

# تحلیل آینده‌نگر عملکرد تحصیلی دانش‌آموزان بر مبنای ابعاد شخصیت با یادگیری ماشین خودکار (Auto ML)

مدیریت

اطلاعات

دوره ۸، شماره ۲

پاییز و زمستان ۱۴۰۱

بابک سهرابی<sup>۱</sup>

استاد، گروه مدیریت فناوری، دانشکده مدیریت صنعتی و فناوری، دانشکده‌گان مدیریت،

دانشگاه تهران، تهران، ایران

ایمان رئیسی وانانی

دانشیار، گروه مدیریت فناوری اطلاعات، دانشکده مدیریت صنعتی، دانشگاه علامه

طباطبائی، تهران، ایران

علی نوروزی

کارشناس ارشد، گروه مدیریت فناوری اطلاعات، دانشکده مدیریت صنعتی و فناوری،

دانشکده‌گان مدیریت، دانشگاه تهران، تهران، ایران

**چکیده:** پیش‌بینی عملکرد دانش‌آموزان برای والدین و معلمان آن‌ها از اهمیت بسزایی برخوردار است. در سال‌های اخیر، برای ارزیابی داده‌های آموزشی و عوامل تأثیرگذار بر عملکرد تحصیلی، از تحلیل یادگیری استفاده شده است. عوامل متعددی از جمله ویژگی‌های فردی، خانوادگی، اجتماعی و محیطی بر این موضوع تأثیرگذار هستند. یکی از مهم‌ترین عوامل فردی، شخصیت است که تأثیر این عامل را بر عملکرد تحصیلی بررسی خواهیم کرد. برای این منظور، داده‌های پنج دوره از دانش‌آموزان مدرسه‌ای در منطقه ۳ تهران را تحلیل می‌کنیم. پژوهش‌های انجام‌شده در این حوزه بیشتر به هم‌بستگی ابعاد مختلف پرداخته‌اند، اما هدف اصلی این پژوهش، پیش‌بینی عملکرد دانش‌آموزان به‌منظور شناسایی دانش‌آموزان در معرض افت تحصیلی است که با علم خانواده به این موضوع برای بهبود آنان اقدام کنند. متدولوژی استفاده‌شده CRISP-DM است. برای تحلیل، از تکنیک داده‌کاوی یادگیری ماشین خودکار (Auto ML) استفاده شده است. براساس معیار Accuracy، طبقه‌بندی در مقایسه با روش شبکه عصبی مصنوعی، با دقت بیشتری انجام شده است. طبق یافته‌های این پژوهش، بعد وظیفه‌شناسی در پیش‌بینی عملکرد دانش‌آموزان، بیشترین تأثیر و بعد روان‌رنجوری کمترین میزان تأثیر را داشته است.

**کلیدواژه‌ها:** تحلیل یادگیری، شخصیت، عملکرد تحصیلی، افت تحصیلی.

## مقدمه

بزرگ‌ترین نهاد دولتی در کشور ایران، آموزش و پرورش است (عربی، قشقایی و فرهودی، ۲۰۱۶). آموزش و پرورش همواره به‌عنوان یکی از ارکان و اساس رشد و توسعه جوامع انسانی، در مبانی اجتماعی، فرهنگی و توسعه‌ای یک کشور یا جامعه جایگاهی ویژه دارد. به این صورت که سیستم آموزشی بستر رشد و نمو نسل‌های آینده بشر بوده و باید به چشم‌آینده‌ای بالقوه به آن نگاه کرد (Sadler-Smith et al, 2016). براساس اطلاعات ثبت‌شده در سامانه سناد، تا ۲۵ شهریور ۱۳۹۸ تعداد دانش‌آموزان ۱۴/۴۶۸/۷۴۴ نفر بوده است. از این آمار، ۸/۱۷۴/۸۷۵ نفر در دوره ابتدایی، ۳/۳۵۱/۸۱۷ نفر در دوره متوسطه اول و ۲/۴۹۲/۳۸۸ نفر در دوره متوسطه دوم ثبت‌نام شده‌اند. عربی و همکاران (۲۰۱۶) ادعا دارند که ایران به‌لحاظ هرم سنی جمعیتی جوان بوده و اکنون دوران خوبی برای سرمایه‌گذاری در آموزش و پرورش است، زیرا بخش بیشتری از جمعیت خود را تحت تأثیر قرار خواهد داد.

امروزه عملکرد تحصیلی دانش‌آموزان برای والدین و معلمان آن‌ها از اهمیت زیادی برخوردار است. به‌طوری که پیش‌بینی عملکرد دانش‌آموز برای انتخاب رشته و برنامه‌ریزی در خصوص آینده شغلی و تحصیلی وی از دغدغه‌های اصلی والدین است (Vandamme et al, 2007). براساس پژوهش‌های مرکز ملی آمار آموزش و پرورش، کمی بیش از نیمی از دانشجویانی که برای نخستین بار در مؤسسه‌های چهارساله به‌طور تمام‌وقت تحصیل می‌کردند، طی مدت ۶ سال مدرک کارشناسی یا معادل آن را دریافت کردند (وزارت آموزش ایالات متحده و مرکز ملی آموزش و پرورش آمار، ۲۰۱۰). از آنجا که در تفاوت‌های فردی بین دانش‌آموزان تنوع زیادی وجود دارد، باید از تعامل بین عوامل فردی و محیط در فرایند یادگیری به‌منظور درک عوامل پیش‌بینی‌کننده موفقیت تحصیلی و بهبود نتایج دانش‌آموزان، درک بهتری داشته باشیم. موفقیت دانشجویان و دانش‌آموزان به‌تازگی برای اکثر مؤسسه‌های آموزش عالی به یک هدف استراتژیک اصلی تبدیل شده است (Zeineddine, Braendle & Farah, 2021).

در این پژوهش قرار است داده‌های یک مدرسه بزرگ در تهران را طی سال‌های مختلف بررسی کنیم، اما وزارت آموزش و پرورش به حجم عظیمی از داده‌های مرتبط با عملکرد، شخصیت و علاقه دانش‌آموزان دسترسی دارد. از کلیدی‌ترین اقدامات مورد نیاز برای تحلیل یادگیری، این است که چه‌طور از آن داده‌ها استفاده کنیم و متوجه شویم که در یک کلاس درس به‌طور حضوری یا آنلاین چه اتفاقاتی می‌افتد، به‌ویژه در ایام کرونا و پساکرونا که آموزش مجازی جایگاه ویژه‌ای یافته است و دانش‌آموزان و معلمان آن‌ها مدام در حال تولید داده‌های بارزشی هستند.

