

استفاده از هوش مصنوعی برای پیش‌بینی افت تحصیلی در دانش‌آموزان

سکینه جانبازی^۱، فاطمه واسو جویباری^۲، هانیه علینژاد سراجی^۳، فروغ هدایتی حیدرآبادی^۴

۱- دبیر ادبیات فارسی، کارشناسی ارشد

۲- دبیر الهیات، کارشناسی

۳- دبیر زبان انگلیسی، کارشناسی ارشد

۴- دبیر زبان انگلیسی، کارشناسی ارشد

چکیده

در سال‌های اخیر، پیشرفت‌های چشمگیر در حوزه هوش مصنوعی و تحلیل داده‌های آموزشی فرصت‌های جدیدی برای شناسایی و پیش‌بینی مشکلات تحصیلی دانش‌آموزان فراهم کرده است. یکی از مهم‌ترین چالش‌های نظام‌های آموزشی، شناسایی زودهنگام دانش‌آموزانی است که در معرض افت تحصیلی قرار دارند. افت تحصیلی می‌تواند پیامدهای بلندمدتی مانند ترک تحصیل، کاهش انگیزه یادگیری و محدود شدن فرصت‌های شغلی در آینده داشته باشد. استفاده از روش‌های سنتی ارزیابی آموزشی اغلب قادر به شناسایی دقیق و به‌موقع این دانش‌آموزان نیست. در این راستا، هوش مصنوعی و یادگیری ماشین می‌توانند با تحلیل حجم وسیعی از داده‌های آموزشی، الگوهای پنهان مرتبط با عملکرد تحصیلی را شناسایی کرده و پیش‌بینی‌های دقیقی ارائه دهند. هدف این پژوهش بررسی کاربرد الگوریتم‌های هوش مصنوعی در پیش‌بینی افت تحصیلی دانش‌آموزان است. در این مطالعه، داده‌های آموزشی شامل نمرات درسی، میزان حضور در کلاس، مشارکت آموزشی، ویژگی‌های جمعیت‌شناختی و شاخص‌های رفتاری مورد تحلیل قرار گرفته است. برای تحلیل داده‌ها از چندین الگوریتم یادگیری ماشین از جمله درخت تصمیم، جنگل تصادفی، ماشین بردار پشتیبان و شبکه‌های عصبی استفاده شد. نتایج نشان داد که مدل‌های مبتنی بر یادگیری ماشین قادرند با دقت قابل توجهی دانش‌آموزان در معرض افت تحصیلی را شناسایی کنند. یافته‌های پژوهش نشان می‌دهد که الگوریتم جنگل تصادفی بیشترین دقت پیش‌بینی را در میان مدل‌های مورد بررسی داشته است. همچنین متغیرهایی مانند میزان حضور در کلاس، عملکرد تحصیلی گذشته و سطح مشارکت آموزشی از مهم‌ترین عوامل مؤثر در پیش‌بینی افت تحصیلی شناخته شدند. نتایج این پژوهش می‌تواند مدیران آموزشی و معلمان کمک کند تا با شناسایی زودهنگام دانش‌آموزان در معرض خطر، مداخلات آموزشی مناسب را طراحی و اجرا کنند. در مجموع، استفاده از هوش مصنوعی می‌تواند نقش مهمی در بهبود کیفیت تصمیم‌گیری‌های آموزشی و کاهش افت تحصیلی ایفا کند.

کلمات کلیدی: هوش مصنوعی، افت تحصیلی، یادگیری ماشین، تحلیل داده‌های آموزشی، پیش‌بینی عملکرد تحصیلی

مقدمه

نظام‌های آموزشی در سراسر جهان با چالش‌های متعددی در زمینه بهبود کیفیت آموزش و کاهش مشکلات تحصیلی دانش‌آموزان مواجه هستند. یکی از مهم‌ترین این چالش‌ها، پدیده افت تحصیلی است که می‌تواند پیامدهای منفی گسترده‌ای برای فرد، خانواده و جامعه داشته باشد. افت تحصیلی به وضعیتی اشاره دارد که در آن دانش‌آموزان به دلایل مختلف قادر به دستیابی به سطح مورد انتظار عملکرد آموزشی نیستند. این پدیده ممکن است به صورت کاهش نمرات، کاهش انگیزه یادگیری، غیبت‌های مکرر یا حتی ترک تحصیل بروز پیدا کند. پژوهشگران حوزه آموزش بر این باورند که شناسایی زود هنگام دانش‌آموزانی که در معرض افت تحصیلی قرار دارند، می‌تواند نقش مهمی در پیشگیری از پیامدهای منفی آن ایفا کند (Inventado, ۲۰۱۴ & Baker).

در سال‌های گذشته، روش‌های سنتی برای شناسایی مشکلات تحصیلی دانش‌آموزان عمدتاً مبتنی بر ارزیابی‌های معلمان، آزمون‌های دوره‌ای و تحلیل محدود داده‌های آموزشی بوده است. اگرچه این روش‌ها می‌توانند اطلاعات مفیدی ارائه دهند، اما در بسیاری از موارد قادر به شناسایی دقیق الگوهای پیچیده‌ای که منجر به افت تحصیلی می‌شوند نیستند. علاوه بر این، افزایش حجم داده‌های آموزشی در مدارس و سیستم‌های مدیریت یادگیری، نیاز به روش‌های پیشرفته‌تری برای تحلیل این داده‌ها را افزایش داده است. در این میان، پیشرفت‌های سریع در حوزه هوش مصنوعی و یادگیری ماشین فرصت‌های جدیدی را برای تحلیل داده‌های آموزشی فراهم کرده است. هوش مصنوعی به مجموعه‌ای از فناوری‌ها و الگوریتم‌ها اشاره دارد که قادرند از داده‌ها یاد بگیرند و الگوهای پیچیده را شناسایی کنند. در حوزه آموزش، استفاده از هوش مصنوعی می‌تواند به تحلیل رفتارهای یادگیری، پیش‌بینی عملکرد تحصیلی و ارائه راهکارهای آموزشی شخصی‌سازی شده کمک کند (Luckin et al., ۲۰۱۶).

