کاربرد هوش مصنوعی در تشخیص خطای آسانسور

مهران شیخی کاریزکی[۱]، حلیمه شمشیری[۲]

[۱] دانشجوی دکتری مهندسی برق، گرایش مخابرات-سیستم، دانشگاه بیرجند، mehran369sh@yahoo.com

[۲] کارشناسی ارشد مهندسی کامپیوتر، گرایش هوش مصنوعی، h.shamshiry@yahoo.com

چکیده: با احداث ساختمان‌های بلند در سال‌های اخیر، آسانسور در زندگی اغلب مردم استفاده می‌شود و اهمیت آسانسورها بیشتر و مهم‌تر شده است. مسئله مهم در سیستم‌های آسانسور تشخیص زودهنگام خطای آسانسور می‌باشد. روش‌های تشخیص خرابی یا خطای آسانسور برای تضمین جان و مال افراد از اهمیت ویژه‌ای برخوردار است. تکنیک‌های هوش مصنوعی از فناوری‌های مهم قرن بیست و یکم در تشخیص خطای آسانسور می‌باشند که در این مقاله از دو جنبه نظری و کاربردی مورد بحث و بررسی قرارگرفته اند. الگوریتم‌های هوش مصنوعی مورداستفاده در این مقاله شبکه عصبیBP ،شبکه عصبی RBF و الگوریتم‌های SVM و K-means می‌باشند. بعد از تعیین الگوریتم‌ها به بررسی کاربرد آن‌ها و هوش مصنوعی در تشخیص خطای آسانسور پرداخته شده است. سرانجام، روند توسعه احتمالی هوش مصنوعی در تشخیص خطای آسانسور در آینده مورد بحث قرار گرفته است.

کلیدواژه‌ها: *آسانسور، الگوریتم، تشخیص خطا، هوش مصنوعی*

مقدمه

با پیشرفت سریع علم و فناوری، ایمنی دستگاه‌های مورداستفاده روزمره نسبت به گذشته از اهمیت بیشتری برخوردار شده است که آسانسورها هم از این موضوع مستثنی نیستند و در شرایط کنونی، حوادث ناشی از آسانسورها مانند به دام افتادن افراد و سقوط آسانسور و قطع شدن برق و غیره زیاد اتفاق می‌افتد [۱]. بنابراین در این مقاله به مطالعه چگونگی بهبود راه‌های تشخیص خطای آسانسور، برای نجات به‌موقع و کاهش میزان تلفات حادثه با استفاده از الگوریتم‌های هوش مصنوعی پرداخته‌ایم. روش معمول برای کاهش میزان حوادث آسانسور، کاهش میزان ریسک خرابی آسانسور مطابق با ارزیابی عملکرد آسانسور می‌باشد[۲]. که نتیجه آن، بهبود قابلیت اطمینان آسانسور و کاهش میزان حادثه بوده است. بااین‌وجود، به دلیل تعداد زیاد آسانسورها، انجام این روش کار دشواری می‌باشد؛ بنابراین، Chen و همکاران[۳]. روش جدید محاسبه ریسک با ریاضیات فازی را برای محاسبه مقدار ریسک سیستم آسانسور پیشنهاد دادند. در عصر داده‌های بزرگ، با توسعه تکنولوژی‌های داده‌کاوی [۴]، تکنولوژی هوش مصنوعی به‌عنوان منبع اطلاعات Real time می‌تواند روشی مؤثر برای تشخیص خطای آسانسورها و کاهش میزان حوادث در آسانسورها باشد. به‌طورکلی استفاده از فناوری هوش مصنوعی برای تشخیص خطاهای آسانسور دارای چهار مرحله اصلی است: (۱) انتخاب مدل، (۲) استخراج ویژگی، (۳) بهینه‌سازی و آموزش مدل و (۴) تشخیص الگوی خطای آسانسور.

از فناوری هوش مصنوعی به‌طور گسترده در تشخیص انواع مختلف نقص‌های مکانیکی استفاده شده است. به‌عنوان‌مثال، Chan [۵]از الگوریتم K-Means بهبودیافته به‌منظور تجزیه‌وتحلیل وضعیت میزان خرابی آسانسورهای مختلف استفاده می‌کند. در [۶] توسط Li و همکاران، روشی برای تشخیص خطای سیستم درب آسانسور بر اساس شبکه عصبی BP پیشنهاد شده است. Tian و همکاران [۷]. برای دستیابی به تشخیص به‌موقع خطاها از طریق کوتاه‌ترین مسیر، روش بهینه‌سازی کلونی مورچگان بهبودیافته را ارائه دادند. Gao [۸]، نتایج آموزش دو الگوریتم شبکه عصبی BP و شبکه عصبی RBF را مقایسه نموده که نتیجه مقایسه

نشان داد، شبکه عصبی RBF از لحاظ سرعت آموزش، سریع‌تر از شبکه عصبی BP می‌باشد و قابلیت تعمیم بهتری دارد. سپس از شبکه عصبی RBF برای تأیید تشخیص خطای کمپرسور هوا استفاده می‌شود. نتایج آزمایش نشان می‌دهد که شبکه عصبی RBF می‌تواند نوع خطای کمپرسور هوا را به‌طور دقیق پیش‌بینی کند. Shen [۹] ترکیب وضعیت Real time عملکرد آسانسور را با ماشین حالت محدود (FSM) بر پایه جریان داده استفاده می‌کند تا قضاوت کند که آیا خطا در حین عملکرد آسانسور رخ می‌دهد یا خیر. سپس او از مدل Net Series مبتنی بر سری‌های زمانی استفاده می‌کند تا با سایر مدل‌های یادگیری ماشین مانند ماشین بردار پشتیبانی (SVM)، حافظه کوتاه‌مدت (LSTM) و شبکه‌های عصبی پیچشی کاملاً محکم (UFCNN) مقایسه کند. این ثابت می‌کند که مدل Net Series از تعمیم و همگرایی بهتری در تشخیص خطای آسانسور برخوردار است.