این پژوهش، دو هدف اصلی دارد. دسته نخست مربوط به شناسایی عوامل مؤثر (ابعاد شخصیت) و میزان تأثیر آن‌ها بر عملکرد تحصیلی دانش‌آموزان است. دسته دوم اهداف مربوط به پیش‌بینی و تحلیل افت عملکرد تحصیلی دانش‌آموزان در مدرسه مدنظر است که دانش‌آموزان براساس ابعاد شخصیت و نمرات سال‌های قبل خود طبقه‌بندی می‌شوند. به‌طور خلاصه اهداف اصلی این پژوهش عبارت‌اند از:

- تحلیل عملکرد تحصیلی با ابعاد شخصیت.

- طبقه‌بندی دانش‌آموزان از نظر افت تحصیلی و هدایت تحصیلی دانش‌آموزان و ارائه راهکار شخصی‌سازی‌شده مبتنی بر این طبقه‌بندی.

## ادبیات موضوع و پیشینه پژوهش

### تجزیه و تحلیل یادگیری

در سال‌های اخیر، تحول پژوهش‌ها در حوزه آموزش بر یادگیری تجزیه و تحلیل متمرکز است که با جمع‌آوری داده‌های ارزشمند در خصوص فرد یادگیرنده یا مؤسسه‌ها، در خصوص نتیجه آموزش بینش اساسی فراهم می‌کند (Ranjeeth, Latchoumi & Paul, 2020). تجزیه و تحلیل یادگیری به فرایند جمع‌آوری، ارزیابی، تحلیل و گزارش داده‌های آموزشی و یادگیری برای تصمیم‌گیری اشاره دارد (Wong, 2017). با توجه به معرفت‌شناسی اساسی در طراحی یادگیری، فراگیران ممکن است با مربیان و مدرسان، با محتوا یا با افراد دیگر تعامل داشته باشند (Elias, 2011).

با کمک تحلیل یادگیری، اساتید و دانشگاه‌ها می‌توانند عملکرد دانشجویان را ارزیابی کنند، میزان موفقیت و ماندگاری آنها را در مسیر آموزشی پیش‌بینی کرده و در نهایت برای بهبود عملکرد آنها اقدامات لازم را انجام بدهند (Dietz-Uhler & Hurn, 2013). این موضوع به‌طور عمده در دو جبهه متمرکز است: شناسایی ویژگی‌های مهم برای پیش‌بینی عملکرد دانش‌آموزان و یافتن بهترین روش پیش‌بینی برای افزایش دقت پیش‌بینی (Zeineddine et al, 2021).

رویکردهای سنتی برای پاسخ به این پرسش‌ها، شامل ارزیابی دانشجو، تجزیه و تحلیل نمرات و میزان فرسایش و ادراک مربی است که اغلب در پایان دوره جمع‌آوری می‌شوند.

تجزیه و تحلیل یادگیری، تحلیل و نمایش داده‌ها در خصوص فراگیران به‌منظور بهبود یادگیری، دریچه جدیدی است که معلمان می‌توانند از طریق آن آموزش را درک کنند (Clow, 2013). تجزیه و تحلیل یادگیری، مسیرهای جدیدی برای معلمان فراهم می‌آورد تا دانش‌آموزان خود را درک کنند و از منابع محدود خود به‌طور مؤثر استفاده کنند. معلمان می‌توانند با یادگیری تحلیلی به‌عنوان راهی به‌منظور تأثیرگذاری در برنامه معیارها برای برداشت‌های غنی‌تر از یادگیری و بهبود آموزش خود استفاده کنند (Clow, 2013).

### شخصیت

کلمه شخصیت از کلمه لاتین پرسونا نشئت می‌گیرد و به ماسک تئاتری اشاره می‌کند که هنرمندان اجرا می‌کنند تا نقش‌های مختلف را طرح کرده یا هویت آنها را مخفی کند (Revelle, 2017). در ابتدایی‌ترین حالت، شخصیت الگوهای مشخص افکار، احساسات و رفتارهاست که شخص را منحصر به فرد می‌کند. اعتقاد بر این است که شخصیت از درون فرد نشئت می‌گیرد و طی زندگی به‌نسبت سازگار است (Anglim et al., 2020).

در حالی که از شخصیت تعاریف متفاوتی وجود دارد، اکثر آنها بر الگوی رفتارها و ویژگی‌هایی تمرکز می‌کنند که می‌تواند به پیش‌بینی و توضیح رفتار فرد کمک کند (Bashiri Haddadan et al, 2016). توضیحات مربوط به شخصیت می‌تواند بر انواع تأثیرات متمرکز شود، از توضیحات ژنتیکی برای ویژگی‌های شخصیتی گرفته تا نقش محیط و تجربه در شکل‌گیری شخصیت افراد (Horstmann & Ziegler, 2020).

شخصیت به‌عنوان مجموعه مشخص رفتارها، شناخت‌ها و الگوهای احساسی که از عوامل زیستی و محیطی تکامل می‌یابند، تعریف می‌شود (Matthews, 2009).

شخصیت به الگوهای فکری، احساسی و رفتاری مشخص افراد، همراه با تصورات روان‌شناختی - پنهان یا آشکار - در پشت آن الگوها اشاره دارد (Furr & Funder, 2004).

شخصیت را می‌توان با آزمون‌های مختلفی تعیین کرد. با توجه به اینکه شخصیت موضوعی پیچیده است، ابعاد شخصیت و مقیاس آزمون‌های شخصیت متفاوت بوده و اغلب به‌طور ضعیفی تعریف شده است. آزمون‌های عینی و اقدامات پیش‌بینی‌شده، دو ابزار اصلی برای سنجش شخصیت هستند. نمونه‌هایی از این گونه آزمون‌ها عبارت‌اند از: پرسش‌نامه پنج‌عاملی (BFI)، پرسش‌نامه شخصیت چندفازی مینه‌سوتا (MMPI-2)، آزمون رورشاخ اینکبلوت، پرسش‌نامه شخصیت عصبی KON-2016 و پرسش‌نامه شخصیت آیزنک (EPQ-R) (Aleksandrowicz, Klasa, Sobański & Stolarska, 2007). همه این آزمون‌ها مفید هستند، زیرا دارای قابلیت اطمینان و اعتبار هستند.