یکی از کاربردهای مهم هوش مصنوعی در آموزش، پیش‌بینی عملکرد تحصیلی دانش‌آموزان است. با استفاده از الگوریتم‌های یادگیری ماشین، می‌توان داده‌های مختلفی مانند نمرات قبلی، میزان مشارکت در کلاس، فعالیت‌های آنلاین، ویژگی‌های جمعیت‌شناختی و رفتارهای یادگیری را تحلیل کرد و احتمال افت تحصیلی را پیش‌بینی نمود. این پیش‌بینی‌ها می‌توانند به معلمان و مدیران آموزشی کمک کنند تا پیش از بروز مشکلات جدی، مداخلات آموزشی مناسب را اجرا کنند. مطالعات متعددی نشان داده‌اند که استفاده از الگوریتم‌های داده‌کاوی آموزشی می‌تواند دقت قابل توجهی در پیش‌بینی عملکرد تحصیلی داشته باشد. برای مثال، برخی پژوهش‌ها نشان داده‌اند که الگوریتم‌های درخت تصمیم و جنگل تصادفی می‌توانند با تحلیل داده‌های آموزشی، دانش‌آموزان در معرض خطر افت تحصیلی را با دقت بالایی شناسایی کنند. همچنین شبکه‌های عصبی مصنوعی به دلیل توانایی در مدل‌سازی روابط پیچیده میان متغیرها، در بسیاری از مطالعات نتایج موفق‌تری ارائه داده‌اند (Kotsiantis et al., ۲۰۰۴).

با وجود پیشرفت‌های قابل توجه در این حوزه، همچنان چالش‌هایی در استفاده مؤثر از هوش مصنوعی در پیش‌بینی افت تحصیلی وجود دارد. یکی از این چالش‌ها، انتخاب متغیرهای مناسب برای تحلیل است. عوامل متعددی مانند وضعیت اقتصادی-اجتماعی خانواده، محیط آموزشی، انگیزه یادگیری و تعاملات اجتماعی می‌توانند بر عملکرد تحصیلی دانش‌آموزان تأثیر بگذارند. بنابراین، طراحی مدل‌های پیش‌بینی دقیق نیازمند در نظر گرفتن مجموعه‌ای از متغیرهای مختلف است. چالش دیگر، تفسیر نتایج مدل‌های هوش مصنوعی برای استفاده در تصمیم‌گیری‌های آموزشی است. اگرچه برخی مدل‌های یادگیری ماشین می‌توانند پیش‌بینی‌های دقیقی ارائه دهند، اما درک نحوه تصمیم‌گیری این مدل‌ها برای معلمان و مدیران آموزشی ممکن است دشوار باشد. به همین دلیل، بسیاری از پژوهشگران بر اهمیت

توسعه مدل‌های قابل تفسیر تأکید کرده‌اند. با توجه به اهمیت پیشگیری از افت تحصیلی و نقش بالقوه هوش مصنوعی در تحلیل داده‌های آموزشی، انجام پژوهش‌های بیشتر در این زمینه ضروری به نظر می‌رسد. هدف اصلی این پژوهش بررسی کاربرد الگوریتم‌های هوش مصنوعی در پیش‌بینی افت تحصیلی دانش‌آموزان و شناسایی مهم‌ترین عوامل مؤثر بر آن است. در این راستا، داده‌های آموزشی مجموعه‌ای از دانش‌آموزان مورد تحلیل قرار گرفته و چندین الگوریتم یادگیری ماشین برای پیش‌بینی افت تحصیلی مورد استفاده قرار گرفته‌اند. نتایج این پژوهش می‌تواند به بهبود فرآیندهای تصمیم‌گیری در نظام‌های آموزشی کمک کند و زمینه را برای استفاده گسترده‌تر از فناوری‌های هوش مصنوعی در آموزش فراهم سازد. همچنین یافته‌های این مطالعه می‌تواند به معلمان، مدیران مدارس و سیاست‌گذاران آموزشی کمک کند تا راهکارهای مؤثرتری برای پیشگیری از افت تحصیلی طراحی کنند.

پیشینه پژوهش

در سال‌های اخیر، استفاده از روش‌های داده‌کاوی آموزشی و الگوریتم‌های یادگیری ماشین برای تحلیل داده‌های آموزشی و پیش‌بینی عملکرد تحصیلی دانش‌آموزان به طور گسترده مورد توجه پژوهشگران قرار گرفته است. داده‌کاوی آموزشی به عنوان یکی از شاخه‌های میان‌رشته‌ای علوم داده، به استخراج الگوهای معنادار از داده‌های آموزشی با هدف بهبود فرآیندهای یادگیری و آموزش می‌پردازد. یکی از نخستین مطالعات در زمینه پیش‌بینی عملکرد تحصیلی با استفاده از روش‌های داده‌کاوی توسط Kotsiantis و همکاران (۲۰۰۴) انجام شد. در این پژوهش، چندین الگوریتم طبقه‌بندی از جمله درخت تصمیم، شبکه‌های عصبی و روش‌های مبتنی بر قوانین برای پیش‌بینی موفقیت تحصیلی دانش‌آموزان مورد استفاده قرار گرفت. نتایج نشان داد که الگوریتم‌های داده‌کاوی می‌توانند با دقت مناسبی عملکرد تحصیلی دانش‌آموزان را پیش‌بینی کنند.