در این مقاله، هدف ما تحقیق و پژوهش الگوریتم‌های هوش مصنوعی برای تشخیص خطای آسانسور با دو روش نظری و کاربردی می‌باشد. در ادامه مقاله، بخش دوم چندین الگوریتم اصلی هوش مصنوعی مانند K-Means، SVM، BP و RBF را معرفی می‌کند. بخش سوم کاربردهای این الگوریتم‌های هوش مصنوعی را در تشخیص خطای آسانسور بررسی می‌کند. چشم‌انداز روش‌های هوش مصنوعی در تشخیص خطای آسانسور در بخش چهارم بحث شده است؛ و نتیجه‌گیری در بخش پنجم آورده شده است.

معرفی الگوریتم AI

در این بخش الگوریتم‌های کلی هوش مصنوعی برای تشخیص خطای آسانسور معرفی می‌شوند. امروزه به دلیل استفاده از سنسورهای دقیق، می‌توان اطلاعات مختلف آسانسور را به‌صورت پویا تحت نظارت داشت و الگوریتم‌ها نیازی به دانش قبلی ندارند و توانایی خودآگاهی قوی دارند. این الگوریتم‌ها می‌توانند اطلاعات مفید و مؤثری را از مجموعه داده‌ها استخراج کنند و سپس خطای آسانسور را تشخیص دهند.

شبکه عصبی BP

شبکه عصبی BP یکی از رایج‌ترین الگوریتم‌های تشخیص خطاهای مکانیکی می‌باشد که شامل یک لایه ورودی، چند لایه مخفی و یک لایه خروجی است. BP یک روش بازگشت به عقب می‌باشد که برای محاسبه گرادیان و تابع هزینه‌ی تمام وزن‌های شبکه می‌باشد. BP نیاز به یادگیری با نظارت دارد. با مشکل کمینه محلی (کوچک کردن تابع هزینه‌بر روی تمام داده‌ها) مواجه است که برای حل مشکل از روش گرادیان کاهشی استفاده می‌شود که هدفش پیدا کردن مجموعه وزن‌های بهینه می‌باشد. این شبکه عصبی از قابلیت نگاشت غیرخطی خوبی با عملکرد تعمیم عالی برخوردار می‌باشد. [۱۰و۱۱].

شبکه عصبی RBF

یک شبکه عصبی مصنوعی که از توابع پایه‌ای شعاعی به‌عنوان توابع فعالیت استفاده می‌کند و خروجی این شبکه یک ترکیب خطی از توابع پایه‌ای شعاعی برای پارامترهای ورودی و نرون ها است و این شبکه تابع تقریب و پیش‌بینی سری‌های زمانی و کلاس‌بندی و کنترل سیستم را انجام می‌دهد و دارای سه لایه: لایه ورودی، لایه مخفی با یک تابع فعالیت RBF خطی و لایه خروجی می‌باشد. در مقایسه با BP ساختار ساده‌تر و همگرایی بهتری دارد و می‌تواند کمینه محلی را بدون هیچ مشکلی تقریب بزند. شبکه عصبی RBF با تبدیل داده‌های ورودی از طریق یک تابع هسته، داده‌های ورودی را از حالت ورودی با بعد پایین به حالت ورودی با بعد بالاتر تبدیل می‌کند. درنتیجه، مسئله غیرخطی با بعد پایین را به یک مسئله تفکیک‌پذیر خطی با بعد بالاتر تبدیل می‌کند. به‌طور خلاصه، شبکه عصبی RBF با استفاده از واحد لایه مخفی پایه، فضای لایه مخفی را ایجاد می‌کند و با تابع هسته که همان نقطه شعاعی مرکزی متقارن است ترکیب می‌کند و به‌صورت کاهشی یکنواخت داده‌های ورودی به فضای قابل‌تفکیک خطی با بعد بالاتر نگاشت می‌یابد [۱۲].

الگوریتم SVM

SVM یک الگوریتم یادگیری با نظارت است که به دلیل پردازش عالی شناسایی الگو و رگرسیون اغلب برای حل مسائل کوچک تشخیص خطا در ابعاد بالاتر استفاده می‌شود [۱۳و۱۴]. یکی از الگوریتم‌های رایج در حوزه دسته‌بندی داده‌ها است، درواقع مجموعه‌ای از نقاط در فضای n بعدی داده‌ها هستند که مرز دسته‌ها را مشخص می‌کنند و مرزبندی و دسته‌بندی داده‌ها بر اساس آن‌ها است و با جابجایی یکی از آن‌ها خروجی دسته‌بندی تغییر می‌کند. هدفش یافتن بهترین و بهینه‌ترین مرز بین داده‌ها

است به‌گونه‌ای که بیشترین فاصله ممکن را از تمام دسته‌ها داشته باشد و یک نمودار بهینه ایجاد کند و برای مواردی که با دقت بسیار بالا نیاز به ماشین داده‌ها داریم، به‌شرط اینکه توابع نگاشت را به‌درستی انتخاب کنیم، بسیار خوب عمل می‌کند[۱۵].

