین تعداد ۹۶ پارامتر تحلیل برای هر یک از حالات پرواز وجود خواهد داشت، که در قسمت ورودی به شبکه اعمال می‌شود. شماتیک ساختار شبکه

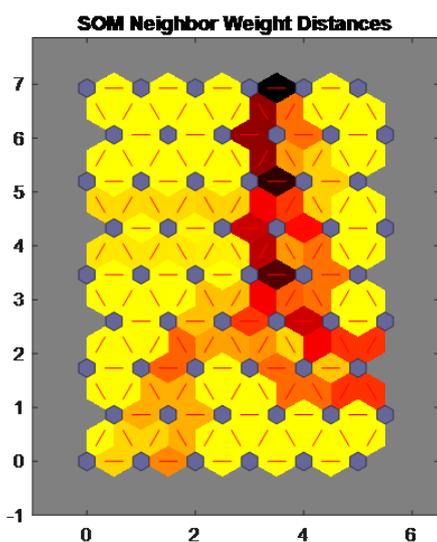
در شکل ۶ قابل مشاهده است.



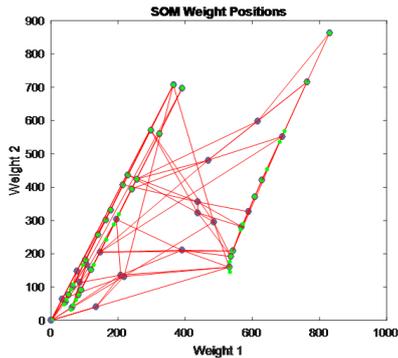
شکل ۶- شماتیک ساختار شبکه SOM با تابع انتقال *compet*

همانطور که در شکل ۶ قابل مشاهده است، تعداد نورون‌های لایه آموزش در واقع تعداد خوشه‌های لایه آخر را تعیین می‌کند.

شکل شماره ۷ فاصله وزن بین نورون‌های مجاور را پس از اتمام آموزش شبکه نشان می‌دهد. به عبارت دیگر برای هر نورون، فاصله بین بردار وزن متصل به خودش تا بردار وزن متصل به نورون‌های مجاورش، اندازه‌گیری می‌شود. هر چقدر این بردارهای وزن به هم نزدیک تر باشند یا فاصله کمتری داشته باشند آن اتصال با رنگ روشن‌تری نشان داده می‌شود که به معنی ارتباط و شباهت بیشتر داده‌های موجود در دو نورون به هم است. بیشترین ارتباط و نزدیکی با رنگ زرد و کمترین ارتباط با رنگ سیاه، نمایش داده شده است.



شکل ۷- فاصله همسایگی نورون‌ها در شبکه SOM آموزش دیده



شکل ۹- نمودار مکان وزنی نورون‌های شبکه آموزش دیده

هدف اصلی پژوهش را شکل شماره ۱۰ با ارائه یکپارچه اطلاعات مورد نیاز جهت ارزیابی مشخص‌های سیگنالی، محقق می‌نماید. هدف اصلی انجام این پژوهش تحلیل و بررسی مشخصه‌های سیگنالی از نظر اهمیت و تأثیر بر شناسایی حالات مختلف سالم و ناسالم است. به همین دلیل شکل شماره ۱۰ در این بررسی اهمیت ویژه ای خواهد داشت.

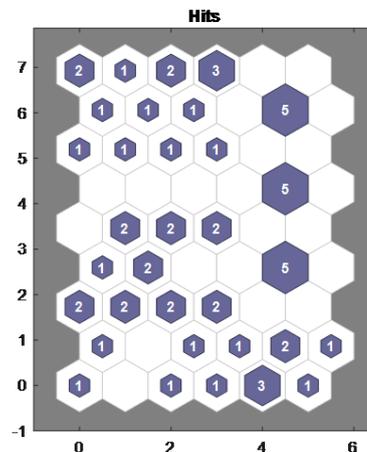
در جدول ۲، شماره هر یک از مشخصه‌ها که در شکل ۱۰ در دسته‌بندی‌های رنگی مختلف قرار گرفته اند، در دسته‌های جداگانه مرتب سازی شده است.