شخصیت به عوامل یا ابعاد تقسیم می‌شود که از طریق تجزیه و تحلیل عاملی از پرسش‌نامه‌ها استخراج می‌شود. در پژوهش‌هایی که از دو بعد استفاده شده است، اغلب ابعاد درون‌گرا - برون‌گرا و روان‌رنجوری (از نظر عاطفی ناپایدار - پایدار) بررسی می‌شود. برای نخستین بار آیزنک در دهه ۱۹۶۰ از این کار استفاده کرد (Eysenck, 1967).

در مدل ۵ فاکتور تطبیقی شخصیت<sup>۱</sup>، شخصیت دارای ۵ بعد است. بعد نخست آن روان‌آزردگی<sup>۲</sup> است و میزان اضطراب، ثبات عاطفی و علائم هیجانی فرد است که در یک سمت آن اضطراب بالا و ثبات عاطفی کم و در مقابل ثبات عاطفی زیاد و اضطراب کم است (Jalili & Mall-Amiri, 2015).

بعد دوم آن برون‌گرایی<sup>۳</sup> است که در واقع شادابی و نشاط، میزان احتیاط (محافظه‌کاری) و جامعه‌پذیری را شامل می‌شود. بعد سوم آن وظیفه‌شناسی<sup>۴</sup> (باوجدان بودن) است که مسئولیت‌پذیری، خستگی‌ناپذیری و عزت نفس نمایان‌گر آن هستند. بعد چهارم مربوط به گشودگی تجارب<sup>۵</sup> شخص است که میزان برتری‌جویی، تفکر پویا، خودتنظیمی را نشان می‌دهد و افراد با این ویژگی انعطاف بالایی از خود

1. Five-factor model of adaptive personality (FFM)
2. Neuroticism
3. Extraversion
4. Conscientiousness
5. Openness to experience

نشان می‌دهند (Costa et al., 2002) و بعد پنجم توافق‌پذیری<sup>۱</sup> است که سنج‌های آن مردانگی، روابط با هم‌سالان و هم‌دلی است (Allport, 1961).

این ابعاد پنج‌گانه به‌طور کلی طی زمان پایدار هستند و به نظر می‌رسد که نیمی از تغییرات به‌دلیل تأثیرات محیطی به ژنتیک فرد مربوط می‌شود (Briley & Tucker-Drob, 2014). ویژگی‌های شخصیتی تحت تأثیر محیط بیشتر از آنچه پژوهشگران در ابتدا تصور می‌کردند انعطاف‌پذیر هستند (Jerominus et al, 2014). قوت‌های شخصیت را می‌توان به‌عنوان ویژگی‌های مثبتی تعریف کرد که در افکار، احساسات و رفتارهای افراد منعکس می‌شود (Park et al., 2004) تفاوت‌های شخصیتی وقوع تجربه‌های زندگی را پیش‌بینی می‌کند (Anglim et al, 2020). در نظریه اجتماعی شدن گروهی، ریچ هریس<sup>۲</sup> معتقد است که گروه‌های هم‌سالان یک فرد، به‌جای شخصیت‌های والدین، تأثیر اولیه شخصیت و رفتار در بزرگسالی هستند. فرایندهای درون‌گروهی و بین‌گروهی، بیشتر از روابط دوجانبه مانند روابط والدین و فرزندان، مسئول انتقال فرهنگ و تعدیل محیطی ویژگی‌های شخصیتی کودکان هستند. بنابراین، این نظریه نشان می‌دهد که تأثیر محیط بر شخصیت کودک بیشتر از سبک رفتار والدین یا محیط خانه است (Harris, 1995). ارزیابی‌ها نشان می‌دهد که تجمع تجربه‌های کوچک روزانه ممکن است برای رشد شخصیت دانشجویان دانشگاه مفید باشد و تأثیرات محیطی ممکن است با حساسیت فردی به تجربه‌ها، مانند امنیت متفاوت باشد (Kawamoto, 2016). برخی از پژوهش‌ها نشان می‌دهد که محیط خانوادگی مشترک بین خواهر و برادر نسبت به تجربه‌های فردی هر کودک تأثیر کمتری بر شخصیت دارد. دوقلوهای هم‌سان تا حد زیادی دارای شخصیت مشابهی هستند، زیرا از نظر ژنتیکی بیشتر یکسان هستند تا محیط مشترک (Anglim et al, 2020).

ویژگی‌های شخصیتی، ترکیبی از ویژگی‌هایی است که برای افراد به‌صورت فردی ذاتی بوده و ویژگی‌هایی که از تجربه‌های خاص زندگی ایجاد می‌شود. ویژگی‌های شخصیتی که یک فرد را تشکیل می‌دهد، تا حد زیادی در تعیین میزان موفقیت وی کمک می‌کند. ویژگی‌های شخصیتی خاصی وجود دارد که به موفقیت معلمان و دانش‌آموزان کمک می‌کند. موفقیت ممکن است برای افراد مختلف معانی متفاوتی داشته باشد. معلمان و دانش‌آموزانی که اکثریت ویژگی‌های زیر را دارند تقریباً بدون در نظر گرفتن تعریف موفقیت، همیشه موفق هستند.

**تطبیق‌پذیری<sup>۳</sup>:** این توانایی کنترل تغییرات ناگهانی بدون ایجاد حواس‌پرتی است. دانش‌آموزانی که این ویژگی را دارند می‌توانند با مشکلات ناگهانی کنار بیایند و اجازه ندهند هم‌کلاسی آن‌ها رنج ببرد. معلمان که این ویژگی را دارند به‌سرعت می‌توانند تغییراتی ایجاد کنند که باعث کاهش حواس‌پرتی شود، در صورتی که همه چیز طبق برنامه پیش نرود (Backmann, Weiss, Schippers & Hoegl, 2019).