الگوریتم K-means

K-means یکی از الگوریتم‌های یادگیری بدون نظارت است. اجرای آن ساده و آسان اما بسیار مؤثر است. عملکرد اصلی این الگوریتم طبقه‌بندی نمونه داده‌های مشابه در یک گروه با یکدیگر که کمترین تشابه با داده‌های خارج از خوشه خودشان را دارند می‌باشد. خوشه مرکزی را به‌طور تصادفی تولید می‌کند و خوشه متعلق به هر نقطه داده را طبق اصل کوتاه‌ترین فاصله اختصاص می‌دهد و سپس موقعیت خوشه مرکزی را بر اساس میانگین ارزش هر نقطه در خوشه تنظیم می‌کند. در مرحله بعد، طبق اصل کوتاه‌ترین فاصله تا زمانی که خوشه مرکزی دیگر تغییر نکند این تکرار ادامه می‌یابد. درنتیجه تابع هزینه را به حداقل می‌رساند و فرایند بهینه‌سازی باعث تغییر مکان خوشه مرکزی و انتساب هر نقطه در کوتاه‌ترین فاصله می‌شود [۱۶].

کاربرد الگوریتم‌های هوش مصنوعی در تشخیص خطای آسانسور

کاربرد شبکه عصبی BP در تشخیص خطای آسانسور

یکی از الگوریتم‌های معروف شبکه عصبی BP می‌باشد که به‌طور گسترده در پیش‌بینی غیرخطی، تشخیص خطا و شناسایی الگو بکار برده می‌شود. این الگوریتم دارای دو مشکل همگرایی و کمینه محلی است که در ترکیب با دیگر الگوریتم‌های بهینه‌سازی مانند بهینه‌سازی ازدحام ذرات (PSO)، الگوریتم ژنتیک(GA) ، تحلیل مؤلفه اساسی (PCA) و... این مشکلات را می‌توان حل نمود. Li و Ai[17]، شبکه‌های عصبی BP را که با استفاده از الگوریتم بیزین تنظیم شده است را با داده‌های ورودی فازی شده ترکیب می‌کند. سپس بر اساس تئوری شواهدD-S ، نتایج حاصل از شبکه عصبی BP ادغام می‌شوند. درنهایت تصمیم‌گیری تلفیقی عیب‌یابی از سیستم راه‌انداز و کشش آسانسور تکمیل می‌گردد. تصمیم‌گیری تلفیقی تشخیص خرابی دستگاه نتایج مطمئن‌تری را ارائه می‌دهد.

Wang[18]، از روش حذف نویز بیشینه ضرایب تبدیل موجک و پارامترهای مشخصه حرکت آسانسور که با استفاده از روش کاهش ویژگی مجموعه راف کاهش یافته است استفاده می‌کند تا یک مدل آسانسور سرعت‌بالا برای تشخیص خطای توقف اضطراری مبتنی بر شبکه عصبی BP فازی فراهم کند. نتایج شبیه‌سازی ثابت می‌کند که مدل آسانسور دقت بالایی در آسانسورهای سرعت‌بالا دارد، چون سرعت همگرایی شبکه عصبی BP نامشخص است به دست آوردن مقدار کمینه محلی آسان است. همچنین Wang[19] از الگوریتم ژنتیکی (GA) استفاده می‌کند که از مزایای جستجوی سراسری موازی و استحکام قوی برخوردار است. الگوریتم ژنتیک برای بهینه‌سازی وزن اولیه و آستانه شبکه عصبی BP فازی استفاده می‌شود. سپس این نتایج بهینه را با نتایج آموزش شبکه عصبی بدون بهینه‌سازی الگوریتم ژنتیک مقایسه می‌کند. این نشان می‌دهد که شبکه عصبی بهینه‌سازی شده توسط GA از قابلیت تعمیم قوی‌تری برخوردار است. درنهایت، تشخیص خطا در سیستم کنترل آسانسور بر اساس این الگوریتم ممکن می‌شود. Liu [۲۰]. باهدف این مسئله که سرعت همگرایی شبکه عصبی BP نامشخص و به دست آوردن مسئله کمینه محلی آسان است، از الگوریتم شبیه‌سازی تبریدی (SA)استفاده می‌کند که یکی از روش‌های جستجوی تصادفی اکتشافی برای به دست آوردن راه‌حل بهینه سراسری است؛ و برای بهینه‌سازی سرعت همگرایی شبکه عصبی، از روش گرادیان مزدوج استفاده می‌کند. سرانجام، یک شبکه عصبی BP که ترکیبی از دو روش گرادیان مزدوج با یک الگوریتم SA با حافظه است را ارائه می‌دهد. مدل شبکه عصبی بهینه‌سازی شده عملکرد بهتری را در زمان آموزش، سرعت همگرایی و دقت نشان می‌دهد. صحت نتیجه تشخیصی تقریباً ۱۰۰٪ است. Zhang و همکاران[۲۱]، برای جمع‌آوری سیگنال‌های ویژگی خطا، از تجزیه میانگین محلی (LMD)استفاده کردند و سپس یک تشخیص خطا از یاتاقان (rolling bearings) را بر اساس یک شبکه عصبی BPساده بررسی کرده‌اند. Wen و همکاران[۲۲]. یک شبکه عصبی BP بهبودیافته را بر اساس الگوریتم بهینه‌سازی ازدحام ذرات (PSO)پیشنهاد دادند که نواقص شبکه عصبی BP که مقداردهی اولیه تصادفی وزن و آستانه، دقت پیش‌بینی را کاهش می‌دهد را حل کند؛ و سپس یک مدل پیش‌بینی خطای سیستم درب آسانسور را بر اساس شبکه عصبی PSO-BP ارائه می‌دهند.