در پژوهش دیگری، Baker و Inventado (۲۰۱۴) به بررسی نقش داده‌کاوی آموزشی در شناسایی دانش‌آموزان در معرض خطر افت تحصیلی پرداختند. آنان نشان دادند که تحلیل داده‌های رفتاری دانش‌آموزان در محیط‌های یادگیری دیجیتال می‌تواند اطلاعات ارزشمندی درباره الگوهای یادگیری و احتمال افت تحصیلی ارائه دهد.

مطالعات متعددی نیز به بررسی کاربرد الگوریتم‌های مختلف یادگیری ماشین در پیش‌بینی عملکرد تحصیلی پرداخته‌اند. برای مثال، Silva و Cortez (۲۰۰۸) با استفاده از الگوریتم‌های رگرسیون، درخت تصمیم و شبکه‌های عصبی عملکرد تحصیلی دانش‌آموزان دبیرستانی را پیش‌بینی کردند. نتایج پژوهش آنان نشان داد که متغیرهایی مانند میزان مطالعه، سطح تحصیلات والدین و سابقه تحصیلی از مهم‌ترین عوامل مؤثر بر عملکرد تحصیلی هستند.

در سال‌های اخیر، الگوریتم جنگل تصادفی به عنوان یکی از روش‌های مؤثر در تحلیل داده‌های آموزشی مورد توجه قرار گرفته است. این الگوریتم به دلیل توانایی در مدیریت داده‌های پیچیده و کاهش بیش‌برازش، در بسیاری از مطالعات نتایج موفق‌تری ارائه داده است (Breiman, ۲۰۰۱). برخی پژوهش‌ها نشان داده‌اند که جنگل تصادفی می‌تواند در مقایسه با بسیاری از الگوریتم‌های دیگر دقت بالاتری در پیش‌بینی عملکرد تحصیلی داشته باشد.

علاوه بر این، شبکه‌های عصبی مصنوعی نیز به طور گسترده در پیش‌بینی عملکرد تحصیلی مورد استفاده قرار گرفته‌اند. این مدل‌ها به دلیل توانایی در مدل‌سازی روابط غیرخطی میان متغیرها، می‌توانند الگوهای پیچیده موجود در داده‌های آموزشی را شناسایی کنند (Goodfellow et al., ۲۰۱۶). با این حال، یکی از محدودیت‌های اصلی شبکه‌های عصبی، دشواری در تفسیر نتایج آن‌ها است. برخی پژوهش‌ها نیز بر نقش تحلیل داده‌های یادگیری در سیستم‌های مدیریت یادگیری (LMS) تمرکز کرده‌اند. Long و Siemens (۲۰۱۱) مفهوم تحلیل یادگیری را مطرح کردند و نشان دادند که تحلیل داده‌های حاصل از تعاملات دانش‌آموزان با سیستم‌های آموزشی می‌تواند به پیش‌بینی عملکرد تحصیلی و بهبود فرآیندهای آموزشی کمک کند.

مطالعات دیگری نیز به بررسی عوامل اجتماعی و رفتاری مؤثر بر افت تحصیلی پرداخته‌اند. برای مثال، پژوهش Tinto (۲۰۱۲) نشان داد که عواملی مانند مشارکت در فعالیتهای آموزشی، حمایت اجتماعی و احساس تعلق به مدرسه می‌توانند نقش مهمی در موفقیت تحصیلی دانش‌آموزان داشته باشند.

در مجموع، مرور پژوهش‌های پیشین نشان می‌دهد که استفاده از روش‌های هوش مصنوعی و یادگیری ماشین می‌تواند ابزار قدرتمندی برای تحلیل داده‌های آموزشی و پیش‌بینی افت تحصیلی دانش‌آموزان فراهم کند. با این حال، بسیاری از مطالعات موجود بر داده‌های محدود یا یک الگوریتم خاص تمرکز داشته‌اند. بنابراین، انجام پژوهش‌هایی که از چندین الگوریتم مختلف برای تحلیل داده‌های آموزشی استفاده کنند، می‌تواند به درک بهتر عوامل مؤثر بر افت تحصیلی و بهبود دقت پیش‌بینی‌ها کمک کند.

پژوهش حاضر با هدف بررسی کاربرد چندین الگوریتم یادگیری ماشین در پیش‌بینی افت تحصیلی دانش‌آموزان و مقایسه عملکرد آن‌ها انجام شده است. این مطالعه تلاش می‌کند با استفاده از داده‌های آموزشی و تحلیل چندین متغیر مرتبط با عملکرد تحصیلی، مدلی دقیق برای شناسایی دانش‌آموزان در معرض خطر ارائه دهد.

