



روش تطبیق‌پذیر شناسایی خطا در سیستم‌های مهندسی با استفاده از یادگیری ماشین

وحید یداله نژاد^۱، جعفری قیدرخلجانی^{۲*}، کریم آتشگر^۲^۱ دانشجوی دکتری، دانشکده صنایع، مجتمع دانشگاهی مدیریت و مهندسی صنایع، دانشگاه صنعتی مالک اشتر، تهران، ایران.^۲ دانشیار، دانشکده صنایع، مجتمع دانشگاهی مدیریت و مهندسی صنایع، دانشگاه صنعتی مالک اشتر، تهران، ایران.

مقاله مستقل، تاریخ دریافت: ۱۴۰۳/۱۰/۲۹؛ تاریخ بازنگری: ۱۴۰۴/۰۲/۰۸؛ تاریخ پذیرش: ۱۴۰۴/۰۳/۰۳

چکیده

در حوزه مهندسی سیستم، تشخیص سریع و کارآمد خطا برای حفظ ایمنی و عملیاتی نگهداشتن سیستم بسیار مورد توجه است. طراحی روش‌های سنتی اغلب برای شناسایی خطاهای از پیش تعریف‌شده هستند و عمدتاً به دانش عمیقی از سیستم نیاز دارند. این ویژگی استقرار و به کارگیری روش‌های سنتی را محدود می‌کند. ما یک رویکرد جدید تشخیص خطا مبتنی بر یادگیری ماشین را معرفی می‌کنیم که در آن تلاش شده از حداقل داده‌های سیستم برای مدل‌سازی استفاده شود. برخلاف روش‌های سنتی، رویکرد این مدل به اطلاعات تخصصی دقیق در خصوص خطاهای خاص سیستم نیاز ندارد. رویکرد مدل به گونه ایست که تمامی انحرافات جدی نسبت به رفتار عادی سیستم را شناسایی و به عنوان خطاهای بالقوه علامت‌گذاری می‌کند. فرض مدل بر آن است که هر گونه اختلاف معنی‌دار بین مقدار داده‌های واقعی حسگرها با مقدار مورد انتظار محاسبه شده، نشان‌دهنده یک خطا است، لذا فرآیند تشخیص خطا را ساده‌تر و وسیع‌تر می‌کند. برای بررسی عملکرد مدل، آزمایش‌هایی بر روی یک کوادکوپتر با تمرکز بر خرابی موتورها انجام شد که نتایج نشان داد، این مدل توانسته خطای رخ داده شده را بدون داشتن دانش قبلی نسبت به انواع خطاهای محتمل تا حد خوبی شناسایی کند؛ لذا می‌تواند به عنوان یک راه‌حل انعطاف‌پذیر و مقیاس‌پذیر برای کاربردهای صنعتی مورد توجه قرار گیرد. سادگی و سازگاری این روش آن را برای سیستم‌های پیچیده جذاب می‌کند.

کلمات کلیدی: یادگیری ماشینی؛ تشخیص خطا؛ یادگیری تحت نظارت؛ وسیله نقلیه هوایی بدون سرنشین (UAV)

A Adaptable Fault Detection Method in Engineering Systems Using Machine Learning

Vahid Yadollahnejad¹, Jafar Gheidar-kheljani^{2,*}, Karim Atashgar²¹ Ph.D. Stu Faculty of Management and Industrial Engineering Department, Malek-Ashtar University of Technology, Tehran, Iran.² Assoc. Prof Faculty of Management and Industrial Engineering Department, Malek-Ashtar University of Technology, Tehran, Iran.

Abstract

In the realm of system engineering, efficient and rapid fault detection is crucial for maintaining operational safety and performance. Traditional fault detection methodologies often depend on extensive system-specific knowledge and are designed to identify only predefined faults, limiting their broader application. This paper introduces a novel machine learning-based fault detection approach that leverages minimal system inputs to model normal operating conditions. Unlike traditional methods, our approach does not require detailed expertise about specific fault conditions. In-stead, it detects deviations from normal behavior, flag-ging these as potential faults. This model assumes that any significant discrepancy between expected and actual sensor data indicates a fault, thereby simplifying the fault detection process and enhancing its applicability across various systems. To validate the effectiveness of this approach, we conducted experiments on a quad-copter, focusing on motor and external disturbances. The results demonstrate that our model can successfully identify faults without prior knowledge of specific fault types, offering a flexible and scalable solution for various industrial applications. The simplicity and adaptability of this method make it particularly attractive for systems where traditional fault detection techniques may be impractical due to complexity or the need for rapid deployment.

Keywords: Machine Learning; Fault Detection; Supervised Learning; Unmanned Aerial Vehicle (UAV).

۱- مقدمه

این مقاله یک رویکرد یادگیری ماشینی مبتنی بر داده برای تشخیص خطا^۱ (FD) ارائه می کند. روش پیشنهادی، روابط بین پارامترهای سیستم قابل اندازه گیری را با استفاده از ابزارهای یادگیری ماشین^۲ (ML) برای شناسایی خطاها مدل سازی می کند. کاربرد عملی این رویکرد از طریق یک مطالعه موردی روی یک کوادکوپتر نشان داده شده است که در آن خطاهای موتور با استفاده از حسگرهایی مانند شتاب سنج و ژيروسکوپ شناسایی می شوند.

بررسی پژوهش های انجام شده در این حوزه حاکی از آن است که مطالعات متعددی بر وضعیت سلامت سیستم تمرکز داشته اند [۱]. در این راستا، در سال های اخیر نیز افزایش قابل توجهی در استفاده از الگوریتم های یادگیری ماشین در حوزه های مختلف و بخصوص در حوزه نظارت بر سلامت سیستم ارائه شده است [۲، ۳].

یکی از الزامات مهم در اکثر روش های FD ارائه شده این است که آنها به دستگاه های اندازه گیری یا نظارت خاصی نیاز دارند که توسط افراد خبره یا به صورت تجربی کنترل می شوند. این روش ها معمولاً متکی بر دانش دقیق از سیستم و صرفاً برای خطاهای مشخص و با اهمیت سیستم طراحی شده اند؛ در نتیجه، هر الگوریتم برای هر سیستم منحصر به فرد و نیاز به یک پیکربندی جداگانه دارد که می تواند زمان بر باشد. در این راستا، پژوهش های اخیر بر ارائه یک پیکربندی انعطاف پذیر جهت تسریع در فرایند پیکربندی روش های تمرکز دارند [۴]. لذا توسعه رویکردهایی که تعامل بین دانش متخصصان و دانش استخراج شده از تجزیه و تحلیل داده ها را بهبود بخشد، همیشه مسیری امیدوارکننده و معتبر است [۵].

مدلی که ما در اینجا پیشنهاد می کنیم، مدلی مبتنی بر داده است که به حداقل تخصص در سیستم نیاز دارد. رویکرد اصلی بر این اصل استوار است که هر سیستمی از اجزای مختلفی تشکیل شده است و خطا یا اختلال در هر یک از این اجزا نه تنها می تواند بر رفتار آن جزء تأثیرگذار باشد، بلکه می تواند باعث ایجاد تغییرات قابل توجهی در عملکرد سایر اجزا شود.

بنابراین، تمرکز ما بر همبستگی بین داده های قابل استخراج سیستم است تا بتوانیم سلامت اجزای سیستم را رصد نماییم. برای دستیابی به این هدف، ما یک روش ML را توسعه دادیم. احمد و همکاران نشان دادند که الگوریتم های یادگیری ماشین در مدل سازی رفتار چند بعدی و غیرخطی تعریف شده در مسئله خود عملکرد مناسبی داشتند [۶].

در ادامه، بند ۲ به ادبیات و مقالات ارائه شده در این زمینه می پردازد. بند ۳ شامل تعریف مساله دقیق تر مساله است. مدل پیشنهادی با جزئیات در بند ۴ ارائه شده است. جهت اعتبارسنجی مدل نیز در بند ۵ یک مورد واقعی مورد بررسی قرار گرفته است و در نهایت، در بند ۶ نتیجه گیری انجام شده است.

۲- بررسی ادبیات

چلیوتیس و همکاران [۷] به رویکردی مبتنی بر یادگیری ماشین (ML) اشاره کرده اند که تمرکز آن بر شناسایی عیوب احتمالی در موتور کشتی است. رویکرد ارائه شده بر پایه داده های تاریخی سیستم در وضعیت سلامت آن است و نیاز چندانی به داده های گسترده مربوط به خطا برای آموزش ندارد. این ویژگی از جمله مواردی است که ما تلاش نمودیم در پژوهش خود مورد توجه قرار دهیم.