یکی از الگوریتم‌های پرکاربرد شبکه عصبی BP است که مشکل آن مقدار کمینه محلی و مقداردهی اولیه تصادفی وزن و آستانه است. بهینه‌سازی الگوریتم، هماهنگی خوب ویژگی غیرخطی را نشان می‌دهد که برای تشخیص خطا کاملاً مناسب است.

کاربرد شبکه عصبی RBF در تشخیص خطای آسانسور

در مقایسه با شبکه عصبیBP ، شبکه عصبی RBF دارای سرعت آموزش سریع‌تر و ساختار ساده‌تری است. ازآنجاکه می‌تواند یک راه‌حل سراسری بهینه را جستجو کند، هیچ مشکلی با مقدار کمینه محلی ندارد. این روش به‌طور گسترده در تشخیص نفوذ، تشخیص خطا، تشخیص پلاک و غیره استفاده می‌شود. بااین‌حال، برخی از کاستی‌ها در شبکه عصبی RBF نیز وجود دارد: انتخاب اولیه خوشه مرکزی کاملاً تصادفی است که ممکن است تأثیر بسیار خوبی در پیش‌بینی‌های بعدی داشته باشد. اما درعین‌حال می‌توان از الگوریتم‌های بهینه‌سازی مانندSA ، GA و غیره برای بهینه‌سازی آن‌ها استفاده کرد. Duan و همکاران [۲۳]. دو روش انتخابی خوشه مرکزی RBF و استخراج سیگنال حرکت پویا آسانسور به‌عنوان ورودی را ترکیب می‌کنند تا نوع خطای آسانسور در حال حرکت را پیش‌بینی کنند. Feng [۲۴] استانداردسازی گسسته را بر روی داده‌های ورودی انجام می‌دهد و از K-means برای تعیین تعداد نورون‌های لایه مخفی استفاده می‌کند. سپس قابلیت بهینه‌سازی سراسری قوی، سرعت همگرایی بالا و عدم نیاز به تنظیم بیش‌ازحد پارامتر PSO را برای ایجاد یک شبکه عصبیRBF بر اساس PSO بهبودیافته ترکیب می‌کند. سرانجام، مقایسه با شبکه عصبی RBF معمولی، تشخیص عالی شبکه عصبی PSO-RBF را نشان می‌دهد. Zhang و همکاران [۲۵] با استفاده از تجزیه بسته موجک برای استخراج ویژگی باند فرکانسی سیگنال پایداری غیر هم‌سطح یاتاقان و انطباق آن با بهینه‌سازی مبتنی بر جغرافیای زیستی برای ایجاد مدلی که توانایی انطباقی قوی داشته باشد. آن‌ها مدلی برای تشخیص خطای یاتاقان بر اساس تجزیه بسته موجک و شبکه عصبی BBO-RBF ارائه دادند. با توجه به این پدیده که سیگنال خطای چرخ‌دنده ضعیف است و تشخیص آن دشوار است، Zhang and Xiao [۲۶]. از تجزیه مقادیر منفرد (SVD) برای حذف نویز سیگنال ارتعاش چرخ‌دنده استفاده می‌کنند و سپس انرژی مقادیر تجزیه بسته موجک را به‌عنوان ورودی شبکه عصبی RBF برای تشخیص خطای چرخ‌دنده در نظر می‌گیرند. [Zhang۲۷]. از ویژگی‌های الگوریتم تجزیه حالت تجربی گروهی (EEMD) بهره می‌برد که می‌تواند تجزیه‌وتحلیل تطبیقی را انجام دهند تا سیگنال‌های لرزش چند چرخ‌دنده را در گروه‌های بردار IMF پراکنده کنند و مقادیر ویژه را از ماتریس کوواریانس استخراج کنند. سپس از طریق الگوریتم تنظیم فضای مماس محلی(LTSA) ، ابعاد بردار ویژه را کاهش می‌دهند و به‌عنوان مقادیر ورودی شبکه عصبی RBF به‌منظور طبقه‌بندی و شناسایی خطای چرخ‌دنده استفاده می‌شود. او همچنین مدل‌های wavelet packet-RBFو LTSA-RBF را مقایسه می‌کند. محمدی و همکاران[۲۸]. الگوریتمی را بر اساس تکامل ترکیبی پیشنهاد می‌کند که می‌تواند به‌طور خودکار معماری و پارامترهای وضعیت شبکه عصبی RBF را تعیین کند.

اگرچه مقداردهی اولیه خوشه مرکزی شبکه عصبی RBF استاندارد کاملاً تصادفی است و این ممکن است منجر به طولانی شدن زمان تکرار الگوریتم شود ولی الگوریتم‌های بهینه‌سازی زیادی برای حل چنین مشکلاتی استفاده می‌شوند. شبکه عصبی RBFبهینه در ترکیب با بسیاری از تکنولوژی‌های پیش‌پردازش داده‌های کارآمد، در زمینه تشخیص خطا بسیار قوی می‌باشند.