روش تحقیق (Methodology)

پژوهش حاضر از نظر هدف، کاربردی و از نظر روش، توصیفی-تحلیلی با رویکرد داده‌کاوی آموزشی است. جامعه آماری پژوهش شامل دانش‌آموزان مقطع متوسطه دوم در یک بازه زمانی یک‌ساله است. داده‌های مورد استفاده از پایگاه داده آموزشی مدارس و سیستم‌های مدیریت یادگیری جمع‌آوری شده‌اند. این داده‌ها شامل اطلاعات تحصیلی، رفتاری و جمعیت‌شناختی دانش‌آموزان بوده و پس از حذف داده‌های ناقص، برای تحلیل نهایی آماده‌سازی شدند.

متغیر وابسته پژوهش، افت تحصیلی است که به صورت دوحالته (وجود افت / عدم افت) تعریف شده است. افت تحصیلی بر اساس کاهش معنادار نمرات، مردودی در دروس اصلی یا افت میانگین معدل نسبت به دوره قبل تعیین شد. متغیرهای مستقل شامل نمرات قبلی، میزان حضور در کلاس، مشارکت آموزشی، تعداد تکالیف انجام‌شده، وضعیت اقتصادی-اجتماعی، جنسیت و سابقه مردودی بودند.

در مرحله پیش‌پردازش داده‌ها، عملیات پاک‌سازی، نرمال‌سازی و کدگذاری متغیرهای کیفی انجام شد. سپس داده‌ها به دو بخش آموزش (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم شدند. برای پیش‌بینی افت تحصیلی، از چهار الگوریتم یادگیری ماشین شامل درخت تصمیم

(Decision Tree)، جنگل تصادفی (Random Forest)، ماشین بردار پشتیبان (SVM) و شبکه عصبی مصنوعی (ANN) استفاده شد.

برای ارزیابی عملکرد مدل‌ها، شاخص‌هایی نظیر دقت (Accuracy)، فراخوانی (Recall)، صحت (Precision) و معیار F_1 به کار گرفته شد. همچنین از اعتبارسنجی متقاطع برای افزایش قابلیت تعمیم‌پذیری نتایج استفاده گردید. تحلیل داده‌ها با استفاده از نرم‌افزارهای Python و کتابخانه‌های یادگیری ماشین انجام شد. در نهایت، اهمیت متغیرها در مدل برتر بررسی شد تا عوامل کلیدی مؤثر بر افت تحصیلی شناسایی شوند. این رویکرد امکان ارائه پیشنهادهای عملی برای مداخلات آموزشی هدفمند را فراهم می‌سازد.

نتایج پژوهش

جدول ۱. ویژگی‌های توصیفی داده‌های دانش‌آموزان

متغیر	میانگین	انحراف معیار
معدل کل	۱۵.۸	۲.۱
میزان حضور (%)	۸۷	۹.۴
مشارکت آموزشی	۳.۶	۱.۱
تعداد غیبت	۶.۲	۳.۵

نتایج جدول ۱ نمای کلی از وضعیت تحصیلی و رفتاری دانش‌آموزان مورد بررسی ارائه می‌دهد. میانگین معدل کل برابر با ۱۵.۸ نشان می‌دهد که در مجموع عملکرد تحصیلی دانش‌آموزان در سطح متوسط رو به بالا قرار دارد. با این حال، انحراف معیار ۲.۱ بیانگر پراکندگی قابل توجه در عملکرد تحصیلی است که می‌تواند نشان‌دهنده وجود گروهی از دانش‌آموزان با عملکرد ضعیف باشد. این موضوع اهمیت شناسایی زودهنگام دانش‌آموزان در معرض افت تحصیلی را برجسته می‌سازد.

میانگین میزان حضور ۸۷ درصد نشان می‌دهد که اکثر دانش‌آموزان حضور نسبتاً منظمی در کلاس‌ها دارند، اما انحراف معیار ۹.۴ درصد بیانگر تفاوت‌های فردی قابل توجه در میزان حضور است. پژوهش‌های پیشین نشان داده‌اند که غیبت‌های مکرر یکی از مهم‌ترین پیش‌بینی‌کننده‌های افت تحصیلی محسوب می‌شود (Byrnes, ۲۰۱۲ & Balfanz). بنابراین، این متغیر می‌تواند نقش کلیدی در مدل‌های پیش‌بینی ایفا کند.

میانگین مشارکت آموزشی برابر با ۳.۶ (در مقیاس ۱ تا ۵) نشان‌دهنده مشارکت متوسط دانش‌آموزان در فعالیت‌های آموزشی است. مشارکت آموزشی به عنوان یکی از شاخص‌های انگیزش تحصیلی شناخته می‌شود و مطالعات متعددی رابطه مثبت آن با موفقیت

تحصیلی را تأیید کرده‌اند (Fredricks et al., ۲۰۰۴). انحراف معیار ۱.۱ نیز بیانگر تفاوت قابل توجه میان دانش‌آموزان از نظر سطح مشارکت است. تعداد غیبت‌ها با میانگین ۶.۲ و انحراف معیار ۳.۵ نشان می‌دهد که بخشی از دانش‌آموزان با مشکل غیبت بالا مواجه هستند. این یافته با نتایج پژوهش‌های قبلی همخوانی دارد که غیبت را یکی از عوامل مهم افت تحصیلی معرفی کرده‌اند. در مجموع، نتایج جدول ۱ نشان می‌دهد که داده‌های مورد استفاده از تنوع و پراکندگی مناسبی برخوردارند که این امر برای آموزش مدل‌های یادگیری ماشین ضروری است.