بوده و همکاران [۸] الگوریتمی برای شناسایی خطا (FD) قبل از رخ دادن خرابی یا کاهش عملکرد سیستم ارائه کرده اند. آنها همچنین خاطرنشان کردند که با ظهور هوش مصنوعی (AI^۳)، داده های بزرگ و ابزارهای نظارتی پیشرفته تر، الگوریتم های FD مبتنی بر داده ها در سال های اخیر به کانون تحقیقاتی تبدیل شده اند و نتایج امیدوارکننده ای را نشان می دهند.

لی [۹] از یادگیری ماشینی برای پیاده سازی فناوری تشخیص خطا لحظه ای برای قطارهای پرسرعت استفاده کرده است. در رویکرد ارائه شده ایشان، دسترسی به داده های سیستم در وضعیت خطا و سلامت جهت آموزش مدل ضروری است، این در حالی است که هدف ما کاهش وابستگی به داده ها و خطاهای گذشته است.

³ Artificial Intelligence

¹ Fault Detection

² Machine Learning

استفاده از یادگیری به موقع (JIT^۱) معرفی می‌کند. روش آنها برای شناسایی کارآمد عیوب بدون تکیه بر مدل‌های سیستم پیچیده طراحی شده‌است. به طور مشابه، هدف مقاله ما شناسایی یک رویکرد انعطاف‌پذیر است که وابستگی به دانش خاص سیستم را به حداقل می‌رساند و در نتیجه پیچیدگی را کاهش می‌دهد.

کائو و همکاران [۱۴] یک راه حل امیدوارکننده برای تشخیص خطا در سیستم‌های غیرخطی با استفاده از روش یادگیری تکراری، به ویژه در محیط‌هایی که خطاها در طول زمان تکامل می‌یابند و به تکنیک‌های تشخیص تطبیقی نیاز دارند، ارائه می‌دهد. ایشان بر سیستم‌هایی تمرکز می‌کنند که در آن روش‌های سنتی به دلیل غیرخطی‌ها و عدم قطعیت با چالش همراه هستند. روش ایشان برای بهبود قابلیت اطمینان و دقت تشخیص خطا به مرور زمان طراحی شده‌است. این رویکرد از کنترل یادگیری تکراری (ILC^۲) برای شناسایی و برآورد خطاها از طریق عملیات مستمر استفاده می‌کند. سیستم با یادگیری از تکرارهای قبلی، به تدریج دقت تشخیص خطا را اصلاح می‌کند.

زنگ و همکاران [۱۵] یک روش تشخیص خطا را ارائه می‌دهد که به طور خاص برای سیستم‌های غیرخطی به هم پیوسته با استفاده از یادگیری قطعی طراحی شده‌است. روش مبتنی بر یادگیری قطعی شامل ساخت مدل‌های محلی رفتار عادی سیستم و مقایسه مداوم داده‌های سیستم بلادرنگ با این مدل‌ها است.

در مقاله خود، ما همچنین رویکرد مشابهی را برای شناسایی عیوب با به حداقل رساندن نیازهای داده مورد بحث قرار می‌دهیم. این روش امکان شناسایی هر دو خطای شناخته شده و ناشناخته را فراهم می‌کند.

سیستمی که به عنوان مطالعه موردی انتخاب کرده ایم یک کودکوپتر چهار موتوره است. در این زمینه پارک و همکاران [۱۶] یک مدل یادگیری بدون نظارت را برای تشخیص حالت‌های ایمن و معیوب در پهپادها پیشنهاد نمودند. این مدل با عدم نیاز به شرایط خطای از پیش تعریف‌شده، محدودیت‌های رویکردهای مبتنی بر قانون و نظارت را برطرف نموده است.

عبدالگاید و همکاران [۱۰] یک رویکرد یادگیری ماشین نیمه نظارت شده برای طبقه بندی خطا در سیستم‌های انتقال و توزیع برق پیشنهاد کرده‌اند. نتایج نشان داده است که رویکرد پیشنهادی انعطاف‌پذیری و سازگاری با شرایط یا پیکربندی‌های مختلف سیستم را با دقت بالا فراهم می‌کند. این مقاله به داده‌های تاریخی در مورد وضعیت سلامت سیستم نیاز دارد.

آمروثان و گوپتا [۱۱] تاکید کردند که FD یک جزء حیاتی در تعمیر و نگهداری پیش‌بینی شده‌است و صنایع نیاز قابل توجهی به تشخیص زود هنگام و دقیق خطا دارند. آنها بر اهمیت این موضوع در محیط تولید تاکید کردند، جایی که برای کاهش هزینه‌های تعمیر و نگهداری، گاهی اوقات نیاز به توسعه مدلی با داده‌های تاریخی محدود یا حتی بدون هیچ گونه داده تاریخی وجود دارد.

سیورز و مدنی [۱۲] یک رویکرد مبتنی علت و معلولی را برای پاسخ به شرایط پیش‌بینی‌شده و پیش‌بینی‌نشده بر اساس مدل‌های الهام‌گرفته از پاسخ‌های ذاتی و سازگار سیستم‌های بیولوژیکی، مانند سیستم ایمنی بی‌مهرگان و کلنی‌های حشرات اجتماعی تحت حمله، پیشنهاد کردند. مفهوم ارائه شده بر اساس تشبیهات بیولوژیکی است، جایی که پاسخ به اختلالات در طول زمان آموخته و تقویت می‌شود.

آنها نشان دادند که رفتار نهادهای سیستم یا داده‌های حسگرهای مجاور می‌تواند به عنوان شاخصی از عملکرد نهادهای دیگر باشد؛ بنابراین، ما نیز از این ایده استفاده کردیم و از طریق تجزیه و تحلیل همبستگی بین نهادهای یک سیستم و پارامترهای قابل اندازه‌گیری در آن سیستم، راه‌حلی برای شناسایی زمان وقوع پیشنهاد کردیم.

فایلر و همکاران [۴] یک الگوریتم جدید FD صرفاً مبتنی بر داده معرفی کردند، که در آن نیازی نیست توسعه‌دهنده یا تحلیل‌گر درک دقیقی از ساختار داخلی یا قوانین عملکردی سیستم داشته باشند. این نوع روش FD همچنین از داده‌های تاریخی برای FD استفاده می‌کند. در این راستا رویکرد ما نیز مبتنی بر داده است با این ملاحظه که از داده‌های تاریخی کمتری استفاده شود.

عباسی و همکاران [۱۳] یک روش جدید تشخیص خطا را برای سیستم‌های غیرخطی مبتنی بر رویکرد داده محور با

^۲ Iterative Learning Control

^۱ Just-in-Time

پیچیده مثل شبکه های حسگر بی سیم، سیستم های چندرباتی و گروه پهپادها بسیار مورد توجه قرار گرفته اند. این روش ها به جای اینکه همه پردازش ها را در یک نقطه مرکزی انجام دهند، کار را بین گره های مختلف تقسیم می کنند. این کار سه مزیت اصلی دارد: باعث می شود سیستم قابل اعتمادتر باشد، تأخیر کمتری داشته باشد و راحت تر بتوان آن را گسترش داد.

مطالعه جالبی توسط دوست محمدیان و همکاران [۲۱] انجام شده که نشان می دهد حتی در سیستم های پیچیده ای که اطلاعات کامل ندارند، می توان با طراحی مناسب یک سیستم نظارت توزیع شده و تعیین آستانه های مناسب، مکانیزم موثری برای تشخیص و جداسازی خطاها ایجاد کرد. آنها با ایده های نوآورانه مثل «ناظر شبکه ای با مقیاس زمانی واحد» و استفاده از روش های پیشرفته ریاضی، راهی پیدا کرده اند که بتوان خطاهای محلی را شناسایی کرد، بدون اینکه این خطاها به بخش های دیگر سیستم سرایت کند.

مدل ارائه شده ما در این پژوهش نیز با وجود اینکه به صورت متمرکز آزمایش شده، اما طراحی آن به گونه ای است که می تواند با کمی تغییر در سیستم های غیرمتمرکز هم پیاده سازی شود که می تواند به عنوان مطالعات آتی مورد توجه قرار گیرد.

محمدزاده ایوقی و علیاری شوره دلی [۲۲] به بررسی ساختارهای مختلف یادگیری عمیق، به ویژه مدل های متغیر پنهان، برای شناسایی فضای حالت غیرخطی پرداختند. نتایج این مطالعه نشان داد که مدل های یادگیری عمیق می توانند عملکرد قابل مقایسه ای با روش های کلاسیک در شناسایی سیستم های غیرخطی داشته باشند.