لازم به ذکر است که مشخصه‌های قرار گرفته در دسته‌بندی شماره ۱۴ که قاب سفید رنگ دارند، در واقع هر کدام یک دسته‌بندی جداگانه هستند و نقش یکسانی با یکدیگر نداشته و به جهت آنکه نقش آنها منحصر به فرد است، در یک دسته قرار گرفته اند.

هر یک از رنگ‌های موجود در نقشه تأثیر هر یک از مشخصه‌ها دارای یک عدد متناظر می‌باشد، مجموع این اعداد در واقع شاخص وزن کلی آن مشخصه از کل وزن‌های مربوط به مشخصه‌ها می‌باشد. در جدول ۳ در صد وزنی مربوط به هر یک از مشخصه‌ها از مجموعه وزن‌های کلی نورون‌های شبکه عصبی قابل مشاهده می‌باشد.

شکل شماره ۸ به بهترین شکل، تصویری از خوشه‌های موجود در داده‌های ورودی را به نمایش می‌گذارد. این شکل در واقع نشان می‌دهد که هر نورون به ازای چند نمونه داده، برنده شده است. بانک داده شامل ۶۰ داده می‌باشد، بنابراین مجموع تعداد داده‌ها باید برابر با ۶۰ باشد.

در شکل شماره ۹، پراکنندگی داده‌های ورودی و همچنین وزن اتصال هر نورون در شبکه آموزش دیده قابل مشاهده است. داده‌های ورودی با نقاط سبز رنگ و وزن‌های اتصال با رنگ آبی تیره مشخص شده‌اند، همچنین اتصال نورون‌های مجاور در این نمودار به خطوط قرمز رنگ به خوبی قابل مشاهده است. در این نمودار نشان داده می‌شود که بردار وزن‌ها تا چه اندازه به توزیع داده‌ها نزدیک شده است و آموزش شبکه در چه سطحی قرار دارد. زیرا هدف اصلی شبکه‌های خوشه‌بندی نیز همین است.



شکل ۸- بازخورد نمونه‌های ورودی در هر یک از نورون‌های شبکه

شکل‌های ۶ تا ۹ اطلاعاتی در مورد ساختار کلی و نحوه چیدمان نورون‌های شبکه آموزش داده شده، همچنین صحت و نحوه عملکرد شبکه آموزش‌دیده قابل مشاهده است.



جدول ۳- در صد وزنی مربوط به هر یک از مشخصه‌ها از مجموع وزن نوروهای شبکه عصبی آموزش دیده