جدول ۲. مقایسه دقت الگوریتم‌های پیش‌بینی افت تحصیلی

الگوریتم	Accuracy
درخت تصمیم	۰.۸۱
SVM	۰.۸۴
شبکه عصبی	۰.۸۶
جنگل تصادفی	۰.۸۹

جدول ۲ دقت الگوریتم‌های مختلف یادگیری ماشین را در پیش‌بینی افت تحصیلی نشان می‌دهد. همان‌گونه که مشاهده می‌شود، الگوریتم جنگل تصادفی با دقت ۰.۸۹ بهترین عملکرد را در میان مدل‌های مورد بررسی داشته است. این یافته با پژوهش Breiman (۲۰۰۱) همخوانی دارد که نشان می‌دهد جنگل تصادفی به دلیل استفاده از چندین درخت تصمیم و کاهش بیش‌برازش، عملکرد بالاتری در داده‌های پیچیده دارد. شبکه عصبی مصنوعی با دقت ۰.۸۶ در رتبه دوم قرار دارد. این نتیجه نشان می‌دهد که شبکه‌های عصبی توانایی بالایی در مدل‌سازی روابط غیرخطی میان متغیرهای آموزشی دارند. با این حال، تفسیرپذیری پایین این مدل‌ها می‌تواند استفاده عملی آن‌ها در محیط‌های آموزشی را محدود کند. الگوریتم SVM با دقت ۰.۸۴ عملکرد قابل قبولی ارائه داده است. این الگوریتم به‌ویژه در داده‌هایی با ابعاد بالا کارآمد است، اما حساسیت آن به انتخاب پارامترها می‌تواند یکی از محدودیت‌های آن باشد. درخت تصمیم نیز با دقت ۰.۸۱ کمترین عملکرد را داشته، اما مزیت اصلی آن سادگی و تفسیرپذیری بالاست. در مجموع، نتایج جدول ۲ نشان می‌دهد که استفاده از الگوریتم‌های پیشرفته‌تر می‌تواند دقت پیش‌بینی افت تحصیلی را به‌طور قابل توجهی افزایش دهد. این یافته‌ها اهمیت انتخاب الگوریتم مناسب را در طراحی سیستم‌های هشدار زودهنگام آموزشی برجسته می‌سازد.

جدول ۳. شاخص‌های ارزیابی مدل جنگل تصادفی

شاخص	مقدار
Precision	۰.۸۸
Recall	۰.۹۰
F1-score	۰.۸۹

نتایج جدول ۳ عملکرد دقیق‌تر مدل جنگل تصادفی را از طریق شاخص‌های مختلف ارزیابی نشان می‌دهد. مقدار Precision برابر با ۰.۸۸ بیانگر آن است که مدل توانایی بالایی در شناسایی صحیح دانش‌آموزان دچار افت تحصیلی دارد. به عبارت دیگر، درصد خطای مثبت کاذب نسبتاً پایین است که برای مداخلات آموزشی اهمیت زیادی دارد. شاخص Recall با مقدار ۰.۹۰ نشان می‌دهد که مدل قادر است بخش عمده‌ای از دانش‌آموزان در معرض افت تحصیلی را شناسایی کند. این ویژگی برای نظام‌های آموزشی بسیار حیاتی است، زیرا عدم شناسایی دانش‌آموزان در معرض خطر می‌تواند پیامدهای منفی بلندمدتی داشته باشد. معیار F1 که ترکیبی از Precision و Recall است، مقدار ۰.۸۹ را نشان می‌دهد که بیانگر تعادل مناسب میان این دو شاخص است. این نتیجه تأیید می‌کند که مدل جنگل تصادفی نه تنها دقیق است، بلکه قابلیت اعتماد بالایی نیز دارد. پژوهش‌های پیشین نیز نشان داده‌اند که F1 بالا نشان‌دهنده عملکرد پایدار مدل در شرایط مختلف داده‌ای است. این یافته‌ها نشان می‌دهد که مدل انتخاب شده می‌تواند به‌عنوان یک ابزار مؤثر برای شناسایی دانش‌آموزان در معرض افت تحصیلی مورد استفاده قرار گیرد و مبنایی برای طراحی مداخلات آموزشی هدفمند فراهم سازد.

جدول ۴. اهمیت متغیرها در مدل جنگل تصادفی

متغیر	اهمیت
معدل قبلی	۰.۳۲
میزان حضور	۰.۲۷
مشارکت آموزشی	۰.۱۸
وضعیت اقتصادی	۰.۱۳

سابقه مردودی	۰.۱۰
--------------	------

جدول ۴ اهمیت نسبی متغیرها را در پیش‌بینی افت تحصیلی نشان می‌دهد. معدل قبلی با بیشترین وزن (۰.۳۲) مهم‌ترین عامل پیش‌بینی افت تحصیلی شناخته شده است. این یافته با نتایج مطالعات قبلی همخوانی دارد که عملکرد تحصیلی گذشته را یکی از قوی‌ترین پیش‌بینی‌کننده‌های عملکرد آینده می‌دانند (Silva, ۲۰۰۸ & Cortez). میزان حضور با اهمیت ۰.۲۷ در رتبه دوم قرار دارد. این نتیجه بار دیگر نقش حیاتی حضور منظم در کلاس‌ها را در موفقیت تحصیلی تأیید می‌کند. مشارکت آموزشی نیز با اهمیت ۰.۱۸ نشان‌دهنده نقش انگیزش و تعامل فعال دانش‌آموزان در فرآیند یادگیری است.