یعقوبی و محمدی [۲۳] یک مشاهده گر مبتنی بر شبکه عصبی تطبیقی را برای تشخیص و جداسازی خطای حسگر و عملکرد در یک مدل دینامیکی غیرخطی وسیله نقلیه هوایی بدون سرنشین طراحی کردند. در این مطالعه، پارامترهای وزن شبکه عصبی با استفاده از فیلتر کالمن توسعه یافته به روز شدند که باعث افزایش نرخ همگرایی شبکه عصبی گردید. نتایج شبیه سازی عددی نشان داد که روش پیشنهادی قادر است، خطاهای ناگهانی، متناوب و اولیه را با دقت و سرعت مناسب تشخیص دهد.

محمدحسین تبار مرزبالی و همکاران [۲۴] روش های مبتنی بر شبکه های یادگیری عمیق را برای استخراج

استفاده از سیستم های فازی برای تشخیص خطا در سیستم های غیرخطی و همراه با عدم قطعیت می تواند موثر باشد. منطق فازی به مدیریت پیچیدگی ها و عدم قطعیت های ذاتی در چنین سیستم هایی با ارائه استراتژی های کنترل منعطف و تطبیقی کمک می کند. در این راستا، زو و همکاران [۱۷] یک روش قوی برای تشخیص خطا با ادغام یک ناظر فازی در سیستم های کنترل شبکه غیرخطی پیشنهاد می کنند. رویکرد آنها با موفقیت هم دینامیک غیرخطی سیستم و هم چالش های ناشی از شبکه مانند تأخیرها و تلفات بسته را بر طرف می کند و اثربخشی سیستم های فازی را در افزایش قابلیت های تشخیص خطا نشان می دهد.

پورچالسکی و همکاران [۱۸] مروری بر روش های مختلف تشخیص خطا اعمال شده در پهپادها، از جمله رویکردهای مبتنی بر یادگیری ماشین، ارائه می دهند. اهمیت قابلیت اطمینان و ایمنی پهپاد را مورد بحث قرار می دهد.

لوپز استرادا و همکاران [۱۹] یک رویکرد مبتنی بر داده را با استفاده از تکنیک های یادگیری ماشین برای ساختن یک مدل ضمنی از سیستم پهپاد از طریق داده حسگرهای داخلی ارائه می دهند. این روش بر روی تشخیص خطاهای محرک در پهپاد کوادروتور تمرکز دارد.

یانگ و همکاران [۲۰] بر اهمیت تشخیص ناهنجاری برای ایمنی پهپاد، استفاده از روش های یادگیری بدون نظارت برای شناسایی انحرافات از الگوهای عملیاتی عادی بدون تکیه بر دانش گسترده سیستم خاص تأکید می کنند.

مقالات ارائه شده بر رویکردهای بدون نظارت و مبتنی بر داده برای تشخیص خطای پهپاد تأکید می کنند و نیاز به شرایط خطای از پیش تعریف شده و دانش گسترده سیستم را به حداقل می رسانند؛ بنابراین هدف تعریف شده مقاله ما نیز در همین راستا تعریف می شود.

مطالعات متعددی از روش های دسته بندی یا خوشه بندی برای تفکیک وضعیت سالم و معیوب سیستم استفاده کرده اند. با این حال، یکی از محدودیت های اساسی این روش ها، وابستگی به داده های مربوط به شرایط مختلف خطا به منظور تسهیل فرآیند یادگیری مدل است. همانطور که در مرجع [۴] نشان داده شد.

ذکر این نکته حائز اهمیت است که در سال های اخیر، روش های غیرمتمرکز برای تشخیص خطا در سیستم های

رویکرد ما منحصرأ بر روی داده‌های وضعیت سالم متمرکز است.

(۴) روش‌های متداول FD غالباً در تعمیم دادن نتایج فراتر از محدوده اطلاعاتی که در بازه آموزش سیستم جمع آوری شده است شکست می‌خورند؛ در نتیجه، قادر به پیش‌بینی مقادیری پارامتر هدف خارج از محدوده تعریف شده خود نیستند؛ لذا منجر به بروز هشدارهای کاذب قابل توجهی خواهند شد. روش پیشنهادی در این مطالعه این محدودیت را از طریق اصلاحات ابتکاری طراحی شده برای افزایش قابلیت‌های عمومی‌سازی الگوریتم در سناریوهای عملیاتی متنوع تا حد خوبی از بین می‌برد. در این راستا ما از مجموعه تصمیم همسایه خلاقانه^۳ که یک روش ابتکاری است، استفاده کردیم.

(۵) در روش استاندارد RF، یک نمونه داده منفرد در درخت‌های تصمیم‌گیری مختلف مورد استفاده قرار می‌گیرد و پاسخ‌های هر درخت به طور مستقل ارزیابی می‌شود؛ اما برخلاف روش RF از DS‌های مختلف برای FD استفاده می‌کنیم که مطابق با دستورات اپراتور تنظیم شده است. این سازگاری امکان راه اندازی یک DS جدید و خاتمه DS قبلی را فراهم می‌کند که توسط اپراتور تعیین می‌شود.

(۶) به طور معمول جهت جلوگیری از محاسبات اضافه و کاهش پیچیدگی از حداقل تعداد پارامتر در مدل استفاده می‌شود؛ لذا به حذف پارامترهایی که همبستگی بالایی با یکدیگر دارند می‌پردازیم، زیرا اثر بخشی مشابهی بر نتیجه خواهند داشت. برخلاف مطالعات موجود، ما تمام پارامترهایی را حذف نمی‌کنیم که همبستگی بالایی دارند. در این روش ابتدا پارامترهای قابل اندازه‌گیری را دسته‌بندی و اگر در یک دسته دو پارامتر با همبستگی بالا وجود داشته باشد، آنگاه یکی از آنها به طور انتخابی حذف می‌شود.

(۷) اغلب تحقیقات انجام شده در خصوص ترکیب ML و FD بر روی تنها یک پارامتر از سیستم مانند سیگنال‌های ارتعاشی یا امواج صوتی متمرکز شده‌اند، اما ما بر روابط متقابل و تأثیرگذار پارامترهای قابل اندازه‌گیری سیستم

ویژگی‌های مؤثر از داده‌های ارتعاشی به‌کار گرفتند. نتایج این پژوهش نشان داد که استفاده از معماری‌های مناسب شبکه‌های عصبی می‌تواند به بهبود چشمگیر دقت تشخیص خطاهای مکانیکی در سیستم‌های الکترومکانیکی منجر شود.

این مطالعات نشان می‌دهند که استفاده از روش‌های یادگیری ماشین، به‌ویژه شبکه‌های عصبی و مدل‌های یادگیری عمیق، می‌تواند در شناسایی سیستم‌های غیرخطی و تشخیص خطا مؤثر باشد. در پژوهش حاضر نیز، با بهره‌گیری از این رویکردها، به تخمین پارامترهای هدف در سیستم‌های غیرخطی پرداخته شده است.

روش توسعه داده شده ما در این مطالعه به شرح زیر است: در ابتدا، پارامترهای موجود و قابل اندازه‌گیری سیستم را شناسایی می‌کنیم. با استفاده از اندازه‌گیری این پارامترها در وضعیت سلامت سیستم، رفتار سیستم را با استفاده از ابزارهای یادگیری ماشین (ML) مدل می‌کنیم. متعاقباً، در یک بازه زمانی از پیش تعیین شده و کوتاه، الگوریتم به طور مداوم پارامترهای هدف را تخمین زده و این تخمین‌ها را با مقادیر واقعی اندازه‌گیری شده مقایسه می‌کند. اگر اختلاف قابل توجهی بین رفتار پیش‌بینی شده (مورد انتظار) و رفتار اندازه‌گیری شده (واقعی) تشخیص داده شود، یک هشدار خطا صادر می‌شود. نوآوری‌های کلیدی این روش به شرح زیر است:


(۱) در مقالات متعددی از روش جنگل تصادفی (RF^۱) استفاده شده است. RF معمولاً شامل استفاده مکرر از تعداد ثابتی از درختان تصمیم است [۴]. روش ما چارچوب جدیدی به نام مجموعه تصمیم (DS^۲) را معرفی می‌کند که به طور مداوم در حال توسعه و گسترش است. (۲) ما یک مفهوم جدید با استفاده از یک روش منحصر به فرد به نام DS فرموله کرده‌ایم. این رویکرد تمرکز ML را بر دامنه پاسخ افزایش می‌دهد و با ثابت نگه داشتن پارامترهای خاص، دقت را بهبود می‌بخشد.

(۳) الگوریتم‌های ML عموماً به دو نوع داده نیاز دارند: داده‌هایی که در زمان سلامت سیستم جمع‌آوری می‌شود و داده‌هایی که در زمانی وقوع خطا در سیستم جمع‌آوری می‌شود. با توجه به چالش و زمان بالای مورد نیاز برای شناسایی تمام خطاهای بالقوه سیستم و یا شبیه‌سازی آن،

^۳ Creative Neighborhood DS

^۱ Random Forest

^۲ Decision Set



شکل ۱- کوادکوپتر مورد استفاده در این تحقیق.