1. Agreeableness

2. Judith Rich Harris

3. Adaptability

## روش Auto ML

یادگیری ماشینی خودکار<sup>۱</sup> (AutoML) فرایند خودکارسازی استفاده از یادگیری ماشین در مسائل دنیای واقعی است (Thornton et al, 2013). AutoML پروسه کامل را از مجموعه داده خام تا مدل یادگیری ماشین قابل استفاده پوشش می‌دهد. AutoML به‌عنوان یک راه‌حل مبتنی بر هوش مصنوعی برای مشکل روزافزون استفاده از یادگیری ماشین پیشنهاد شده است (Zeineddine et al, 2021). اتوماسیون در AutoML به افراد غیرمتخصص اجازه می‌دهد تا از الگوها و تکنیک‌های یادگیری ماشین بدون نیاز به تخصص در یادگیری ماشین استفاده کنند. خودکارسازی فرایند استفاده از یادگیری ماشینی علاوه بر مزایای ایجاد راه‌حل‌های ساده‌تر، ایجاد سریع‌تر راه‌حل‌ها و مدل‌ها را نیز ارائه می‌دهد. از AutoML برای مقایسه اهمیت نسبی هر عامل در یک مدل پیش‌بینی استفاده می‌شود (Feurer et al, 2019).

در ادبیات، برای پیش‌بینی عملکرد دانش‌آموزان، از چند روش یادگیری ماشین استفاده شده است. برای این منظور به‌طور عمده از رگرسیون لجستیک، درخت تصمیم، شبکه عصبی مصنوعی، Naive Bayes، K نزدیک‌ترین همسایه و ماشین‌های بردار پشتیبانی استفاده شده است (Zeineddine et al, 2021). روش‌های رگرسیونی برای پیش‌بینی عملکرد دانش‌آموز از مجموعه محدودی از روابط بین متغیرهای وابسته و مستقل استفاده می‌کنند و یک تابع پیش‌بینی را ایجاد می‌کنند که این ارتباطات را مدل‌سازی می‌کند (Mayilvaganan & Kalpanadevi, 2014). روش رگرسیون لجستیک برای پیش‌بینی عملکرد دانش‌آموزان به‌طور معمول برای توصیف ارتباط بین تعدادی از متغیرهای مستقل استفاده می‌شود که می‌توانند به‌صورت باینری، طبقه‌ای و مداوم دسته‌بندی شوند (Romero, spejo, Zafra, Romero & Ventura, 2013). منطق هنگام استفاده از تکنیک‌های درخت تصمیم معادل یک سری عبارات IF-THEN است که می‌تواند به ساده‌سازی درک این روش کمک کند. چند مقاله وجود دارد که از این روش برای پیش‌بینی عملکرد دانش‌آموز با استفاده از شاخص‌های کلیدی مانند نمرات دانشجو در دوره‌های خاص و معدل فعلی استفاده کرده‌اند (Zeineddine et al, 2021). توانایی شبکه عصبی مصنوعی در تشخیص ارتباط پیچیده بین متغیرهای مستقل و وابسته، آن را به ابزاری قدرتمند در پیش‌بینی عملکرد دانش‌آموزان تبدیل می‌کند (Marbouti, Diefes-Dux & Madhavan). متغیرهای متداول استفاده‌شده در پیش‌بینی عملکرد دانش‌آموزان با استفاده از شبکه عصبی، نگرش دانشجویان به یادگیری، داده‌های پذیرش، CGPA و نمرات دروس خاص است. این تکنیک به دقت ۹۸ درصدی در پیش‌بینی عملکرد دانش‌آموزان با استفاده از داده‌ها پس از پیوستن دانشجویان به مؤسسه آموزشی منجر شده است (Zeineddine et al, 2021). Naive Bayes روش دیگری است که برای پیش‌بینی عملکرد دانش‌آموزان استفاده می‌شود. این روش، از کلیه ویژگی‌های موجود در داده‌ها استفاده می‌کند و برای نشان دادن اهمیت و تأثیر هر یک از این پیش‌بینی‌ها، بین متغیرهای مستقل مقایسه می‌کند (Shahiri & Husain, 2015). مقالاتی که از این روش استفاده می‌کنند، به‌طور عمده متغیرهایی مانند نمرات، بورسیه‌ها، CGPA، پیشینه دانش‌آموز، جمعیت‌شناسی، داده‌های شبکه اجتماعی و ارزیابی‌های داخلی را در نظر

می‌گیرند (Zeineddine et al, 2021). K-Nearest Neighbours، الگوریتمی ساده است که یک نقطه داده را براساس نزدیک‌ترین کلاس رایج همسایه‌های آن طبقه‌بندی می‌کند. داده‌های این تکنیک شامل تعدادی از ویژگی‌های چندمتغیره است که برای طبقه‌بندی استفاده می‌شود. روش K نزدیک‌ترین همسایه در پیش‌بینی عملکرد دانش‌آموزان از نظر سطح یادگیری (یادگیرنده کند، متوسط، خوب و عالی) سریع است (Strecht et al., 2015). میزان صحت آن هنگام استفاده از عوامل روانی حرکتی کمی بالاتر از ۶۰ درصد بود و هنگام استفاده از داده‌های استخراج‌شده از ارزیابی‌های داخلی، CGPA و فعالیت‌های خارج از برنامه، به ۸۳ درصد رسید (Zeineddine et al, 2021). طبق نتایج پیشینه پژوهش، بین عامل‌های برون‌گرایی و وظیفه‌شناسی با استرس تحصیلی رابطه منفی و معنادار و با عامل روان تندرستی رابطه مثبت و معنادار وجود دارد. همچنین، ویژگی‌های مثبت شخصیتی از پیامدهای مخرب استرس محافظت می‌کنند و مانع اختلال تحصیلی می‌شوند. متغیرهای آموزشی و مالی از پیش‌بینی‌کننده‌های مهم اختلال هستند. رابطه ویژگی‌های شخصیتی برون‌گرایی و وظیفه‌شناسی با عملکرد تحصیلی، مثبت و مستقیم و با روان‌رنجوری، منفی و معکوس است. انعطاف‌پذیری استاد در رضایت و عملکرد دانشجویان به‌بیشترین تأثیر دارد. دو عامل مسئولیت‌پذیری و روان‌رنجوری با رضایت و عملکرد هم‌بستگی منفی دارند. نوع مدل ریاضی در میانگین دقت پیش‌بینی تأثیر کمی دارد. یک مدل به‌خوبی نمرات امتحان نهایی همه دانش‌آموزان را در دوره پویایی پیش‌بینی می‌کند. نمرات قبلی قوی‌ترین پیش‌بینی‌کننده معدل متوسطه و عوامل روان‌شناختی و رفتاری (برای مثال انگیزه، خودتنظیمی و کنترل اجتماعی) اعتبار معدل پیش‌بینی را افزایش می‌دهند. جنسیت، تعداد دانش‌آموزان در یک کلاس، تعداد دوره‌های ارائه‌شده در یک ترم و رشته تحصیلی از عوامل مهم مؤثر بر عملکرد دانشجویان هستند. صفت شخصیت توافق و هیجان‌پذیری، در پیش‌بینی عملکرد تحصیلی دانشجویان نقش بیشتری دارند.