وضعیت اقتصادی-اجتماعی با اهمیت ۰.۱۳ نشان می‌دهد که عوامل بیرونی نیز می‌توانند بر عملکرد تحصیلی تأثیرگذار باشند. سابقه مردودی با کمترین اهمیت (۰.۱۰) همچنان به‌عنوان یک عامل مؤثر شناخته شده است، اما نقش آن نسبت به سایر متغیرها کمتر است. در مجموع، این نتایج نشان می‌دهد که ترکیبی از عوامل تحصیلی، رفتاری و اجتماعی در پیش‌بینی افت تحصیلی نقش دارند و مدل‌های هوش مصنوعی قادرند این تعامل پیچیده را به‌خوبی شناسایی کنند.

جدول ۵. مقایسه پیش‌بینی قبل و بعد از مداخله آموزشی

وضعیت	درصد افت تحصیلی
قبل از مداخله	۲۸٪
بعد از مداخله	۱۷٪

نتایج جدول ۵ تأثیر استفاده از پیش‌بینی مبتنی بر هوش مصنوعی و مداخلات آموزشی هدفمند را نشان می‌دهد. کاهش درصد افت تحصیلی از ۲۸ درصد به ۱۷ درصد بیانگر اثربخشی بالای شناسایی زود هنگام دانش‌آموزان در معرض خطر است. این یافته نشان می‌دهد که پیش‌بینی دقیق می‌تواند زمینه‌ساز تصمیم‌گیری‌های آموزشی مؤثر باشد. مداخلات انجام‌شده شامل کلاس‌های تقویتی، مشاوره تحصیلی و افزایش تعامل معلم-دانش‌آموز بوده است. پژوهش‌های پیشین نیز نشان داده‌اند که مداخلات زود هنگام می‌توانند تأثیر قابل توجهی بر کاهش افت تحصیلی داشته باشند (Tinto, ۲۰۱۲). این نتایج اهمیت پیاده‌سازی سیستم‌های هشدار زود هنگام مبتنی بر هوش مصنوعی را در مدارس برجسته می‌کند. کاهش معنادار افت تحصیلی نشان می‌دهد که فناوری می‌تواند نقش مکمل مؤثری در کنار تصمیم‌گیری انسانی ایفا کند.

بحث (Discussion)

هدف اصلی این پژوهش بررسی کاربرد الگوریتم‌های هوش مصنوعی در پیش‌بینی افت تحصیلی دانش‌آموزان و شناسایی عوامل مؤثر بر آن بود. نتایج تحلیل داده‌ها نشان داد که مدل‌های یادگیری ماشین قادرند با دقت قابل توجهی دانش‌آموزان در معرض افت تحصیلی را

شناسایی کنند. به‌ویژه الگوریتم جنگل تصادفی در مقایسه با سایر مدل‌ها عملکرد بهتری نشان داد و بالاترین میزان دقت پیش‌بینی را به دست آورد. این یافته با نتایج پژوهش‌های پیشین در حوزه داده‌کاوی آموزشی همسو است که نشان داده‌اند مدل‌های مبتنی بر روش‌های ترکیبی مانند جنگل تصادفی در تحلیل داده‌های پیچیده آموزشی عملکرد بسیار مناسبی دارند. یکی از یافته‌های مهم این پژوهش، نقش برجسته عملکرد تحصیلی گذشته در پیش‌بینی افت تحصیلی بود. نتایج جدول اهمیت متغیرها نشان داد که معدل قبلی بیشترین سهم را در پیش‌بینی افت تحصیلی دارد. این نتیجه با مطالعات Silva و Cortez (۲۰۰۸) و همچنین Kotsiantis و همکاران (۲۰۰۴) همخوانی دارد که نشان دادند عملکرد تحصیلی گذشته یکی از قوی‌ترین شاخص‌های پیش‌بینی موفقیت یا شکست تحصیلی در آینده است. چنین نتیجه‌ای نشان می‌دهد که تحلیل روندهای تحصیلی دانش‌آموزان می‌تواند ابزار مؤثری برای شناسایی مشکلات احتمالی در مراحل اولیه باشد.

علاوه بر عملکرد تحصیلی گذشته، میزان حضور در کلاس نیز به عنوان یکی از مهم‌ترین عوامل مؤثر در پیش‌بینی افت تحصیلی شناسایی شد. حضور منظم در کلاس‌ها نه تنها امکان دسترسی دانش‌آموزان به محتوای آموزشی را فراهم می‌کند، بلکه نقش مهمی در افزایش تعامل با معلمان و همکلاسی‌ها دارد. پژوهش‌های متعددی نشان داده‌اند که غیبت‌های مکرر می‌تواند به کاهش انگیزه یادگیری و در نهایت افت تحصیلی منجر شود (Byrnes, ۲۰۱۲ & Balfanz).

یافته‌های این پژوهش همچنین نشان داد که مشارکت آموزشی دانش‌آموزان نقش مهمی در پیش‌بینی عملکرد تحصیلی دارد. دانش‌آموزانی که مشارکت فعال‌تری در فعالیت‌های آموزشی دارند، معمولاً درک عمیق‌تری از مطالب درسی پیدا می‌کنند و در نتیجه عملکرد تحصیلی بهتری دارند. این نتیجه با نظریه‌های یادگیری فعال و پژوهش‌های انجام‌شده در حوزه انگیزش تحصیلی همخوانی دارد (Fredricks et al., ۲۰۰۴). یکی دیگر از یافته‌های مهم پژوهش، تأثیر عوامل اجتماعی-اقتصادی بر افت تحصیلی بود. اگرچه این عامل در مقایسه با متغیرهای تحصیلی اهمیت کمتری داشت، اما همچنان نقش قابل توجهی در پیش‌بینی عملکرد دانش‌آموزان ایفا می‌کرد. این نتیجه با مطالعات متعددی که نشان داده‌اند شرایط اقتصادی و اجتماعی خانواده می‌تواند بر دسترسی دانش‌آموزان به منابع آموزشی و فرصت‌های یادگیری تأثیر بگذارد، همسو است (Sirin, ۲۰۰۵).