استفاده از شبکه عصبی SVM در تشخیص خطا آسانسور

SVMمی‌تواند برای طبقه‌بندی چندگانه یا پیش‌بینی داده‌ها استفاده شود. فرایند بهینه‌سازی آن، یافتن یک ابر صفحه (hyperplane) بهینه از بین نمونه‌های مختلف است. بیشتر با روش‌های ریاضی بهینه‌سازی می‌شود و حتی درصورتی‌که تعداد نمونه‌ها کم باشد می‌تواند تأثیر خوبی برای یادگیری داشته باشد. اینکه تأثیر آموزش خوب باشد یا خیر بستگی دارد به (1) : انتخاب تابع هسته، (2) انتخاب پارامترهایSVM . برای توضیح دومی، SVMروش‌های مختلف انتخاب پارامتر از قبیل روش گرادیان کاهشی، روش اعتبار سنجی متقابل، ایمنی مصنوعی و غیره را دارد.Gao [۲۹]. برای تعیین پارامترهای SVM از جستجوی شبکه و اعتبارسنجی متقابل استفاده می‌کند، طبقه‌بندی کننده را به‌صورت یک‌به‌یک برای هر یک از دو نوع نمونه روی مسئله چند کلاسی خطاها ایجاد می‌کند؛ و سپس ابر صفحه بهینه را می‌یابد. سرانجام، طبقه‌بندی کننده ایجاد شده می‌تواند نوع خطا را طبقه‌بندی کند و آزمایش‌ها ثابت می‌کند که نتیجه تشخیص صحیح است. He و همکاران [۳۰]، نمونه‌های سیگنال شکاف از خطاهای مختلف را از طریق سنسور جابجایی جریان گردابی با دقت بالا به دست آورده و سپس با تجزیه بسته موجک، بردار ویژه خطا را استخراج می‌کنند. سیستم تشخیص خطای آسانسور برای ترمز، بر اساس ماشین بردار پشتیبان حداقل-مربعی (LSSVM) است. در مرحله اول، Yi [۳۱]، سیگنال شتاب ارتعاشات آسانسور را به بسته موجک تجزیه می‌کند، اطلاعات انرژی هر باند فرکانسی سیگنال را به دست می‌آورد و بردار ویژه انرژی را ایجاد می‌کند. در مرحله دوم، با مقایسه سه روش بهینه‌سازی پارامترهای SVM، تعیین می‌کند که PSO با طبقه‌بندی بهینه دقیق برای بهینه‌سازی پارامترها

استفاده می‌شود. درنهایت، یک LSSVM مبتنی بر PSO ایجاد شده است که می‌تواند خطاهای آسانسور را با توجه به سیگنال حرکت آسانسور طبقه‌بندی کند. برای تشخیص خطاهای یاتاقان آسانسور Saimurugan و همکاران [۳۲]، استفاده می‌کند از ۱۲ سیگنال ارتعاشی به‌دست‌آمده از حسگرهای پیزوالکتریک برای ویژگی‌های آماری از طریق درخت تصمیم و اثرات چهار تابع هسته مختلف مدل SVM در طبقه‌بندی خطا را مقایسه می‌کند. Li و همکاران [۳۳] پیشنهاد روش تشخیص خطا بر اساس نسل دوم تبدیل بسته موجک (RSGWPT)، مجموعه‌های راف مجاور (NRS) و SVM را داده‌اند. در این روش از RSGWPT برای استخراج ویژگی‌های خطا برای نوشتن بردار ویژه و از NRS برای کاهش ابعاد بردار ویژه استفاده می‌کند. درنهایت، از SVM برای طبقه‌بندی حالت خطا با توجه به ویژگی‌های کلیدی آن استفاده می‌شود. از این روش برای تشخیص خطای گیربکس استفاده می‌شود، نتایج نشان می‌دهد که توانایی طبقه‌بندی خوبی دارد. Yi و همکاران [۳۴] سیگنال‌های شتاب ارتعاش و سیگنال‌های نویز در سه جهت X، Y، Z از ماشین را جمع‌آوری کردند، سیگنال ویژگی را با استفاده از تجزیه بسته موجک برای آموزش LSSVM استخراج کردند و درنهایت پارامترهای LSSVM را به‌وسیله GA بهینه‌سازی کردند به‌طوری‌که مدل طبقه‌بندی آسانسور برای خطای ماشین راندمان تشخیص خوبی دارد.

SVM دارای یک اصول طبقه‌بندی ساده و خوبی است؛ اما در هنگام استفاده از داده‌های بزرگ، زمان محاسبات و حافظه محاسباتی زیادی را هدر می‌دهد. یکی از راه‌حل‌ها این است که ابعاد داده را کاهش دهیم. به‌عنوان‌مثال، با استفاده از تکنولوژی‌های پیش‌پردازش داده‌ها مانند PCA و SVD. راه دیگر این است که مجموعه داده‌های بزرگ را به چندین مجموعه داده کوچک برای آموزش SVM تقسیم کنید. هر دو می‌توانند مشکل راندمان پایین استفاده از SVM را در مجموعه داده‌های بزرگ حل کنند.

استفاده ازK-means در تشخیص خطای آسانسور

K-meansیک الگوریتم خوشه‌بندی یادگیری بدون نظارت است. این الگوریتم ساده اما کارآمد یکی از الگوریتم‌های پرکاربرد در تجزیه‌وتحلیل خوشه است. برای مثال می‌توان از آن برای یافتن مرکز گره عصبی در لایه مخفی شبکه عصبی RBF استفاده کرد. این اثر مطلوبی در خوشه‌بندی دارد، اما درعین‌حال ممکن است در بهینه محلی قرار بگیرد و اثر خوشه‌بندی آن به انتخاب تعداد k خوشه مرکزی وابسته است. روش‌های بهینه‌سازی متنوعی برای حل مسئله بهینه محلی وجود دارد، مانند K-means++. برای انتخابk ، در حال حاضر، روش اصلی فقط روش elbow (نقطه تورم روی منحنی) و ضریب contour می‌باشند که دقت کمتری دارند؛ اما این تأثیری در این‌که یکی از روش‌های اصلی تشخیص خطا در این مرحله باشد ندارد.