شماره	در صد وزنی	شماره	در صد وزنی	شماره	در صد وزنی
۱	۰.۲۱	۳۳	۰.۳۱	۶۵	۱.۸۴
۲	۰.۱۷	۳۴	۰.۴۲	۶۶	۰.۴۵
۳	۰.۱۷	۳۵	۰.۴۲	۶۷	۰.۴۵
۴	۰.۴۹	۳۶	۰.۴۲	۶۸	۰.۳۱
۵	۰.۴۹	۳۷	۲.۰۸	۶۹	۰.۳۱
۶	۰.۴۲	۳۸	۰.۳۱	۷۰	۰.۴۵
۷	۲.۰۸	۳۹	۰.۴۵	۷۱	۰.۴۵
۸	۱.۷۴	۴۰	۲.۰۸	۷۲	۰.۴۵
۹	۲.۰۸	۴۱	۲.۰۸	۷۳	۲.۰۸
۱۰	۱.۷۴	۴۲	۲.۰۸	۷۴	۰.۳۱
۱۱	۰.۵۶	۴۳	۰.۸۷	۷۵	۰.۸۳
۱۲	۲.۰۸	۴۴	۰.۳۱	۷۶	۱.۷۴
۱۳	۰.۲۱	۴۵	۰.۳۱	۷۷	۲.۰۸
۱۴	۳.۱۲	۴۶	۰.۴۵	۷۸	۲.۰۸
۱۵	۳.۱۲	۴۷	۱.۳۹	۷۹	۰.۴۵
۱۶	۱.۰۴	۴۸	۰.۴۵	۸۰	۰.۹۷
۱۷	۱.۳۲	۴۹	۰.۳۵	۸۱	۰.۳۱
۱۸	۰.۴۲	۵۰	۱.۱۵	۸۲	۰.۴۵
۱۹	۲.۰۸	۵۱	۰.۳۱	۸۳	۰.۴۵
۲۰	۰.۱	۵۲	۰.۴۵	۸۴	۰.۴۵
۲۱	۰.۳۱	۵۳	۰.۴۵	۸۵	۲.۰۸
۲۲	۲.۰۸	۵۴	۰.۴۵	۸۶	۰.۰۳
۲۳	۲.۰۸	۵۵	۰.۳۵	۸۷	۲.۰۸
۲۴	۲.۰۸	۵۶	۰.۳۱	۸۸	۱.۷۴
۲۵	۲.۰۸	۵۷	۰.۳۱	۸۹	۲.۰۸
۲۶	۱.۹۱	۵۸	۰.۴۵	۹۰	۲.۰۸
۲۷	۰.۶۹	۵۹	۱.۳۹	۹۱	۲.۰۸
۲۸	۲.۴۳	۶۰	۰.۴۵	۹۲	۰.۰۳
۲۹	۰.۵۶	۶۱	۰.۳۵	۹۳	۲.۰۸
۳۰	۲.۰۸	۶۲	۰.۳۱	۹۴	۱.۷۴
۳۱	۰.۳۱	۶۳	۰.۳۱	۹۵	۲.۰۸
۳۲	۰.۳۱	۶۴	۰.۴۵	۹۶	۲.۰۸

هر چه درصد وزنی مشخصه بالاتر باشد آن مشخصه دارای توان بالای در کمک به شبکه جهت تشخیص حالت سیستم می‌باشد. در صورتی که مشخصه دیگری نیز وجود داشته باشد که دارای درصد وزنی مشابه باشد، بایستی بررسی شود که آیا توزیع این وزن‌ها نیز یکسان می‌باشد یا مشخصه دیگر دارای توزیع متفاوتی است. در صورت یکسان بودن توزیع وزن‌ها، استفاده از هر دو مشخصه تأثیری در قدرت تشخیص شبکه ندارد.

به عنوان نمونه مشخصه‌های دسته‌بندی شده در دسته شماره ۱ که با قاب قرمز رنگ در شکل ۱۰ مشخص شده اند همگی دارای درصد وزنی ۲.۰۸ می‌باشند که از نظر عددی در مقایسه با بقیه مشخصه‌ها میزان قابل توجهی است. اما از این دسته که ۲۱ مشخصه را شامل می‌شود تنها یکی کافی است و محاسبه بقیه هیچ تأثیری در قدرت تشخیص شبکه نخواهد داشت. در مقابل مشخصه شماره ۲۰ دارای درصد وزنی ۰.۱ درصد بوده اما نوع توزیع این وزن‌ها در نقشه تأثیر آن در شکل ۱۰ متفاوت از دیگر توزیع وزن‌ها می‌باشد که به این معنی است که در صورت حذف آن از فرایند آموزش شبکه، قدرت شبکه هر چند اندک، اما کاهش خواهد یافت.

با اعمال روند نمونه شرح داده شده در بالا بر تمامی مشخصه‌ها مشخص می‌شود که در نهایت از ۹۶ پارامتر مورد بررسی تنها ۲۴ مورد آن مفید و مؤثر خواهد بود.