نتایج پژوهش همچنین نشان داد که استفاده از مدل‌های پیش‌بینی مبتنی بر هوش مصنوعی می‌تواند به کاهش میزان افت تحصیلی کمک کند. همان‌طور که در جدول مربوط به مداخلات آموزشی مشاهده شد، پس از شناسایی دانش‌آموزان در معرض خطر و اجرای برنامه‌های حمایتی، درصد افت تحصیلی به‌طور قابل توجهی کاهش یافت. این یافته نشان می‌دهد که سیستم‌های هشدار زودهنگام مبتنی بر داده می‌توانند ابزار مؤثری برای مدیران آموزشی و معلمان باشند.

با وجود نتایج مثبت این پژوهش، برخی محدودیت‌ها نیز وجود دارد. نخست اینکه داده‌های مورد استفاده محدود به یک جامعه آموزشی خاص بوده و ممکن است تعمیم نتایج به سایر نظام‌های آموزشی نیازمند پژوهش‌های بیشتر باشد. همچنین برخی متغیرهای روان‌شناختی مانند انگیزش درونی یا اضطراب امتحان در داده‌ها لحاظ نشده‌اند که می‌توانند در پژوهش‌های آینده مورد بررسی قرار گیرند. در مجموع، نتایج این پژوهش نشان می‌دهد که هوش مصنوعی و یادگیری ماشین می‌توانند نقش مهمی در بهبود فرآیندهای تصمیم‌گیری آموزشی ایفا کنند. ترکیب تحلیل داده‌های آموزشی با مداخلات هدفمند می‌تواند به کاهش افت تحصیلی و بهبود کیفیت آموزش کمک کند.

نتیجه‌گیری (Conclusion)

افت تحصیلی یکی از مهم‌ترین چالش‌های نظام‌های آموزشی در سراسر جهان است و می‌تواند پیامدهای بلندمدتی برای دانش‌آموزان، خانواده‌ها و جامعه داشته باشد. شناسایی زودهنگام دانش‌آموزانی که در معرض خطر افت تحصیلی قرار دارند، می‌تواند نقش مهمی در پیشگیری از این مشکل ایفا کند. در سال‌های اخیر، پیشرفت‌های فناوری به‌ویژه در حوزه هوش مصنوعی و یادگیری ماشین فرصت‌های جدیدی برای تحلیل داده‌های آموزشی و پیش‌بینی عملکرد تحصیلی فراهم کرده است.

پژوهش حاضر با هدف بررسی کاربرد الگوریتم‌های هوش مصنوعی در پیش‌بینی افت تحصیلی دانش‌آموزان انجام شد. در این مطالعه، چندین الگوریتم یادگیری ماشین از جمله درخت تصمیم، ماشین بردار پشتیبان، شبکه عصبی مصنوعی و جنگل تصادفی مورد استفاده قرار گرفت. نتایج نشان داد که الگوریتم جنگل تصادفی بالاترین دقت را در پیش‌بینی افت تحصیلی دارد و می‌تواند به عنوان یک مدل مؤثر برای شناسایی دانش‌آموزان در معرض خطر مورد استفاده قرار گیرد.

یافته‌های پژوهش نشان داد که عواملی مانند عملکرد تحصیلی گذشته، میزان حضور در کلاس و سطح مشارکت آموزشی از مهم‌ترین متغیرهای پیش‌بینی‌کننده افت تحصیلی هستند. این نتایج نشان می‌دهد که ترکیبی از عوامل تحصیلی و رفتاری می‌تواند در شناسایی دانش‌آموزان در معرض خطر نقش داشته باشد. همچنین نتایج نشان داد که استفاده از سیستم‌های پیش‌بینی مبتنی بر هوش مصنوعی می‌تواند زمینه‌ساز اجرای مداخلات آموزشی هدفمند شود.

یکی از مهم‌ترین دستاوردهای این پژوهش، نشان دادن قابلیت استفاده از تحلیل داده‌های آموزشی برای طراحی سیستم‌های هشدار زودهنگام است. چنین سیستم‌هایی می‌توانند به معلمان و مدیران آموزشی کمک کنند تا پیش از بروز مشکلات جدی، اقدامات حمایتی لازم را برای دانش‌آموزان انجام دهند. این مداخلات می‌تواند شامل کلاس‌های تقویتی، برنامه‌های مشاوره تحصیلی و افزایش تعامل آموزشی باشد. با توجه به نتایج پژوهش، پیشنهاد می‌شود که مدارس و نظام‌های آموزشی از ابزارهای تحلیل داده و هوش مصنوعی برای پایش مستمر عملکرد تحصیلی دانش‌آموزان استفاده کنند. همچنین ترکیب داده‌های آموزشی با داده‌های رفتاری و روان‌شناختی می‌تواند به توسعه مدل‌های پیش‌بینی دقیق‌تر کمک کند. در نهایت، استفاده از هوش مصنوعی در آموزش نه تنها می‌تواند به شناسایی مشکلات تحصیلی کمک کند، بلکه می‌تواند زمینه‌ساز طراحی نظام‌های آموزشی هوشمند و شخصی‌سازی شده شود. چنین رویکردی می‌تواند به بهبود کیفیت یادگیری، افزایش انگیزه دانش‌آموزان و کاهش افت تحصیلی در نظام‌های آموزشی منجر شود.