- **مجموعه تصمیم (DS):** یک DS به عنوان تابعی تعریف می- شود که با یک مجموعه داده انتخاب شده مطابقت دارد. در این مطالعه، ما از یک مدل رگرسیون غیرخطی چند متغیره از کتابخانه Sci-Kit-Learn Python برای ساخت DS خود استفاده کردیم. (DS باید حداقل ۳۰ نمونه داشته باشد).

- **مجموعه های تصمیم همسایه:** اینها DS هایی هستند که می توانند از یک DS مرجع با حداقل تنظیمات مثبت یا منفی تنها در یک پارامتر کلیدی تبدیل شوند. همانطور که در شکل ۲ نشان داده شده است، DS های همسایه برای بردار (a) که می توانند تنها با تغییرات در پارامتر جهت سیگنال شتاب اپراتور تولید شوند، با بردارهای (a') و (a'') نشان داده شده اند. نشان دهنده پارامترهای همسایه.

- **مجموعه های تصمیم همسایه متقارن:** این مجموعه ها به جفت های از مجموعه های تصمیم اشاره می کنند که از تغییرات مثبت و منفی (نه لزوماً برابر) در تنها یک پارامتر کلیدی مجموعه تصمیم مرجع ایجاد می شوند. به عنوان مثال، در شکل ۲، جفت مجموعه های تصمیم (a') و (a'') و همچنین (a''') و (a''''') ، مجموعه های تصمیم متقارن را نشان می دهند.

تأکید داریم.

۸) استفاده از ML در FD امکان تجزیه و تحلیل موثر حجم داده های بزرگ، استخراج الگوها و پیش بینی های دقیق را فراهم می کند، بنابراین توانایی شناسایی خطاها در حوزه های مختلف را افزایش می دهد.

۳- تعریف مساله

یک کوادکوپتر (شکل ۱) مجهز به چهار موتور الکتریکی را در نظر بگیرید که با تغییر سرعت موتورهای خود، مانورها را اجرا می کند.

عملکرد سیستم توسط دو حسگر حیاتی ژيروسکوپ و شتاب سنج کنترل می شود: آنها اطلاعات ضروری مربوط به تعادل پهناد و موقعیت آن را در هر لحظه به پردازنده ارائه می دهند. با استفاده از این داده ها، همراه با سیگنال های کنترلی دریافتی از اپراتور، پردازنده دستورات را به ماژول های کنترل کننده سرعت الکترونیکی (ESC^۱) متصل به هر موتور ارسال می کند.

تعاریف:

- **مجموعه داده:** مجموعه ای از داده های دریافتی سیستم که در آن یک یا چند پارامتر کلیدی ثابت می مانند. در زمینه مطالعه موردی ما، پارامتر کلیدی سیگنال ارسالی اپراتور است که شامل جهت و شتاب است؛ بنابراین، تمام داده های دریافتی که دارای شتاب و جهت سیگنال مشابه هستند در یک مجموعه داده دسته بندی می شوند.

^۱ Electronic Speed Controller


این پاسخ عمل می‌کند.

مثال: (مطالعه موردی): در مطالعه موردی که در این پژوهش انجام شده‌است، پارامترهای دسته دوم انتخابی به شرح ذیل است:


- شتاب در جهات مختصات مختلف (به عنوان مثال، محورهای X, Y, Z)

در مرحله بعدی، ما همبستگی بین پارامترها را در هر دسته ارزیابی می‌کنیم. عاقلانه است که یک پارامتر واحد از پارامترهایی که همبستگی بالایی در یک دسته دارند، انتخاب کنیم و بقیه را کنار بگذاریم. برای شناسایی وابستگی‌های متقابل بین داده‌ها، از ضریب همبستگی پیرسون استفاده می‌کنیم که از ۱- تا ۱ است.

در ادامه نمونه‌ای از ماتریس همبستگی نشان داده شده است که جهت ایجاد این ماتریس از تابع همبستگی نرم افزار پایتون استفاده شده‌است. ما داده‌ها تستی دریافتی از پرواز کوادکوپتر را به تفکیک پارامترهای اشاره شده بالا به نرم افزار دادیم که نتیجه به شرح شکل ۳ نشان داده شده‌است.



شکل ۳- ماتریس همبستگی بین پارامترهای یک کوادکوپتر.



شکل ۲- نمونه ای از DS های مجاور

- **خطا:** عواملی که باعث انحراف سیستم از عملکرد مورد انتظار می‌شود. این عوامل را می‌توان به عنوان عوامل داخلی و خارجی طبقه‌بندی کرد. به عنوان مثال:

- اگر کوادکوپتر به درستی کالیبره نشده باشد.
- اگر کوادکوپتر نتواند به حد مطلوب برسد.
- اگر عوامل خارجی مانند باد یا اجسام خارجی کوادکوپتر را از مسیر مورد نظر خود منحرف کند.

۴- مراحل اجرای مدل

مدل پیشنهادی از روش شناسی چهار مرحله‌ای استفاده می‌کند.

مرحله ۱: این مرحله بر شناسایی مناسب‌ترین پارامترهای قابل اندازه گیری از طریق استفاده از حسگرهای موجود در سیستم یا قابل استقرار در آن تمرکز دارد. این پارامترها به دو دسته اصلی طبقه‌بندی می‌شوند:

- **دسته اول:** پارامترهایی که وضعیت لحظه‌ای سیستم را بازگو می‌کند که می‌تواند هم عوامل مرتبط با سیستم مانند سرعت، زاویه انحراف، شتاب و ... و هم عوامل خارجی سیستم مانند دمای هوا، غلظت هوا، گرانش زمین و ... را شامل شود.


مثال: (مطالعه موردی): در مطالعه موردی که در این پژوهش انجام شده‌است، پارامترهای دسته اول انتخابی به شرح ذیل است:

- شتاب گرانش
- سیگنال کنترل اپراتور

- **دسته دوم:** این پارامترها نشان‌دهنده پاسخ سیستم به وضعیت فعلی است و به عنوان شاخص‌های قابل اندازه‌گیری


پارامتر ژيروسکوپ Z در تخمین شتاب خطی Y تغییر ناپیزی در دقت محاسبات ایجاد می کند که صرفا ضریب تعیین (R^2) از ۰/۹۹۹۹۸۴ به ۰/۹۹۹۹۰۷ تغییر کرده است. همچنین تجربه نشان می دهد که پارامترهایی با ضریب همبستگی بالای ۰/۸ با یکدیگر تاثیر مشابهی بر برازش پارامتر هدف دارند، لذا حذف یکی از آنها از افزونگی در فرایند محاسبه جلوگیری می کند.

R^2 : 0.999984, MAE: 0.000426, MSE: 1.08660, RMSE: 0.001042



(الف)

: 0.999907, MAE: 0.00094, MSE: 6.67973, RMSE: 0.00258



(ب)

شکل ۵- (الف) مقدار تخمینی شتاب خطی Y با در نظر گرفتن گرانش Y و گرانش Z، (ب) مقدار تخمینی شتاب خطی Y با در نظر گرفتن گرانش Y.

روش های دیگری نیز در راستای انتخاب پارامتر مناسب که ممکن است نتایج بهتری نیز ارائه نماید وجود دارد که از مراجع مختلف قابل مطالعه است [۷].

شتاب خطی X (LINEAR ACCELERATION X):


شکل ۶ نشان می دهد که پارامترهای گرانش Y، گرانش Z و ژيروسکوپ X ارتباط معنی داری با شتاب خطی X ندارند لذا از محاسبات حذف شدند.

در مطالعه موردی ما، ماتریس همبستگی استخراج شده از داده های جمع آوری شده از طریق حسگرهای یک کوادکوپتر در شکل ۳ نشان داده شده است. این داده ها به طور خاص به حرکت رو به جلو کوادکوپتر در امتداد محور Y مربوط می شود. شکل ها و توضیحات اشاره شده بعدی در واقع تصویر بخش کوچکی از ماتریس همبستگی است که برای روشن شدن روابط بین پارامترها بر محدوده مشخصی از جدول متمرکز شده است.

شتاب خطی Y (LINEAR ACCELERATION Y):

شکل ۴ نشان می دهد که سه پارامتر - گرانش X (GRAVITY X)، ژيروسکوپ Y (GYROSCOPE Y) و ژيروسکوپ Z (GYROSCOPE Z) - همبستگی قابل توجهی با شتاب خطی Y ندارند؛ در نتیجه، از محاسبات مربوط به شتاب خطی Y حذف شدند.