با توجه به این مشکل که الگوریتمK-means به‌راحتی به مسئله بهینه محلی ورود می‌کند، Fei [۳۵]، الگوریتم K-means را بر اساس بهبود PSO پیشنهاد می‌کند که می‌تواند ضمن جلوگیری از ورود به بهینه محلی، سرعت همگرایی الگوریتم را بهبود بخشد. و سپس او چهار نوع مختلف از سیگنال خطا مکانیکی را جمع‌آوری می‌کند. ثابت شده است که مدل PSO- K-means می‌تواند چهار خطا مکانیکی را بهتر از قبل طبقه‌بندی کند. Tsortzisو Likas [۳۶]. راه‌حل دیگری پیشنهاد می‌دهند: به حداقل رساندن واریانس در حداکثر k خوشه و سپس خوشه. Zhang و همکاران [۳۷]، این روش و تابع هسته را ترکیب می‌کنند و سپس آن را با K-meansمعمولی و K-means++ مقایسه می‌کنند. نشان داده شده است که برتری روش جدید مشهود است. سپس با استفاده از الگوریتم هسته مینی ماکس K-means، یک مدل تشخیص خطای ارتعاش برای واحد مولد توربین آبی ایجاد می‌شود. Du و همکاران [۳۸]، با استفاده از الگوریتم کلونی مورچگان (ACA) که دارای مزایای جستجوی هوشمند و بهینه‌سازی سراسری است، الگوریتم توصیف داده بردار پشتیبانی (SVDD) را بهینه کرده و این مسئله که انتخاب پارامتر SVDD تأثیر واضحی در عملکرد طبقه‌بندی دارد را حل می‌کند. سپس مدل SVDD مبتنی بر بهینه‌سازی ACA با K-means ایجاد می‌شود . مدل تشخیص خطا برای ماشین‌های دوار که از شاخص DBI برای تعیین تعداد خوشه مرکزی استفاده می‌شود تأثیر برجسته‌ای دارد. Zhang و همکاران [۳۹] یک روش تشخیص خطا مکانیکی را بر اساس آنتروپی جابجایی چند مقیاسی (MPE) وK-means++ پیشنهاد دادند. سپس آن‌ها این روش را برای تغییر طبقه‌بندی حالت خطا به تپ چنجر زیر بار اعمال کردند. در [۴۰]،Gong و همکاران. یک شاخص ارزیابی را بر اساس الگوریتم K-Means و PCA پیشنهاد دادند. شاخص ارزیابی با افزایش تعداد خوشه‌ها، آستانه تشخیص خطاها را بهبود می‌بخشد، بنابراین می‌تواند سیگنال‌های خطا را با حساسیت بیشتری تشخیص دهد. Amruthnath و Gupta [۴۱]. اثر خوشه‌بندی انواع مختلفی از روش‌های خوشه‌بندی مانند K-means, Fuzzy C-Means و غیره را مقایسه می‌کنند. راه‌حل‌های زیادی برای این مسئله که الگوریتمK-means ممکن است در محاسبات تکراری وقت خود را تلف کند وجود دارد. به‌عنوان‌مثال،

Elkan K-means سرعت محاسبات K-means را با کاهش محاسبات غیرضروری بهینه می‌کند و Mini Batch K-means زمان تکرار K-means را با کاهش منظم تعداد نمونه‌ها در مجموعه نمونه‌های آموزشی کاهش می‌دهد.

رویدادهای آینده

با توسعه مداوم فناوری هوش مصنوعی، توانایی به‌کارگیری فناوری هوش مصنوعی در تشخیص خطا آسانسور به‌طور مداوم در حال پیشرفت است. مطالب فوق فقط به قسمتی از کاربرد هوش مصنوعی در تشخیص خطا اشاره دارد و رویدادهای جدیدی در تشخیص خطا در آینده وجود دارد.

تشخیص تصویر

با بهبود مداوم بینایی رایانه، مدل تشخیص خطا مبتنی بر پردازش تصویر به یکی از مسیرهای توسعه تشخیص خطا آسانسور تبدیل خواهد شد. علاوه بر این، با ظهور انواع مختلفی از بهینه‌سازی شبکه‌های عصبی پیچشی (CNN)مانندResNet و DenseNet ،[۴۲] تشخیص خطا Real time بر اساس پردازش تصویر ممکن است از تشخیص خطا به پیش‌بینی خطا تبدیل شود. نتیجه پیش‌بینی وقوع خرابی، جلوگیری بیشتر از ضرر مالی می‌باشد. Yaman و Karakose [۴۳]. یک روش تشخیص خطا برای طناب آسانسور را بر اساس پردازش تصویر ارائه می‌دهند و تشخیص لبه بر روی تصویر طناب آسانسور دریافت شده را برای شناسایی وضعیت طناب انجام می‌دهند. تصاویر با دوربین‌های ثابت توسط سیستم آسانسور گرفته می‌شود. موقعیت طناب آسانسور با استخراج لبه‌ها بر روی تصاویر تعیین می‌شود. بنابراین، طناب آسانسور به‌صورت Real time نظارت می‌شود. طناب شناسایی شده با استفاده از روش همبستگی خودکار به سیگنال‌های تصویر تبدیل می‌شود؛ و سیگنال تفاوت، سیگنال‌های خطا را که با استفاده از سیگنال همبستگی خودکار به‌دست‌آمده را به‌عنوان خطای طناب نشان می‌دهد.