همچنین، براساس نتایج، در کشور ایران بیشتر پژوهش‌ها در این زمینه به‌صورت اثر ابعاد شخصیت بر نمرات دانش‌آموزان انجام شده بود یا در پژوهش‌های دیگر این طبقه‌بندی با یک روش انجام شده بود.

### شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی (ANNs)<sup>۱</sup> که معمولاً شبکه‌های عصبی (NNs)<sup>۲</sup> گفته می‌شوند، سیستم‌های محاسباتی‌ای هستند که از شبکه‌های عصبی بیولوژیکی که مغز موجودات را تشکیل می‌دهند، الهام گرفته‌اند (Nix & Zhang, 2017). اصطلاحات «شبکه عصبی» (NN) و «شبکه عصبی مصنوعی» (ANN) معمولاً به شبکه پرسپترون چندلایه<sup>۳</sup> اشاره دارند. با این حال، انواع دیگر شبکه‌های عصبی هم وجود دارد که می‌توان به ماشین بردار پشتیبان<sup>۴</sup> و کمی‌سازی بردار یادگیرنده<sup>۵</sup> اشاره کرد. شبکه پرسپترون چندلایه دارای یک لایه ورودی (در سمت چپ) با سه نورون، یک لایه پنهان (در وسط) با سه نورون و یک لایه

1. Artificial neural networks
2. Neural networks
3. Multilayer Perceptron Network
4. Support vector machines
5. Learner vector quantification

خروجی (در سمت راست) با سه نورون است. برای هر متغیر پیش‌بینی‌کننده یک نورون در لایه ورودی وجود دارد. در طبقه‌بندی، از  $N-1$  نورون برای  $N$  متغیر استفاده می‌شود.



شکل ۱. اجزای شبکه پرسپترون چندلایه

**لایه ورودی:** بردار مقادیر متغیر پیش‌بینی‌کننده  $(x_1 \dots x_p)$  به لایه ورودی وارد می‌شود. لایه ورودی (یا پردازش قبل از لایه ورودی) این مقادیر را استاندارد می‌کند، به طوری که محدوده هر متغیر از  $-1$  تا  $1$  است. لایه ورودی مقادیر را بین هر یک از نورون‌های لایه پنهان توزیع می‌کند. علاوه بر متغیرهای پیش‌بینی‌کننده، عدد ثابت  $1/0$  که به آن بایاس<sup>۱</sup> می‌گویند به هر یک از لایه‌های پنهان داده می‌شود. بایاس در یک ضریب وزنی ضرب می‌شود و به مجموع ورودی به نورون اضافه می‌شود.

**لایه پنهان:** با رسیدن یک نورون به لایه پنهان، مقدار هر نورون ورودی در یک وزن  $(w_{ji})$  ضرب می‌شود و مقادیر وزنی حاصل با هم جمع می‌شوند و مقدار ترکیبی  $u_j$  را تولید می‌کنند. مجموع وزنی  $(u_j)$  به یک تابع انتقال،  $\sigma$  وارد می‌شود که مقدار  $h_j$  را به دست می‌دهد. خروجی‌های لایه پنهان به لایه خروجی توزیع می‌شود.

**لایه خروجی:** با رسیدن یک نورون به لایه خروجی، مقدار هر نورون لایه پنهان در یک وزن  $(w_{kj})$  ضرب می‌شود و مقادیر وزنی حاصل با هم جمع می‌شوند و مقدار ترکیبی  $v_j$  را تولید می‌کنند. مجموع وزنی  $(v_j)$  به تابع انتقال،  $\sigma$  وارد می‌شود که مقدار  $y_k$  را به دست می‌دهد. مقادیر  $y$  خروجی‌های شبکه هستند (Kweik et al, 2020).



هر اتصال، مانند سیناپس<sup>۱</sup> های مغز بیولوژیکی، می‌تواند سیگنالی را به سایر نورون‌ها منتقل کند. یک نورون مصنوعی سیگنالی دریافت می‌کند و سپس آن را پردازش می‌کند و می‌تواند به نورون‌های متصل به آن سیگنال دهد (Schmidhuber, 2015). سیگنال در واقع یک عدد واقعی است و خروجی هر نورون توسط برخی از عملگرهای غیر خطی از مجموع ورودی‌های آن محاسبه می‌شود. اتصالات را لبه<sup>۲</sup> می‌نامند. نورون‌ها و لبه‌ها معمولاً وزنی دارند که با پیشرفت یادگیری تنظیم می‌شود (Schmidhuber, 2015). وزن باعث افزایش یا کاهش قدرت سیگنال در یک اتصال می‌شود. نورون‌ها ممکن است حد آستانه‌ای<sup>۳</sup> داشته باشند که سیگنال فقط در صورت عبور سیگنال کل از آن آستانه ارسال شود. به‌طور معمول، نورون‌ها به‌صورت چند لایه<sup>۴</sup> جمع می‌شوند. لایه‌های مختلف ممکن است تغییرات متفاوتی را روی ورودی‌های خود انجام دهند. سیگنال‌ها از لایه اول (لایه ورودی) و پس از گذراندن چند لایه تا آخرین لایه (لایه خروجی) حرکت می‌کنند.