علاوه بر این، پارامترهای گرانش Y (GRAVITY Y) و گرانش Z (GRAVITY Z) یک همبستگی قوی دارند، لذا گرانش Z (GRAVITY Z) برای جلوگیری از افزونگی در فرایند محاسبات حذف می گردد.




شکل ۴- ماتریس همبستگی شتاب خطی Y.

بنابراین، پارامترهای نهایی در نظر گرفته شده برای محاسبه شتاب خطی Y، گرانش Y و ژيروسکوپ X هستند.


توصیه برای انتخاب پارامتر: توصیه می شود هر پارامتری که ضریب همبستگی کمتر از ۰/۲ با پارامتر هدف دارند حذف شود، زیرا به دقت برازش مدل کمک چندانی نمی کند. به عنوان مثال، همانطور که در شکل ۵ و شکل ۴ Error! Reference source not found. نشان داده شده است حذف

شتاب خطی Z انتخاب می‌شوند.



شکل ۸- ماتریس همبستگی شتاب خطی Z.

نتیجه برازش شتاب خطی Z با در نظر گرفتن دو پارامتر گرانش Z و ژيروسکوپ Z در شکل ۹ نشان داده شده‌است.




شکل ۹- مقدار تخمینی شتاب خطی Z.

مرحله ۲: در این مرحله، DS های مختلفی ایجاد می‌کنیم و با استفاده از کتابخانه Sci-Kit-Learn در محیط برنامه نویسی پایتون، یک تابع رگرسیون غیرخطی را بر هر مجموعه تصمیم برازش می‌کنیم. در مطالعه موردی ما که یک کوادکوپتر است هر مجموعه تصمیم (DS) تمامی داده‌هایی است که در یک دستور مشخص از اپراتور (یعنی یک زاویه حرکت و مقدار شتاب مشخص) از سنسورهای سیستم دریافت می‌شود.


حذف DS ها غیرضروری و تکراری موجب می‌گردد داده های موجود در دسته‌ها کمتری قرار گیرند، لذا داده‌های بیشتر در هر DS خواهیم داشت که دقت برازش افزایش می‌دهد. برای این منظور در مطالعه موردی ما به دلیل تشابه و تقارن در محل قرارگیری موتورهای کوادکوپتر رفتار مشابهی در شرایط خرابی موتورها شاهد خواهیم بود و صرفاً زوایای انحراف متفاوت

علاوه بر این، یک همبستگی قوی بین ژيروسکوپ Y و گرانش X دیده می‌شود. لذا برای ساده کردن مدل و جلوگیری از افزونگی، ژيروسکوپ Y از محاسبات حذف شده‌است.



شکل ۶- ماتریس همبستگی شتاب خطی X.

لذا پارامترهای نهایی برای محاسبه شتاب خطی X، گرانش X و ژيروسکوپ Z در نظر گرفته می‌شود. نتیجه در شکل ۷ نشان داده شده‌است.



شکل ۷- مقدار تخمینی شتاب خطی X.

شتاب خطی Z (LINEAR ACCELERATION Z):

شکل ۸ نشان می‌دهد که پارامترهای گرانش X، ژيروسکوپ X و ژيروسکوپ Y ارتباط معنی داری با شتاب خطی Z ندارند، لذا از محاسبات حذف شده‌اند.

علاوه بر این، همبستگی قوی بین گرانش Y و گرانش Z وجود دارد؛ بنابراین مطابق رویکرد قبل گرانش Y حذف می‌شود و گرانش Z به دلیل ارتباط مستقیم آن با جا به جایی عمودی کوادکوپتر به عنوان پارامتر محوری تر باقی می‌ماند. لذا دو پارامتر گرانش Z و ژيروسکوپ Z در محاسبه نهایی برای

در کدام ناحیه قرار دارد استفاده می شود (معادله (۲))

$$\vec{a} = (x, y) \begin{cases} \text{Area 1} & x \geq y > 0 \\ \text{Area 2} & y \geq x > 0 \\ \text{Area 3} & y \geq -x > 0 \\ \text{Area 4} & -x \geq y > 0 \\ \text{Area 5} & -x \geq -y > 0 \\ \text{Area 6} & -y \geq -x > 0 \\ \text{Area 7} & -y \geq x > 0 \\ \text{Area 8} & x \geq -y > 0 \end{cases} \quad (2)$$

در این مطالعه موردی، به دلیل محدودیت سخت افزاری در دریافت فرمان اپراتور از طریق سنسورهای موجود ما حرکت به سمت بالا یا پایین (محور Z) را در نظر نگرفتیم.

مرحله ۳: برآورد پارامترهای هدف و مکانیسم هشدار

خطا


در این مرحله پارامترهای هدف به کمک برازشی که بر روی هر DS انجام شده تخمین زده می شود و در هر مرحله زمانی مدل انحراف را بررسی می کند که نحوه عملکرد مدل به شرح ذیل است:

تخمین پارامتر: در هر مرحله زمانی، مدل پارامتر هدف را بر اساس وضعیت فعلی و ورودی های اپراتور تخمین میزند. این تخمین به شدت به DS هایی که قبلاً تعریف شده متکی است. **بررسی انحراف:** پس از تخمین پارامتر هدف، مدل مقدار تخمین زده شده را با مقدار واقعی رخ داده شده مقایسه می کند. اگر انحراف قابل توجهی بین مقادیر پیش بینی شده و مشاهده شده وجود داشته باشد که برای مدت زمان مشخصی باقی بماند، مدل اعلام خطا خواهد کرد.

استفاده از DS های همسایه متقارن: در سناریوهایی که هیچ DS از پیش تعریف شده ای با سیگنال اپراتور مطابقت ندارد، مدل از DS های همسایه متقارن برای تخمین پارامتر هدف استفاده می کند. معادله (۳) چگونگی استفاده از DS های همسایه را نشان می دهد.

- i شماره پارامتری که در همسایگی تغییر داشته است.
- G_i اندازه سنسور هدف مجهول
- G_i^- اندازه سنسور هدف برای DS همسایگی متقارن پایین با تغییر نامین پارامتر
- G_i^+ اندازه سنسور هدف برای DS همسایگی متقارن بالایی با تغییر نامین پارامتر
- P_i مقدار پارامتر نام در DS مورد بررسی
- P_i^- مقدار پارامتر نام برای DS همسایگی متقارن پایین


خواهند بود؛ لذا امکان تجمیع این زوایا در یک DS وجود خواهد داشت. به عنوان مثال، شکل ۱۰ زوایای دستوری اپراتور را نشان می دهد که می توانند در یک DS قرار گیرند. بررسی ها نشان می دهد که در مطالعه موردی می توان تمامی جهت های دستوری اپراتور را در DS های بین زاویه ۰ تا ۴۵ تجمیع نمود و از ایجاد DS های غیر ضروری جلوگیری کرد.



شکل ۱۰- بردارهای نمونه ای که می توانند در یک DS مشترک گنجانده شوند.

به عنوان مثال، برای در نظر گرفتن بردار $(\vec{a'})$ در محدوده ۰ تا ۴۵ درجه، لازم است تغییراتی در علامت مقادیر X و Y ایجاد کنیم. این تنظیم را می توان از طریق ضرب ماتریس با ماتریس تبدیل $\begin{bmatrix} -1 & 0 \\ 0 & -1 \end{bmatrix}$ ، همانطور که در شکل ۱۱ و معادله (۱) نشان داده شده است، به دست آورد.

$$\begin{aligned} (x, y) = \vec{a} = \vec{a'} \times \begin{bmatrix} -1 & 0 \\ 0 & -1 \end{bmatrix} &= (-x', -y') \\ (x, y) = \vec{a} = \vec{a''} \times \begin{bmatrix} -1 & 0 \\ 0 & +1 \end{bmatrix} &= (-x'', y'') \end{aligned} \quad (1)$$



شکل ۱۱- ضرایب برداری هر محدوده.

تابع زیر برای تعیین اینکه شتاب ارسال شده توسط اپراتور

بررسی و نظارت کند. در اینجا یک رویکرد مشخص برای نحوه بررسی انحرافات و اعلام خطا برای اطمینان از قابلیت اطمینان و دقت سیستم آورده شده است:

پیش بینی مداوم و مدیریت انحراف

(۱) پیش بینی پیوسته: مقادیر سنسور هدف به طور پیوسته بر اساس آخرین ورودی داده ها و شرایط سیستم پیش بینی می شوند.

(۲) آستانه انحراف:

سطح مشکوک: اگر انحراف بین مقادیر اندازه گیری شده و پیش بینی شده از سه برابر انحراف استاندارد (۳σ) بیشتر شود، سیستم این را به عنوان یک رویداد مشکوک علامت گذاری می کند.