یادگیری قانون انجمنی

امروزه، بسیاری از فن‌آوری‌های تشخیص خطا در آسانسورها محدود به یک جزء یا یک سیستم محلی خاص هستند؛ اما به دلیل همبستگی بین اجزای مختلف درون سیستم، معمولاً تشخیص خطا با انحرافاتی مواجه می‌شود. بر این اساس، دقت تشخیص خطا آسانسور را می‌توان با استفاده از برخی روش‌های یادگیری ماشین به‌طور قابل‌توجهی بهبود داد تا قواعد ارتباط هر یک از مؤلفه‌ها را پیدا کرده و برخی از تنظیمات را در سیستم تشخیصی انجام داد. تحقیقات زیادی در مورد روش یادگیری ماشین انجام شده است، مانند الگوریتم Apriori در یادگیری قانون انجمنی. این امر می‌تواند قوانین انجمنی را در مجموعه داده‌ها و همبستگی داده‌ها به دست آورد.

سیستم تشخیص خطای هوشمند مبتنی بر هوش مصنوعی

مکانیسم خطا و دانش قبلی روش‌های تشخیص خطا عمدتاً به مکانیسم خطا و درخت خطا متکی بوده و یا به شناسایی الگو و سیستم‌های خبره مبتنی بر قانون تکیه دارد. با پیشرفت هوش مصنوعی، سیستم‌های تشخیصی زیادی امروزه وجود دارند اما به اندازه کافی هوشمند نیستند و نیاز به پیشرفت‌های جدیدی خواهند داشت. سیستم تشخیص خطای هوشمند، ترکیبی از هوش مصنوعی، مکانیسم خطا و دانش قبلی است که یکی از مسیرهای توسعه تشخیص خطا خواهد بود.

۵. نتیجه‌گیری

تشخیص خطای آسانسور برای کاهش وقوع خرابی آسانسور و اطمینان از ایمنی و امنیت افراد قابل توجه است. ظهور فناوری هوش مصنوعی ابزار فنی جدیدی را برای تشخیص خطا آسانسور به ارمغان آورده است. در این مقاله شبکه عصبیBP ، شبکه عصبیRBF ، - K-means و SVMبه‌صورت نظری معرفی شده و کاربرد آن‌ها به‌طور خلاصه گفته شده است. نتایج حاصل از این الگوریتم‌ها به‌تنهایی خوب عمل نمی‌کنند و مشکلاتی دارند که با استفاده از ترکیب آن‌ها با الگوریتم‌های بهینه‌سازی می‌توان بهتر و سریع‌تر خطای آسانسورها را تشخیص داد. با پیشرفت سریع هوش مصنوعی، اعتقاد بر این است که تشخیص خطای آسانسور بیشتر و مؤثرتر خواهد شد.

منابع

[1] State Administration for Market Regulation. (2019) The Notice about Safety Status of Special Equipment in 2018 (In Chinese). http://samr.saic.gov.cn/tzsbj/gzdt/201904/t20190404_292592.html

[2] Zhang H. and Rui Y.N. 2009 Rese arch on Extension-Fuzzy-Based Evaluation Used for Elevator Performance Electrotechnics Electric 08 12-15

[3] Chen Z.P., Wang Z., Zhang G.A., Li C.G., Li Z.W. and He P. 2019 Research of big-data-based elevator fault diagnosis and predication Journal of Mechanical & Electrical Engineering 36 90-94
[4] Chang K. 2014 A Comparative and Analysis Research of Neural Network in the Classification Algorithm of Data Mining (Anhui University)
[5] Chang S. 2018 The Mining Algorithm Research of Elevator Safety Big Data Based on Hadoop Journal of Weinan Teachers College 33 34-40
[6] Li F.J., Qu Z.W., Dou L.Q. and Zong Q. 2009 Study of the fault prediction for elevator gate system based on neural network Journal of Tianjin University of Technology 25 8-10
[7] Tian Z.X., Zhang Y., Pan Y.X. and Li J.D. 2018 Application Research of Ant Colony Algorithm in Elevator Monitoring System (In Chinese) Electronics World **9** 202
[8] Gao B. 2016 Research on Mechanical Fault Diagnosis Based on Neural Network (Qingdao University of Science and Technology)
[9] Shen Z.P. 2018 Research and Application of Elevator Safety Monitoring Method based on Big Data (Zhejiang University of Technology)
[10] Fan Z.Y. 2011 BP neural network model and learning algorithm (In Chinese) Software Guide 10 66-68
[11] Wu C.Y. 2007 The Research and Application on Neural Network (Northeast Agricultural University)
[12] Chai J., Jiang Q.Y. and Cao Z.K. 2002 Function Approximation Capability and Algorithms of RBF Neural Networks Pattern Recognition and Artificial Intelligence 15 310-316
[13] John S.T. and Sun S.L. 2011 A review of optimization methodologies in support vector machines Neurocomputing 74 3609-3618
[14] Widodo A. and Yang B.S. 2007 Support vector machine in machine condition monitoring and fault diagnosis Mechanical Systems and Signal Processing 21 2560-2574
[15] Ding S.F., Qi B.J. and Tan H.Y. 2011 An Overview on Theory and Algorithm of Support Vector Machines Journal of University of Electronic Science and Technology of China 40 2-10
[16] Khawaja S.G., Khan A.M., Akram M.U. and Khan S.A. 2018 A novel architecture for k-means clustering algorithm AECIA 2016. Marrakech 311-320
[17] Li R. and Ai Y.L. 2010 Study on fault diagnosis of elevator based on neural network information fusion technology Computer Engineering and Applications 46 231-234
[18] Wang Z.P. 2016 A Research of Emergency Stop Fault Diagnosis Technology Based on Big Data Analysis of High-Speed Elevator Running Characteristics and its Application (In Chinese) (Zhejiang University of Technology)
[19] Wang H.B. 2013 Research of Elevator Real-time Monitoring and Online Intelligent Fault Diagnosis Based on Fuzzy Neural Network (Northeast University)
[20] Liu L. 2013 Research on the Elevator Fault Diagnosis Based on the BP Neural Network (Xinjiang University)
[21] Zhang L.P., Liu H.M. and Lu C. 2016 Fault Diagnosis Technology of Rolling Bearing Based on LMD and BP Neural Network Proceedings of the World Congress on Intelligent Control and Automation (Guilin,) 1327-1331
[22] Wen P.G., Zhi M., Zhang G.Y. and Li S.M. 2016 Fault Prediction of Elevator Door System Based on PSO-BP Neural Network Engineering 8 761-766
[23] Duan D., Qiu Y.M. and Zhou L. 2011 Fault Predication of Multi-Elevator Operating System Based on Neural Network Computer Systems and Applications 20 252-255
[24] Feng X. 2017 Research and Implementation of Monitoring and Warning System for Elevator Operation (University of Science and Technology of China)
[25] Zhang Q., Gao J.W., Zhang B., Mao Y.L. and Dong H.H. 2017 Fault Diagnosis of Rolling Bearing Based on