۶. جمع بندی و نتیجه گیری

هدف اصلی از انجام این پژوهش ارائه یک روش تکمیل کننده بر اساس شبکه‌های عصبی خودسازمانده جهت کاهش مناسب و صحیح مشخصه‌ها و سنسورهای مورد نیاز در توسعه یک سیستم تشخیص عیب بالگرد است. مجموعه مشخصه‌های مؤثر در روند تشخیص مکان وقوع

با مقایسه درصدهای وزنی جدول ۳ و نقشه تأثیر هر مشخصه در شکل ۱۰ مشخص می‌شود که همواره درصد وزنی بالاتر به معنی با اهمیت بودن نمی‌باشد. به عبارت دیگر درست است که





عیب نابالانسی جرمی در روتور اصلی بالگرد مد نظر بوده است. در ابتدا با فرض داده‌برداری از شتاب‌های خطی وارده بر هاب روتور اصلی بالگرد در سه جهت x ، y و z و همچنین شتاب دورانی حول هر کدام از آن محورها، به مدل‌سازی حالات مختلف پرواز ایستایی در مورد بالگرد UH-60 پرداخته شده است. این حالات شامل انجام پرواز ایستایی در ۳ ارتفاع مختلف صفر، ۱.۵ و ۳ کیلومتری تحت شرایط خراب و سالم می‌باشد. حالات معیوب به صورت مدل‌سازی ۵ جرم نابالانسی مختلف به جرم ۱ تا ۵ گرم و ۳ محل وقوع شامل ریشه، وسط و نوک پره روتور می‌باشد. مجموعه این مدل‌سازی‌ها، بانک داده مسئله را تشکیل می‌دهد.

با استفاده از تابع خودهمبستگی، پیش‌پردازش بر روی داده‌های خروجی از مدل دینامیکی انجام شده است. دلیل این کار ایجاد بانک داده‌ای است که نسبت به نویز مقاوم باشد. سپس با استفاده از یک شبکه عصبی خودسازمان‌ده یا (SOM)، بانک داده در ۵۴ حالت مختلف خوشه‌بندی گردید و ۳۳ نورون به عنوان نورون برنده انتخاب شدند. این نورون‌های برنده، طبق بردار، وزن و فاصله بردار وزن هر کدام نسبت به نورون مجاور، خوشه‌بندی شده و وزن‌های مشخصی برای اتصال هر نورون به هر مشخصه بدست آورده شده است.

با اختصاص یک رنگ به وزن‌های اتصالات هر نورون به هر مشخصه یک توزیع رنگی از وزن‌های هر مشخصه تحت عنوان نقشه تأثیر آن مشخصه بدست آمده که در واقع مانند اثر انگشت آن مشخصه عمل می‌کند و در شکل ۱۲، مجموعه این نقشه قابل مشاهده است. همچنین در صورت تجمع وزن‌های اتصال مربوط به هر مشخصه، درصد سهم وزنی هر مشخصه از کل وزن‌های اتصال بدست خواهد آمد. در جدول ۳ درصد وزنی هر مشخصه قابل مشاهده می‌باشد.

با توجه به درصد‌های وزنی هر مشخصه در جدول ۳ واضح است که تعدادی از مشخصه‌ها دارای درصد‌های وزنی برابری هستند. با بررسی نقشه تأثیر هر یک از مشخصه‌ها مشخص شده است که برابر بودن درصد وزنی مشخصه‌ها دو معنی دارد که بایستی بررسی شود. حالت اول این است که این دو مشخصه دارای نقشه تأثیر یکسانی نیز هستند که در این صورت استفاده از یکی از آن‌ها کافی است و حذف دیگری تأثیری در قدرت تشخیص شبکه ندارد. حالت دوم چنین است که نقشه تأثیر دو مشخصه متفاوت باشد که در این صورت نقش و وظیفه دو مشخصه متفاوت بوده و در واقع با حذف یکی از آن‌ها قدرت تشخیص شبکه کاهش می‌یابد.

با بررسی ۹۶ مشخصه عنوان شده مشخص شده است که تنها ۲۴ مورد از آن‌ها بایستی محاسبه شوند و بقیه دارای نقش و وظیفه‌ای تکراری هستند. مشخصه‌های منتخب در جدول ۴ ارائه شده‌اند.