سطح خطا: به طور کلی انحراف بیش از چهار برابر انحراف استاندارد (۴σ) توسط مدل به عنوان خطا طبقه بندی می شود. این رویکرد تضمین می کند که سیستم فقط اختلافات قابل توجه را شناسایی کند.

مکانیسم گزارش خطا

(۱) قرار داشتن مستمر سیستم در وضعیت مشکوک: اگر سیستم به طور مداوم در یک بازه زمانی مشخص در وضعیت مشکوک باقی بماند به این معنی است که سیستم در وضعیت اختلالات تصادفی نیست و نیازمند توجه بیشتری است.

(۲) محاسبه میانگین انحراف: سیستم در کنار پیگیری مدت زمان مشکوک، میانگین مقدار انحرافات را در این دوره محاسبه می کند.

(۳) گزارش خطا: اگر سیستم به طور پیوسته قرائت های مشکوک را ثبت کند و میانگین انحراف محاسبه شده از آستانه خطای از پیش تعریف شده فراتر رود، یک گزارش خطا راه اندازی می شود.

این رویکرد ساختار یافته تضمین می کند که سیستم با شناسایی دقیق و گزارش خطاهای واقعی قابل اعتماد باقی بماند.

مرحله ۴: مجموعه اولیه DS های موجود در مدل ممکن است تمام رفتارهای ممکن سیستم را پوشش ندهد؛ بنابراین سیستم باید انعطاف پذیر و سازگار با شرایط جدید باشد که مستلزم یک مرحله بازآموزی مداوم است. این فرآیند بازآموزی مداوم به سیستم اجازه می دهد تا یاد بگیرد و با سناریوهای جدید سازگار شود.


P_i^+ مقدار پارامتر نام برای DS همسایگی متقارن بالایی
 E مقدار انتظاری

$$G_i = E \left(\left(\frac{G_i^- \times |P_i^- - P_i| + G_i^+ \times |P_i^+ - P_i|}{|P_i^+ - P_i|} \right) \right) \quad (3)$$

For All $i \in I$

بهبود و اضافه نمودن DS: اگر مدل هیچ خطایی را تشخیص ندهد، اقدام به اضافه نمودن نتایج پارامترهای اندازه گیری شده به DS مربوط به آن وضعیت می کند. اگر DS وجود نداشته باشد، DS جدیدی ایجاد می گردد. این ویژگی به مدل اجازه می دهد تا به طور مداوم قابلیت های تصمیم گیری خود را اصلاح و گسترش دهد.

آموزش و داده های اولیه مورد نیاز: یکی از پیش نیازهای اولیه مدل برای راه اندازی آن است که حداقل داده مورد نیاز دو مجموعه تصمیم پایین ترین و بالاترین در دسترس باشد؛ زیرا در ادامه مدل به کمک روش مجموعه تصمیم همسایگی و ایجاد مجموعه تصمیم جدید اطلاعات خود را توسعه و غنی تر می کند. برای مثال در مطالعه موردی ما، داشتن اطلاعات اولیه دو DS در زوایای ۰ و ۴۵ درجه که پایین و بالاترین مجموعه DS ما هستند ضروری است. شکل ۱۲ همچنین رفتار سیستم در دو شتاب صفر و حداکثر شتاب نیز در این دو زاویه لازم خواهد بود. این داده ها به مدل کمک می کند تا به طور مؤثر بتواند DS های میانی را با دقت و استحکام بیشتری تخمین بزند.



شکل ۱۲- حداقل تعداد DS های مورد نیاز.

در حالت عملیاتی، سیستم به طور مداوم مقادیر سنسور هدف را پیش بینی می کند تا هر گونه اختلاف را در لحظه

صرفاً به صورت کنترل شده دستور حداکثر شتاب اپراتور به سمت جلو را بررسی نمودیم.



شکل ۱۴- گوشی HTC-Desire-C

در این مطالعه، تمرکز اولیه بر روی میزان شتاب کوادکوپتر است که ذاتاً با جهت و اندازه سیگنال های کنترلی صادر شده توسط اپراتور مرتبط است؛ در نتیجه، داده های حسگر شتاب سنج به عنوان سنسور هدف تعیین می شود.

پارامترهای قابل اندازه گیری مربوط به مدل ما عبارتند از:

- ❖ شتاب ارسالی اپراتور (ACCELERATION SEND BY OPERATOR): این پارامتر مقدار و جهت شتابی را نشان میدهد که اپراتور به کوادکوپتر ارسال می کند که معمولاً به صورت بردار بیان می شود.
- ❖ گرانش (GRAVITY): این پارامتر شتاب گرانش زمین بر کوادکوپتر را نشان می دهد.
- ❖ ژيروسکوپ (GYROSCOPE): سرعت چرخش حول محورهای مختصات (X, Y, Z) را اندازه گیری می کند و داده های مهمی را در مورد تغییرات جهت گیری کوادکوپتر ارائه می کند.
- ❖ شتاب (ACCELERATION): این پارامتر شتاب حرکت کوادکوپتر در جهت محورهای مختصات (Z, Y, X) را نشان می دهد.
- ❖ شتاب خطی (LINEAR ACCELERATION): این پارامتر شتاب خالص حرکت سیستم را نشان می دهد، منظور از شتاب با حذف شتاب گرانش زمین است (معادله ۵)

$$\text{LINEAR ACCELERATION X} = \text{ACCELERATION X} - \text{GRAVITY X} \quad (5)$$

هنگامی که سیستم داده های جدید دریافت می کند، در صورت وجود DS مربوطه، این داده ها به مجموعه داده اضافه می شود. متعاقباً، فرآیند برازش عملکرد بر اساس DS به روز می شود. در صورتی که DS مربوطه وجود نداشته باشد، داده های استخراج شده تا رسیدن به حداقل تعداد مجاز DS که در این حالت ۳۰ نمونه است، ذخیره می شود.

قبل از استفاده از داده ها، بسیار مهم است که اطمینان حاصل شود که سیستم در هنگام جمع آوری داده ها در حالت خطا نبوده است. علاوه بر این، محدوده مجاز پذیرش سلامت سیستم که در معادله (۴) شرح داده شده است نیز بروز رسانی می شود. این فرآیند به روزرسانی به مدل کمک می کند تا در طول زمان دقیق تر و قابل اعتمادتر شود.

$$\sigma_{combined} = \sqrt{\frac{(\sigma_{old})^2 \cdot N_{old} + (\sigma_{new})^2 \cdot N_{new}}{N_{old} + N_{new}}} \quad (4)$$


۵- مطالعه موردی

برای اعتبارسنجی مدل، ما به شناسایی خطاهای احتمالی در موتورهای یک کوادکوپتر (مدل SYMA-X5SW) پرداختیم. شکل ۱۳ چون دسترسی به پردازنده داخلی کوادکوپتر دشوار بود ما داده های مربوط به سنسورها را با قراردادن یک حسگر خارجی جمع آوری نمودیم بدین صورت که با کمک گرفتن از نرم افزار AndroSensor و گوشی هوشمند HTC-Desire-C داده های مربوط به سنسورهای جمع آوری شد، شکل ۱۴.



شکل ۱۳- کوادکوپتر سیما مدل X5sw

چون داده مربوط به دستور اپراتور در دسترس نبود ما



شکل ۱۵: هر پارامتر اندازه گیری شده، شامل تمام ۵۰ مشاهدات است.

می‌توان به عنوان موضوع پژوهش‌های آتی تعریف گردد.

روش‌های استخراج شده از ChatGPT برای پیش‌بینی روابط غیرخطی

- ویژگی‌های چند جمله‌ای (Polynomial Features)
 - مدل رگرسیون، ماشین برداری پشتیبانی (SVM^۱)
 - کتابخانه Keras برای ایجاد یک شبکه عصبی برای رگرسیون
 - مدل رگرسیون درخت تصمیم
 - مدل رگرسیون فرایند گاوسی (Gaussian)
 - رگرسیون کرنل ریج (KRR^۲)
- برای تجزیه و تحلیل دقیق، ما به طور خاص بر روی مولفه‌های شتاب کوادکوپتر در سه جهت اصلی (X,Y,Z) تمرکز کردیم که هر یک پارامتر هدف جداگانه‌ای در نظر گرفته می‌شوند. ما رگرسیون غیر خطی را به طور مستقل برای هر DS برآزش می‌کنیم. پارامترهای هر DS مشخص شده در مرحله ۴، به دقت کالیبره شدند تا عملکرد پیش‌بینی مدل را بهینه کنند. (همانطور که اشاره شد، هر DS مجموعه داده‌هایی است که در بازه ارسال جهت و مقدار شتاب مشخص توسط اپراتور ثبت شده باشد).