همه شبکه‌های عصبی دارای یک لایه ورودی و یک لایه خروجی هستند، اما ممکن است تعداد لایه‌های پنهان متفاوت باشد. شبکه‌های ANN به‌عنوان تلاشی برای بهره‌برداری از معماری مغز انسان برای انجام وظایفی که الگوریتم‌های معمولی موفقیت چندانی در آنها نداشت، آغاز شد. آنها به‌زودی در راستای بهبود نتایج تجربی تغییر جهت دادند و به‌طور عمده تلاش برای وفادار ماندن به پیش‌سازهای بیولوژیکی خود را کنار گذاشتند. نورون‌ها در الگوهای مختلف به یکدیگر متصل شده‌اند تا خروجی برخی از نورون‌ها به ورودی دیگر تبدیل شود (Schmidhuber, 2015). شبکه، یک نمودار هدایت‌شده و وزن‌دار را تشکیل می‌دهد. یک شبکه عصبی مصنوعی شامل مجموعه‌ای از نورون‌های شبیه‌سازی‌شده است. هر نورون یک گره است که از طریق پیوندهایی که مربوط به اتصالات بیولوژیکی آکسون - سیناپس - دندریت<sup>۵</sup> است به گره‌های دیگر متصل می‌شود. هر پیوند دارای وزنی است که قدرت تأثیر یک گره بر دیگری را تعیین می‌کند (Nix & Zhang, 2017).

## روش ارزیابی

هنگام انجام پیش‌بینی‌های طبقه‌بندی، ممکن است چهار نوع نتیجه رخ دهد.

- مثبت واقعی<sup>۶</sup> زمانی است که پیش‌بینی می‌کنید یک مشاهده متعلق به یک کلاس است و در واقع متعلق به آن کلاس است.
- منفی واقعی<sup>۷</sup> زمانی است که پیش‌بینی می‌کنید مشاهده‌ای به یک کلاس تعلق ندارد و در واقع متعلق به آن کلاس نیست.

---

1. synapse  
 2. edge  
 3. Threshold  
 4. layer  
 5. Axon-synapse-dendrite  
 6. True positives  
 7. True negatives

- زمانی که پیش‌بینی می‌کنید مشاهده‌ای متعلق به یک کلاس است، در حالی که در واقعیت چنین نیست، مثبت کاذب<sup>۱</sup> رخ می‌دهد.
  - منفی کاذب<sup>۲</sup> زمانی رخ می‌دهند که پیش‌بینی می‌کنید مشاهده‌ای در واقع متعلق به یک کلاس نیست، اما درحقیقت چنین است.
- براساس ماتریس حاصل از مطالب بالا می‌توان انواع مختلفی از معیارها و خطاها را اندازه‌گیری کرده و دقت و صحت مدل را ارزیابی کرد.

**Accuracy:** دقت به‌عنوان درصد پیش‌بینی صحیح برای داده‌های آزمایش تعریف می‌شود. می‌توان آن را به‌راحتی با تقسیم تعداد پیش‌بینی‌های صحیح بر تعداد کل پیش‌بینی‌ها محاسبه کرد.

$$\text{accuracy} = \frac{\text{correct predictions}}{\text{all predictions}} \quad \text{رابطه ۱}$$

**AUC:** این شاخص که ناحیه زیر منحنی<sup>۳</sup> است، نشان‌دهنده درجه یا اندازه تفکیک‌پذیری است و نشان می‌دهد که مدل چقدر می‌تواند بین کلاس‌ها تمایز قائل شود. هرچه AUC بالاتر باشد، مدل در تمایز بین نمونه‌های کلاس‌های مختلف بهتر عمل می‌کند.

**Precision:** این شاخص به‌عنوان کسری از مثال‌های مرتبط (مثبت واقعی) در بین همه مثال‌هایی که پیش‌بینی شده‌اند و متعلق به یک کلاس خاص هستند، تعریف می‌شود.

$$\text{precision} = \frac{\text{true positives}}{\text{true positives} + \text{false positives}} \quad \text{رابطه ۲}$$

**Recall:** این شاخص به‌عنوان بخشی از نمونه‌هایی تعریف می‌شود که با توجه به همه نمونه‌هایی که واقعاً در کلاس هستند، متعلق به یک کلاس هستند.

$$\text{recall} = \frac{\text{true positives}}{\text{true positives} + \text{false negatives}} \quad \text{رابطه ۳}$$

## روش پژوهش

این پژوهش با توجه به اینکه از داده‌های موجود در پایگاه داده مدرسه استفاده کرده‌ایم، از نوع کمی توصیفی است. همچنین به این دلیل که برای مدل‌سازی از دو روش استفاده کردیم (AutoML و شبکه‌های عصبی)، از شاخه علی مقایسه‌ای و به‌صورت مولتی‌متد است. بنابراین، به‌طور خلاصه پژوهش از نوع کمی توصیفی، از شاخه علی مقایسه‌ای و به‌صورت مولتی‌متد است. از آنجا که مسئله بررسی شده با رویکرد داده‌کاوی تحلیل می‌شود، متدولوژی استفاده‌شده CRISP-DM است. متدولوژی CRISP-DM<sup>۴</sup>

1. False positives

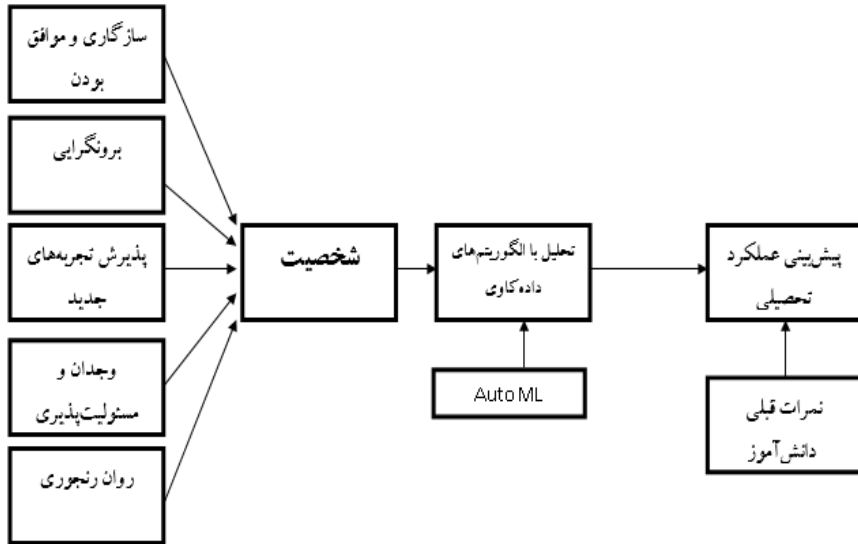
2. False negatives

3. Area Under The Curve

4. Cross Industry Standard Process for Data Mining

(فرایند استاندارد میان‌صنعتی برای داده‌کاوی) یک مدل فرایند جامع برای انجام پروژه‌های داده‌کاوی است (Wirth & Hipp, 2000).