Wavelet Packet and BBO-RBF Industrial Control Computer 30 83-84
[26] Zhang Q. and Xiao S.G. 2017 Gear Fault Diagnosis of RBF Neural Network Based on Singular Value Decomposition (In Chinese) The 7th National Conference of Local Mechanical Engineering Society and the Cross-Strait Machinery Science and Technology Academic Forum (Wenchang,) 311-315
[27] Zhang J.T. 2018 The fault diagnosis of gear based on manifold learning method and radial basis function neural network College of Machinery and Equipment
[28] Mohammadi R., Fatemi Ghomi S.M.T. and Zeinali F. 2014 A new hybrid evolutionary based RBF networks method for forecasting time series: A case study of forecasting emergency supply demand time series Engineering Applications of Artificial Intelligence 36 204-214
[29] Gao F. 2014 Research and Development of Fault Diagnosis Expert System for Elevators (Northeastern University)
[30] He W.H., Wu P.L. and Shen W.C. 2010 Fault Diagnosis of Elevator Brake Based on LS-SVM Industry and Mine Automation 36 44-48
[31] Yi S.L. 2016 Research on Elevator Fault Diagnosis Method Based on Vibration Feature Extraction (Kunming University of Science and Technology)
[32] Saimurugan M., Ramachandran K.I., Sugumaran V. and Sakthivel N.R. 2011 Multi component fault diagnosis of rotational mechanical system based on decision tree and support vector machine Expert Systems with Applications 38 2923-4660
[33] Li N., Zhou R., Hu Q.H. and Liu X.H. 2012 Mechanical fault diagnosis based on redundant second generation wavelet packet transform, neighborhood rough set and support vector machine Mechanical Systems and Signal Processing 28 1-696
[34] Yi S.L., Wan Z., Tao R., Li K., Gou M. and Li X.S. 2016 Diagnosis of Elevator Faults with SVM Based on Optimization by GA Computer and Digital Engineering 44 166-170
[35] Fei X.J. 2015 Machinery Fault Intelligent Detection Based on Improved K-means Clustering Computer Measurement and Control 23 1121-1123
[36] Tzortzis G.F. and Likas A.C. 2009 The Global Kernel k-Means Algorithm for Clustering in Feature Space IEEE Transactions on Neural Networks 20 1181-1194
[37] Zhang X.Y., Zhang X.P. and Su B.P. 2015 Vibrant fault diagnosis for hydro-turbine generating unit using minmax kernel K-means clustering algorithm Power System Protection and Control 43 27-34
[38] Du W.L., Li A.S., Sun W., Li Y.M. and Liu C.L. 2012 Fault Diagnosis of Rotating Mechanism Based on Ant Colony SVDD Algorithm and Cluster Method Journal of Shanghai Jiao Tong University 46 1440-1444
[39] Zhang Y., Chen B., Xu Y., Wang L., Xu H.H. and Ma H.Z. 2018 Mechanical fault diagnosis method for OLTC based on MPE and K-means++ algorithm 2018 IEEE 3rd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC) (Chongqing,) 1252-1256
[40] Gong X.B., Wang R.X. and Xu M.Q. 2014 Early Sensor Fault Detection Based on PCA and Clustering Analysis Journal of Harbin Institute of Technology (New Series) 21 113-120
[41] Amruthnath N. and Gupta T. 2018 A Research Study on Unsupervised Machine Learning Algorithms for Early Fault Detection in Predictive Maintenance 2018 5th International Conference on Industrial Engineering and Applications (ICIEA) (Chongqing,) 355-361
[42] He K., Zhang X.Y., Ren J. and Sun J. 2016 Deep Residual Learning for Image Recognition 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (Las Vegas,) 770-778