جدول ۴- لیست مشخصه‌های سیگنالی مهم

شماره	شتاب / راستا	شماره	شتاب / راستا
۳-peak	x خطی	۳۵-C	حول x
۵-peak	x زاویه‌ای	۴۳-RMS	حول Z
۸-A	y	۵۰-CF	حول Y
۱۳-AA	z	۵۵-IF	حول Z
۱۴-AA	y	۵۹-IF	حول x
۱۶-AA	حول y	۶۵-SF	حول x
۱۷-AA	حول x	۷۵-SRA	حول X
۲۰-E	y	۷۷-SRA	حول x
۲۶-NE	y	۸۰-CIF	حول Y
۲۷-NE	x	۸۱-CIF	حول X
۲۸-NE	حول y	۸۳-CIF	حول x
۲۹-NE	حول x	۸۶-MF	حول Y

نقطه ضعف پژوهش صورت گرفته عدم استفاده از داده‌های واقعی روتور اصلی بالگرد است که در پژوهش‌های بعدی با استفاده از داده‌های تجربی این ضعف قابل برطرف شدن خواهد بود. در ضمن یکی از گام‌های پژوهشی آتی بر مبنای نتایج

Navy Roadmap to Structural Health and Usage Monitoring-The Present and Future, Annual Forum Proceedings-American Helicopter Society, INC, 2007.

- [11] L. Andrew, C. Cheung, and M. Martinez, *Use of artificial neural networks for helicopter load monitoring*, in In Proc. 7th DSTO Int. Conf. on Health & Usage Monitoring, 2011.
- [12] Q. Xin, J. Qi, D. Theilliol, Y. Zhang, J. Han, D. Song, and C. Hua, *A review on fault diagnosis and fault tolerant control methods for single-rotor aerial vehicles*, Journal of Intelligent & Robotic Systems, 2014.
- [13] D. Mylaraswamy, B. Xu, P. Dietrich and A. Murugan, *Case Studies: Big Data Analytics for System Health Monitoring*, in In Proceedings on the International Conference on Artificial Intelligence (ICAI), 2014.
- [14] H. Azzam and J. McFeat, *Development, validation, verification and certification of structural health monitoring systems for military aircraft*, MASAAG, 2016.
- [15] X. Liqing, Z. Cheng, H. Yan, G. Yunan and F. Haiyan, *A frame design of helicopter health monitoring and diagnosis system based on testability*, in Prognostics and System Health Management Conference 2017.
- [16] C. V. Garzón, G. B. Moncayo, D. H. Alcántara, J. C. T. Martínez and R. M. Menendez, *Towards an automatic system to spindle fault detection*, in IFAC International Federation of Automatic Control, 2018.
- [17] J. Serafini, G. Bernardini, R. Porcelli and P. Masarati, *In-flight health monitoring of helicopter blades via differential analysis*, Aerospace Science and Technology, 2019.
- [18] A. Mauricio, L. Zhou, D. Mba and K. Gryllias, *Vibration based condition monitoring of helicopter gearboxes based on cyclostationary analysis*, Turbomachinery Technical Conference and Exposition, 2019.
- [19] Z. He, H. Shao, X. Zhong, Y. Yang and J. Cheng, *An intelligent fault diagnosis method for rotor-bearing system using small labeled infrared thermal images and enhanced CNN transferred from CAE*, Elsevier, Advanced Engineering, 2020.
- [20] H. Li, G. Feng, D. Zhen and F. Gu, *A normalized frequency-domain energy operator for broken rotor bar fault*

حاصله، توسعه و پیاده‌سازی الگوریتم عیب‌یابی با سرعت بالاتر و حجم محاسبات کمتر خواهد بود. همچنین امکان طراحی و برنامه‌ریزی تست‌های داده‌برداری هدفمند با روش ارائه شده روی بالگرد، وجود دارد.