با بررسی ادبیات موضوع، دو دسته متغیر اصلی در ایجاد مدل پیش‌بینی عملکرد دانش‌آموزان شناسایی شده‌اند که مدل مفهومی پژوهش بر این اساس شکل گرفته است. این مدل در شکل ۲ نشان داده شده است.



شکل ۲. مدل مفهومی پژوهش

تعداد ۱۵۵۲ دانش‌آموز پایه‌های مختلف تحصیلی با توجه به دسترسی به اطلاعات آن‌ها (از میان این دانش‌آموزان به‌طور تصادفی داده‌های آموزش و داده‌های آزمون انتخاب خواهند شد).

یک‌سوم از داده‌ها را به‌طور تصادفی انتخاب می‌کنیم که به مجموعه اعتبارسنجی<sup>۱</sup> معروف است. تقسیم معمولی آموزش/ آزمون/ اعتبارسنجی این است که از ۶۰ درصد داده‌ها برای آموزش، ۲۰ درصد از داده‌ها برای اعتبارسنجی و ۲۰ درصد از داده‌ها برای آزمایش استفاده شوند.

داده‌های مورد نیاز دو دسته هستند. دسته نخست داده‌های عملکرد تحصیلی دانش‌آموزان که این داده‌ها از پایگاه‌داده مدرسه و جست‌وجو روی انبار داده و با استفاده از ابزارهای اوراکل و میکروسافت به دست آمد. دسته دوم داده‌های مربوط به تست شخصیت است که با توزیع پرسش‌نامه در میان دانش‌آموزان، معلمان و والدین دانش‌آموز به ثبت رسیده است. داده‌های مربوط به تست شخصیت دانش‌آموزان در سال‌های گذشته نیز در پایگاه‌داده مدرسه موجود بوده است.

## تحلیل نتایج

در این قسمت طبق متدولوژی CRISP-DM پیش می‌رویم.

### شناخت کسب‌وکار

این مرحله اولیه در درک اهداف و نیازهای پروژه از دیدگاه کسب‌وکار و سپس تبدیل این دانش به تعریف مسئله داده‌کاوی و برنامه اولیه پروژه برای دستیابی به اهداف متمرکز است. طبق پژوهش‌های انجام‌شده، مدرسه مدنظر هرساله تعداد زیادی رتبه برتر در المپیادهای دانش آموزی کسب می‌کند. میزان درصد افت تحصیلی هرساله بیشتر شده و در برخی پایه‌ها با جهش همراه بوده است. در دوران اوج‌گیری ویروس کرونا و مجازی شدن تدریس در مدارس سراسر کشور از اسفند ۱۳۹۸، حجم عظیمی از داده‌ها توسط معلمان و دانش‌آموزان در حال تولید است. شیوع این بیماری این فرصت را فراهم آورده است که از این داده‌ها و همچنین از این فضا برای تولید داده‌های جدید از طریق پرسش‌نامه‌ها استفاده کرده و از آن‌ها در راستای بهبود وضعیت روحی و عملکرد تحصیلی دانش‌آموزان استفاده کرد.

### شناخت داده‌ها

مرحله درک داده‌ها با جمع‌آوری اطلاعات اولیه آغاز می‌شود و برای آشنایی با داده‌ها، شناسایی مشکلات کیفیت داده‌ها، کشف نخستین بینش در خصوص داده‌ها یا کشف زیرمجموعه‌های جالب برای تشکیل فرضیه‌های اطلاعات پنهان، فعالیت‌هایی انجام می‌دهد. مقاطع تحصیلی دانش‌آموزان، پیش دبستان، اول تا ششم دبستان، اول تا سوم راهنمایی و اول و دوم متوسطه است که در فکت‌های مختلف همه یا به‌طور کلی در Dim\_Set ۵۷ دوره داریم، اما داده‌های دانش‌آموزان فقط برای ۲۳ دوره موجود است که از دوره ۳۱ تا ۵۲ (که فقط شامل یک StudentID است) است. دوره‌های ۳۱ تا ۵۲ دارای تعداد دانش‌آموز متفاوتی هستند که تعداد آنها بین ۵۴ تا ۷۶ متغیر است.

براساس Dim\_Student به‌طور کلی ۱۵۵۲ کد شناسایی برای دانش‌آموزان (StudentID) یا به بیان دیگر، ۱۵۵۲ دانش‌آموز داریم که در مقاطع مختلف تحصیلی کد شناسایی کلاس را نیز گرفته‌اند، بنابراین StudentClassID ۷۲۶۴ داریم.

### آماده‌سازی داده‌ها

مرحله آماده‌سازی داده‌ها، کلیه فعالیت‌های ساخت مجموعه داده نهایی (داده‌هایی که در ابزار (های) مدل‌سازی) از داده‌های اولیه خام وارد می‌شوند را در برمی‌گیرد. وظایف آماده‌سازی داده‌ها به احتمال زیاد چند بار انجام می‌شود و به ترتیب خاصی نیست. این وظایف شامل ضبط، انتخاب ویژگی، تمیز کردن داده‌ها، ساخت ویژگی‌های جدید و تبدیل داده‌ها برای ابزارهای مدل‌سازی است.

برای این منظور کارهای زیر روی داده‌ها انجام شد:

- ترکیب فکت‌ها و دایم‌های مربوطه با یکدیگر
- حذف برخی رکوردها

- ساخت یک جدول نهایی که در این جدول هر دانش‌آموز تبدیل به یک رکورد می‌شود.
- گسسته‌سازی نمرات
- Pivot کردن جدول

## مدل‌سازی

در این مرحله، تکنیک‌های مختلف مدل‌سازی انتخاب و اعمال شده و پارامترهای آنان در مقادیر مطلوب کالیبره می‌شوند. به‌طور معمول، برای همان نوع مشکل داده‌کاوی چند روش وجود دارد. برخی از تکنیک‌ها به قالب‌های داده خاص نیاز دارند.