نتایج این ارزیابی‌ها که هم شامل انتخاب‌های روش‌شناختی و هم نتایج تحلیل‌های رگرسیونی است، در زیر ارائه می‌شود. این یافته‌ها نه تنها کاربرد عملی روش انتخابی ما را نشان می‌دهند، بلکه به توسعه مدل‌های پیش‌بینی در

ما داده‌ها را از حسگرهای یک کوادکوپتر در شرایط یک سیگنال فرمان کنترل‌شده از اپراتور جمع‌آوری کردیم، با این ملاحظه که داده‌ها در شرایط محیطی محدود، پایدار و عاری از تأثیرات خارجی مانند باد جمع‌آوری شده‌است. برای اطمینان از سلامت داده‌ها، اندازه‌گیری‌ها در حالی که سیستم در شرایط ایده آل خود قرار داشت، دریافت شده است. جمع‌آوری داده‌ها در فواصل ۰/۰۰۵ ثانیه در ۵۰ آزمایش پرواز انجام شده‌است. (شکل ۱۵)

ما از کتابخانه Sci-Kit-Learn برای پیاده‌سازی یک مدل رگرسیون غیر خطی با هدف تخمین مقدار لحظه‌ای پارامتر هدف (شتاب کوادکوپتر) استفاده کردیم. داده‌ها به طور سیستماتیک به دو دسته می‌شوند: مجموعه داده آموزشی که برای توسعه مدل استفاده می‌شود و مجموعه داده آزمون که برای ارزیابی عملکرد آن استفاده می‌شود. این تقسیم‌بندی، ارزیابی مدل را با مقایسه مقادیر پیش‌بینی‌شده با اندازه واقعی تسهیل می‌کند، بنابراین امکان وجود دارد که کارایی مدل سنجیده شود.

برای انتخاب بهترین روش برآورد پارامتر هدف، ما از ChatGPT برای استخراج روش‌های مختلف مورد استفاده محققان و بررسی کیفیت پاسخ آنها در مساله مورد بررسی ما استفاده نمودیم. بر اساس توصیه‌های آن، که هم سرعت پردازش و هم دقت را در نظر گرفته است، روش چند جمله‌ای روش انتخابی ما برای مطالعه است. عملکرد سایر روش‌های نیز

^۲ Kernel Ridge Regression


^۱ Support Vector Machine

(بازوی شماره ۳) وصل کردیم. این اقدام برای شبیه سازی عملکرد غیرعادی موتور شماره ۳ طراحی شده است. (شکل ۱۶)



شکل ۱۶: نحوه قرار گیری واشر آهنی

شکل ۱۷ اختلاف بین رفتارهای پیش بینی شده و واقعی سیستم در سه محور اصلی X، Y و Z را در هنگام وقوع خرابی نشان می دهد.



شکل ۱۷: مقایسه پارامترهای شتاب در سلامت سیستم و وضعیت خطا

برای جلوگیری از این خطا، ما حداکثر مدت زمان مورد نیاز کوادکوپتر برای انتقال از حالت عملیاتی قبلی به حالت تعادل را محاسبه می کنیم. ما این فاصله زمانی را برابر زمان مورد نیاز کوادکوپتر برای انتقال از نقطه حداکثر شتاب اپراتور (نقطه A) به حالت تعادل (نقطه B) در نظر گرفتیم. (شکل ۱۸)


سیستم های پویا کمک می کنند. از طریق این رویکرد، ما قصد داریم یک چارچوب جامع و علمی قوی برای پیش بینی دقیق رفتارهای سیستم های مکانیکی پیچیده مانند کوادکوپترها ارائه نماییم.

بررسی های انجام شده در مطالعه ما سطح دقت قابل پذیرشی را در تخمین پارامتر شتاب سیستم در تمام محورهای مختصات نشان می دهد. این سطح دقت بیان کننده اثربخشی مدل رگرسیون غیر خطی است که با استفاده از داده ها و روش های مشخص شده آموزش داده شده است. با ایجاد این دقت پایه، مرحله بعدی تحقیق ما شامل ارزیابی قابلیت مدل در تشخیص خطا در سیستم است.

۵-۱- ایجاد شکست کنترل شده

برای ارزیابی عملکرد مدل در تشخیص عیوب ما یک واشر آهنی با سایز M10 و وزن ۳/۵ گرم به زیر یکی از بازوهای کوادکوپتر

موقعیتی را در نظر بگیرید که در آن کوادکوپتر به سمت نقطه خاصی در حال حرکت است و ناگهان اپراتور فرمان دیگری را صادر می کند که آن را در جهت دیگری هدایت می کند. در این شرایط، وضعیت فیزیکی کوادکوپتر به دلیل دستور قبلی در حالت تعادل و افقی نیست، لذا در مدل پیشنهادی شاهد اختلاف قابل توجه بین مقادیر پیش بینی شده پارامتر هدف و مقدار واقعی خواهیم بود.



شکل ۱۸: حداکثر فاصله زمانی برای رسیدن کوادکوپتر به تعادل.

(۳) وقتی سیگنال توسط اپراتور تغییر داده می‌شود، تنها یک ثانیه اول داده‌های دریافتی حذف و مابقی داده‌ها بر حسب زمان وقوع به صورت سری به یکدیگر متصل می‌شوند تا در تحلیل استفاده شوند.

(۴) اگر انحراف بین مقادیر پیش‌بینی‌شده و واقعی از $\pm 4\sigma$ برای یک دوره مداوم ۲ ثانیه‌ای بیشتر شود، خطا اعلام می‌شود (دوره ۲ ثانیه‌ای به مجموعه داده‌های جمع‌آوری‌شده که یک ثانیه اول پس از تغییر سیگنال در هر جهت از آنها حذف شده باشد).

شکل ۱۹ رفتار انحراف بین مقادیر واقعی شتاب و مقادیر پیش‌بینی شده را در شرایط عادی سیستم و در طول وقوع خطای دستی ایجاد شده بالا نشان می‌دهد.

مدل توسعه داده شده ما توانسته به طور موثر خطای دستی ایجاد شده بر سیستم را در هر سه جهت مختصات شناسایی کند. شایان ذکر است که این نتیجه بدون تکیه بر دانش تخصصی از سیستم کوادکوپتر به دست آمد. این قابلیت مدل تطبیق پذیری و پتانسیل روش ما برای تشخیص خطا (FD) و پیش‌بینی در سیستم‌های مختلف را برجسته می‌کند.


برای شناسایی حداکثر زمان لازم برای بازگشت کوادکوپتر به وضعیت تعادل خود، ما فرمان حداکثر شتاب و توقف ناگهانی را بارها و در امتداد یکی از محورها مختصات اجرا کردیم. مدت زمان مورد نیاز برای بازگشت سیستم به حالت تعادل پس از هر اجرا اندازه گیری شد. برای تعیین این مدت، از بررسی مقدار سنسور شتاب گرانش حول محور Z (GRAVITY Z) استفاده کردیم.

به طور خاص، ما زمان لازم برای حرکت سیستم را از حداقل مقدار شتاب گرانشی حول محور Z - که نشان دهنده حداکثر شیب کوادکوپتر است - به حداکثر مقدار آن $9/8$ محاسبه کردیم، که نشان‌دهنده نقطه تعادل کوادکوپتر است. این دوره انتقال به طور مداوم حدود $0/94$ ثانیه بود.

بر اساس توضیحات فوق، تحلیل به شرح زیر انجام شد:

(۱) همانطور که قابل مشاهده است حداکثر $0/94 \approx 1$ ثانیه برای رسیدن سیستم به حالت تعادل لازم است؛ بنابراین، اولین ثانیه پس از تغییر سیگنال توسط اپراتور، داده‌های تحریف شده در نظر گرفته می‌شود و از محاسبات حذف می‌شود.

(۲) داده‌های باقی مانده قابل قبول تلقی می‌شود.



شکل ۱۹: مقدار شتاب برآورد شده و شتاب واقعی سیستم در جهت (الف) بردار X ، (ب) بردار Y ، (پ) بردار Z .