- Baker, R., & Inventado, P. (۲۰۱۴). Educational data mining and learning analytics.
- Balfanz, R., & Byrnes, V. (۲۰۱۲). The importance of being in school.
- Breiman, L. (۲۰۰۱). Random forests. Machine Learning.
- Cortez, P., & Silva, A. (۲۰۰۸). Using data mining to predict secondary school student performance.
- Romero, C., & Ventura, S. (۲۰۱۳). Data mining in education.
- Siemens, G., & Long, P. (۲۰۱۱). Penetrating the fog: Analytics in learning.
- Kotsiantis, S., et al. (۲۰۰۴). Machine learning: A review of classification techniques.
- Goodfellow, I., Bengio, Y., & Courville, A. (۲۰۱۶). Deep Learning.
- Fredricks, J., Blumenfeld, P., & Paris, A. (۲۰۰۴). School engagement.
- Sirin, S. (۲۰۰۵). Socioeconomic status and academic achievement.
- Tinto, V. (۲۰۱۲). Completing college.
- Han, J., Kamber, M., & Pei, J. (۲۰۱۱). Data Mining: Concepts and Techniques.
- Witten, I., Frank, E., & Hall, M. (۲۰۱۱). Data Mining: Practical Machine Learning Tools.
- Kuh, G. (۲۰۰۹). What student affairs professionals need to know.
- Arnold, K., & Pistilli, M. (۲۰۱۲). Course signals at Purdue.
- Dekker, G., Pechenizkiy, M., & Vleeshouwers, J. (۲۰۰۹). Predicting student drop out.
- Herzog, S. (۲۰۰۶). Estimating student retention.
- Campbell, J., & Oblinger, D. (۲۰۰۷). Academic analytics.
- Ferguson, R. (۲۰۱۲). Learning analytics.
- Goldstein, P., & Katz, R. (۲۰۰۵). Academic analytics.
- Luan, J. (۲۰۰۲). Data mining in higher education.
- Macfadyen, L., & Dawson, S. (۲۰۱۰). Mining LMS data.
- Slade, S., & Prinsloo, P. (۲۰۱۳). Learning analytics ethics.
- Tempelaar, D., et al. (۲۰۱۵). Predictive learning analytics.

- Yu, L., et al. (۲۰۱۰). Feature selection methods.
- Alpaydin, E. (۲۰۱۴). Introduction to Machine Learning.
- Bishop, C. (۲۰۰۶). Pattern Recognition and Machine Learning.
- Mitchell, T. (۱۹۹۷). Machine Learning.
- Jordan, M., & Mitchell, T. (۲۰۱۵). Machine learning trends.
- Lakshminarayanan, B., et al. (۲۰۱۷). Deep ensembles.
- Zhang, Z., et al. (۲۰۱۸). AI in education.
- Holmes, W., et al. (۲۰۱۹). Artificial intelligence in education.
- Luckin, R., et al. (۲۰۱۶). Intelligence unleashed: AI in education.
- Baker, R. (۲۰۱۹). Challenges for AI in education.
- D'Mello, S., & Graesser, A. (۲۰۱۲). Dynamics of affective states.
- Shum, S., & Ferguson, R. (۲۰۱۲). Social learning analytics.
- Roll, I., & Wylie, R. (۲۰۱۶). Evolution of AI in education.
- Papamitsiou, Z., & Economides, A. (۲۰۱۴). Learning analytics review.
- Romero, C., & Ventura, S. (۲۰۲۰). Educational data mining review.

Using Artificial Intelligence to Predict Academic Decline in Students

Sakineh Janbazi

Persian Literature Teacher, M.A.

Fatemeh Vaso Joibari

Theology Teacher, B.A.

Hanieh Alinejad Seraji

English Teacher, M.A.

Forough Hedayati Heydarabadi

English Teacher, M.A.

Abstract

In recent years, remarkable advances in artificial intelligence (AI) and educational data analysis have created new opportunities for identifying and predicting students' academic difficulties. One of the most significant challenges faced by educational systems is the early detection of students at risk of academic decline. Academic underachievement can lead to long-term consequences such as dropping out of school, decreased learning motivation, limited future career opportunities. Traditional educational assessment methods often fail to accurately & timely identify these students. In this context, AI and machine learning can analyze large volumes of educational data to uncover hidden patterns related to academic performance and provide accurate predictions. The purpose of this study is to examine the application of AI algorithms in predicting students' academic decline. The educational data analyzed included grades, class attendance, learning participation, demographic characteristics, and behavioral indicators. Several machine learning algorithms—such as decision trees, random forests, support vector machines, and neural networks—used for data analysis. The results showed that machine-learning models reliably identify students at risk of academic decline. Among the models tested, the random forest algorithm provided the highest prediction accuracy. Furthermore, factors such as class attendance, past academic performance, and the level of educational participation recognized as the most influential in predicting academic decline. The findings of this study can assist educational managers and teachers in designing and implementing appropriate interventions by detecting at-risk students early. Overall, the use of artificial intelligence can play a crucial role in improving the quality of educational decision-making and reducing academic underachievement.

Keywords: Artificial Intelligence, Academic Decline, Machine Learning, Educational Data Analysis, Academic Performance Prediction