۷. مآخذ

- [1] A. Andrew and H. Azzam, *Effects of Helicopter Main Rotor Faults on Fuselage Vibration Modes*, in AIAA /AHS/ASC Structures, 1991.
- [2] A. Andrew, *The Use of Infield Data and Math Dynamic Models to Evaluate Diagnostic Strategies for Main Rotor Systems Faults*, in ASCE/AHS/ASC Structures, 1991.
- [3] H. Azzam, R. Callan and A. Andrew, *The Implementation of a Pattern Recognition Technique to Classify Main Rotor System Faults*, AIAA/ASME Adaptive Structures Forum 1991.
- [4] R. Ganguli, I. Chopra, and D. Haas, *Formulation of a rotor-system damage detection methodology*, In AIAA/ASME/ASCE/AHS/ASC Structures and AIAA/ASME Adaptive Structures Forum, New Orleans, 1995.
- [5] R. Ganguli, I. Chopra, and D. Haas, *Detection of helicopter rotor system simulated faults using neural networks*, Journal of the American Helicopter Society, 1997.
- [6] J. Pouradier and M. Trouvé, *An Assessment of Eurocopter Experience in HUMS Development and Support*, Proceedings of the 57th AHS International Annual Forum, 2001.
- [7] H. Decker, *Gear Crack Detection using Tooth Analysis*, Proceedings of the Meeting of the Society for MFPT, 2002.
- [8] Yang, M., I. Chopra, and D. Haas, *Rotor System Health Monitoring Using Coupled Rotor-Fuselage Vibration Analysis*, Annual Forum Proceedings - American Helicopter Society, 2000.
- [9] P. J. Dempsey and A. A. Afjeh, *Integrating Oil Debris and Vibration Gear Damage Measurement Technologies Using Fuzzy Logic*, Journal of the American Helicopter Society, 2004.
- [10] S. Maley, J. Plets, and N. D. Phan, US



20. True Positive (TP)
21. False Positive (FP)
22. Hub
23. Peak
24. Average
25. Absolute Average
26. Energy
27. Normalized Energy
28. Covariance
29. بیشترین مقدار یک پارامتر در زمانی معین
30. Peak to average ratio
31. Root mean square
32. Crest factor
33. Impulse factor
34. Shape factor
35. مقدار قله در یک نمودار فرکانسی
36. Square root of amplitude
37. Clearance factor
38. Fast Fourier transform (FFT)
39. Power Spectral Density (PSD)
40. Self-Organizing Map (SOM)
41. Topology
42. competitive
43. Kohonen
44. batch algorithm
45. Manhattan

- diagnosis*, IEEE Transactions on Instrumentation and Measurement, 2020.
- [21] M. Aleksey and D. Pavel, *The Demonstrator of Structural Health Monitoring System of Helicopter Composite Blades*, in ICSI The 4th International Conference on Structural Integrity, 2021 .
- [22] R. C. Cristobal, S. Andrew and F. Arturo, *Experimental assessment of a broadband vibration and acoustice mission sensor for rotorcraft transmission monitoring*, in 7th European Conference of the Prognostics and Health Management Society, 2022.
- [23] J. Leoni, F. Zinnari, E. Villa, M. Tanelli and A. Baldi, *Flight regimes recognition in actual operating conditions: A functional data analysis approach*, ELSEVIER, no. Engineering Applications of Artificial Intelligence, 2022.
- [24] E. Gildish, M. Grebshtein, Y. Aperstein, A. Kushnirski and I. Makienko, *Helicopter Bolt Loosening Monitoring using Vibrations and Machine Learning*, in 7th European Conference of the Prognostics and Health Management Society, 2022.
- [25] J.J. Howlett, *UH-60A black hawk engineering simulation program. volume 1: Mathematical Model*, NASA Ames Research Center, 1981.
- [26] Tamayo. Sergio, "Design of fault tolerant control system for individual blade control helicopters" (2011). Graduate Theses,
- [27] *Cluster with Self-Organizing Map Neural Network* 1994-2016.

۸. پی‌نوشت

1. Health and usage monitoring system
2. pitch control
3. lag damper
4. Infield
5. supervised
6. Acoustic Emissions
7. Fault Diagnosis (FD)
8. Fault- Tolerant Control (FTC)
9. Wavelet
10. autocorrelation
11. Fast Fourier transform
12. Broken Rotor Bar (BRB)
13. Frequency Domain
14. Energy Operator
15. Operational modal analysis
16. Naïve model
17. Isolation Forest
18. Auto-Encoder
19. Harmonic filtering (HF)