۶- نتیجه گیری

روش های سنتی FD به شدت نیازمند دانش و تجهیزات تخصصی و نظارت افراد خبره است و به طور معمول برای سیستم های ثابتی طراحی می شوند، لذا اغلب محدود به تشخیص طیف محدودی از خطاها هستند. ما سعی داریم در مطالعه خود، با به کارگیری یک رویکرد مبتنی بر داده و استفاده موثر از ابزارهای یادگیری ماشین (ML) به شناسایی خطا در سیستم پردازش با این ملاحظه که حداقل نیاز به درک عمیق از سیستم یا تخصص فنی گسترده از سیستم وجود داشته باشد. روش شناسی ما شامل مدل سازی روابط بین متغیرهای مختلف سیستم با استفاده از حداقل مجموعه پارامترهای قابل اندازه گیری است. ما یک مدل FD را ارائه

نمودیم که صرفاً از داده های سیستم در شرایط سلامت خود استفاده می کند به این معنی که نیاز به اندازه گیری پارامترها در شرایط خطا و آموزش مدل در این شرایط وجود ندارد؛ لذا مدل ما برای شناسایی خطاهای شناخته شده و ناشناخته طراحی شده است.

به طور خاص در این مدل ما به صورت لحظه ای به بررسی میزان انحراف مقدار انتظاری پارامتر هدف سیستم از مقدار واقعی اندازه گیری می پردازیم و در صورت مشاهده یک انحراف قابل توجه به عنوان یک خطا علامت گذاری می شود.

چون رویکرد مدل آن است که صرفاً بر داده های مربوط به وضعیت سلامت سیستم تکیه می کنیم، لذا امکان تشخیص ناهنجاری هایی که قبلاً با آن مواجه نشده یا تعریف نشده نیز

- [4] Feierl, L., Unterberger, V., Rossi, C., Geradts, B., & Gaetani, M. (2023). Fault Detective: Automatic Fault-Detection for Solar Thermal Systems based on Artificial Intelligence. *Solar Energy Advances*, 100033.
- [5] Yairi, T., Kawahara, Y., Fujimaki, R., Sato, Y., & Machida, K. (2006). Telemetry-mining: a machine learning approach to anomaly detection and fault diagnosis for space systems. Paper presented at the 2nd IEEE International Conference on Space Mission Challenges for Information Technology (SMC-IT'06), pp. 8 pp.-476.
- [6] Ahmad, M. W., Reynolds, J., & Rezgui, Y. (2018). Predictive modelling for solar thermal energy systems: A comparison of support vector regression, random forest, extra trees and regression trees. *J. cleaner production*, 203, 810-821.
- [7] Cheliotis, M., Lazakis, I., & Theotokatos, G. (2020). Machine learning and data-driven fault detection for ship systems operations. *Ocean Engineering*, 216, 107968.
- [8] Bode, G., Thul, S., Baranski, M., & Müller, D. (2020). Real-world application of machine-learning-based fault detection trained with experimental data. *Energy*, 198, 117323.
- [9] Li, Y. (2022). Exploring real-time fault detection of high-speed train traction motor based on machine learning and wavelet analysis. *Neural Computing and Applications*, 34(12), 9301-9314.
- [10] Abdelgayed, T. S., Morsi, W. G., & Sidhu, T. S. (2017). Fault detection and classification based on co-training of semisupervised machine learning. *IEEE Transactions on Industrial Electronics*, 65(2), 1595-1605.
- [11] Amruthnath, N., & Gupta, T. (2018). A research study on unsupervised machine learning algorithms for early fault detection in predictive maintenance. Paper presented at the 2018 5th international conference on industrial engineering and applications (ICIEA).
- [12] Sievers, M., & Madni, A. M. (2016). Agent-based flexible design contracts for resilient spacecraft swarms. Paper presented at the 54th AIAA aerospace sciences meeting, p. 0476.
- [13] Abbasi, M. A., Khan, A. Q., Abid, M., Mustafa, G., Mehmood, A., Luo, H., & Yin, S. (2020). Parity-based robust data-driven fault detection for nonlinear systems using just-in-time learning

وجود خواهد داشت. جهت صحت گذاری مدل ما عملکرد مدل را بر روی یک کوادکوپتر مورد بررسی قرار دادیم. نتایج نشان می دهد که رویکرد ما می تواند به طور نسبتاً موثری خطاهای کنترل شده وارد شده به سیستم را تشخیص دهد.

یکی از مزایای کلیدی این روش، کاربرد آن در سیستم های مختلف بدون نیاز به تخصص مرتبط با سیستم است، که باعث می شود آن را بسیار متنوع و آسان با حداقل زمان و هزینه پیاده سازی کرد.

این بستر برای مطالعات آتی وجود دارد که پس از آگاهی از وقوع خطا، با شناسایی مکان دقیق خطا و انتخاب اقدامات اصلاحی مرتبط، بتواند سیستم را به سمت یک سیستم تاب آور تبدیل نماید.

علاوه بر این، مجموعه های تصمیم (DS) مورد استفاده در سیستم FD ما می تواند با در نظر گرفتن پارامترهای کلیدی بهبود یابد. به عنوان مثال، ادغام یک سنسور فشار هوا یا ارتفاع در مجموعه داده های کوادکوپتر می تواند DS ها را غنی تر کند و دقت و قابلیت اطمینان مدل را بهبود بخشد. این گسترش نه تنها قابلیت های تشخیص خطا را اصلاح می کند، بلکه دامنه کاربردها را نیز گسترش می دهد و سیستم FD را در محیط های عملیاتی متنوع سازگارتر و قوی تر می کند؛ همچنین بررسی عملکرد سایر روش های برازش جهت پیش بینی پارامترهای هدف نیز می توان به عنوان موضوع پژوهش های آتی در نظر گرفته شود.

۶- مراجع

- [1] Bektash, O., & la Cour-Harbo, A. (2020). Vibration analysis for anomaly detection in unmanned aircraft. Paper presented at the Annual Conference of the Prognostics and Health Management Society 2020.
- [2] Cheng, D.-L., & Lai, W.-H. (2019). APPLICATION OF SELF-ORGANIZING MAP ON FLIGHT DATA ANALYSIS FOR QUADCOPTER HEALTH DIAGNOSIS SYSTEM. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*.
- [3] Zhang, X., Zhao, Z., Wang, Z., & Wang, X. (2021). Fault detection and identification method for quadcopter based on airframe vibration signals. *Sensors*, 21(2), 581.

- [20] Yang, L., Li, S., Li, C., Zhu, C., Zhang, A., & Liang, G. (2023). Data-driven unsupervised anomaly detection and recovery of unmanned aerial vehicle flight data based on spatiotemporal correlation. *Science China Technological Sciences*, 66(5), 1304-1316.
- [21] Doostmohammadian, M., Zarrabi, H., & Charalambous, T. (2023). Sensor fault detection and isolation via networked estimation: rank-deficient dynamical systems. *Int. J. Cont.*, 96(11), 2853-2870.
- [۲۲] ایوقی م.و، دلی ع. ش. (۲۰۲۳). مدل های مبتنی بر یادگیری عمیق در شناسایی سیستم های غیرخطی. *مجله کنترل*, ۱۷(۲), ۱-۲۳.
- [۲۳] یعقوبی ع، محمدی م. (۲۰۲۴). تشخیص خطا با استفاده از شبکه عصبی در روتور تمایل یابنده. *نشریه مهندسی مکانیک امیرکبیر*, ۵۶(۳), ۳۲۱-۳۴۴.
- [۲۴] مرزبالی ح.م، حسنی س، مشایخی ه، مشایخی و. (۲۰۲۱). استخراج ویژگی به کمک یادگیری عمیق برای تشخیص و دسته بندی خطاهای مکانیکی یاتاقان در ماشین های القایی قفس سنجایی. *مکانیک سازه ها و شاره ها*, ۱۱(۵), ۳۳-۴۸.
- approach. *Transactions of the Institute of Measurement and Control*, 42(9), 1690-1699.
- [14] Cao, W., Cong, W., & Sun, M. (2012). Iterative learning based fault detection and estimation in nonlinear systems. *J. Sys. Eng. Elec.*, 23(3), 419-424.
- [15] Zeng, C., Chen, T., Xing, M., & Wang, Y. (2024). Fast fault detection for nonlinear interconnected systems via deterministic learning. *Transactions of the Institute of Measurement and Control*, 46(4), 624-637.
- [16] Park, K. H., Park, E., & Kim, H. K. (2021). Unsupervised fault detection on unmanned aerial vehicles: Encoding and thresholding approach. *Sensors*, 21(6), 2208.
- [17] Zhu, Z., & Jiao, X. (2012). Fault detection for nonlinear networked control systems based on fuzzy observer. *J. Sys. Eng. Elect.*, 23(1), 129-136.
- [18] Puchalski, R., & Giernacki, W. (2022). UAV fault detection methods, state-of-the-art. *Drones*, 6(11), 330.
- [19] López-Estrada, F., Méndez-López, A., Santos-Ruiz, I., Valencia-Palomo, G., & Escobar-Gómez, E. (2021). Fault detection in unmanned aerial vehicles via orientation signals and machine learning. *Revista iberoamericana de automática e informática industrial*, 18(3), 254-264.