پس از آماده‌سازی داده‌ها، یک جدول با هفت متغیر (پنج متغیر مستقل شخصیت دانش‌آموزان، یک متغیر مستقل نمرات سابق دانش‌آموز و یک متغیر وابسته با عنوان معدل فعلی دانش‌آموز) و دارای ۱۵۵۲ رکورد (تعداد دانش‌آموزان) به دست آمد.

برای آغاز مدل‌سازی ابتدا نیاز است داده‌ها به دو دسته آموزشی<sup>۱</sup> و آزمایشی<sup>۲</sup> تقسیم شوند. همچنین، ستون نمره به‌عنوان لیبِل باید از داده‌های تست حذف شود. توجه شود که یک‌سوم داده‌ها به‌عنوان داده‌های تست انتخاب شدند. از داده‌های جدید برای ارزیابی مدل خود برای جلوگیری از احتمال بیش‌برازش<sup>۳</sup> مجموعه آموزشی استفاده کردیم. با وجود این، گاهی اوقات ارزیابی مدل در حال ساختن آن برای یافتن بهترین پارامترهای یک مدل مفید است، اما نمی‌توانیم از مجموعه آزمون برای این ارزیابی استفاده کنیم. برای ارزیابی مدل در حالی که هنوز در حال ساخت و تنظیم مدل هست، یک‌سوم از داده‌ها را به‌طور تصادفی انتخاب می‌کنیم که به مجموعه اعتبارسنجی معروف است. تقسیم معمولی آموزش/آزمون/اعتبارسنجی این است که از ۶۰ درصد داده‌ها برای آموزش، ۲۰ درصد از داده‌ها برای اعتبارسنجی و ۲۰ درصد از داده‌ها برای آزمایش استفاده شود.

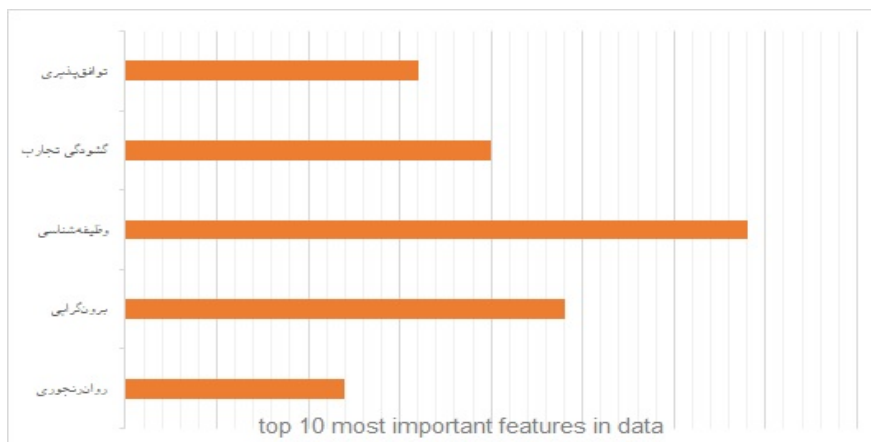
پس از جداسازی داده‌های دانش‌آموزان جدید به‌عنوان داده‌های اعتبارسنجی، جداسازی تست و تمرین انجام می‌شود. پس از نمونه‌گیری از داده‌ها، برای طبقه‌بندی نمرات دانش‌آموزان، از روش تحلیل داده Auto-ML استفاده شد. برای تحلیل با این روش در زبان پایتون از کتابخانه‌های `autosklearn.classification` و `AutoSklearnClassifier` استفاده شده است.

همچنین، برای این طبقه‌بندی نیز از روش شبکه عصبی مصنوعی استفاده شد تا در نهایت نتایج به‌دست‌آمده از دو روش با هم مقایسه شوند.

افزون بر این، در مدل‌سازی از قابلیت انتخاب ویژگی استفاده شد تا مشخص شود کدام بعد شخصیت روی مدل تأثیر بیشتری دارد. برای این کار، از روش «اهمیت ویژگی»<sup>۴</sup> استفاده شده است. نتیجه این کار در شکل ۳ بیان شده است.

---

1. Train data
2. Test data
3. Overfitting
4. Feature Importance



شکل ۲. اهمیت ویژگی ها بر مدل

همان طور که مشاهده می شود، ویژگی وظیفه شناسی بیشترین تأثیر و ویژگی روان رنجوری کمترین تأثیر را بر نمرات دارد.

### اعتبارسنجی (ارزیابی)

قبل از اقدام به استقرار نهایی مدل، ارزیابی دقیق تر مدل و بررسی مراحل انجام شده برای ساخت مدل مهم است تا مطمئن شویم اهداف تجاری را به درستی تحقق می بخشد. در این مرحله، نتایج حاصل از روش تحلیل را براساس معیارهای مختلف ارزیابی کرده و براساس آن ها تصمیم گیری می کنیم. عملکرد مدل برای روش Auto ML براساس مقیاس های ذکر شده در ادبیات موضوع، در جدول ۱ آورده شده است. همچنین، برای مقایسه با روش شبکه های عصبی، شاخص های ارزیابی برای این روش نیز در جدول ذکر شده است. همان طور که مشاهده می شود، این شاخص ها برای روش Auto ML مقدار بالاتری را نشان می دهد.

جدول ۱. عملکرد مدل

Accuracy	Recall	Precision	AUC	الگوریتم
۰/۸۶۱	۰/۸۱۵	۰/۷۹۷	۰/۸۳۲	Auto ML
۰/۷۹۴	۰/۷۶۳	۰/۷۴۳	۰/۷۵۱	شبکه های عصبی

### استقرار

استقرار مدل در مدرسه مدنظر انجام شد و با توجه به اینکه از تمام داده های موجود در مدرسه در مراحل قبل استفاده شده بود، نتیجه ارزیابی مدل و نتایج حاصل از آن تفاوتی نکرده است. پس از کسب

نتیجه‌گیری‌های انجام‌شده از این پژوهش، نتایج پژوهش به مدرسه مدنظر ابلاغ شده و جزئیات آن به مدیران مدرسه به‌طور کامل توضیح داده شده است. این نتایج در اختیار معلمان و دانش‌آموزان و همچنین خانواده دانش‌آموزان قرار داده شد تا مدرسه و والدین با استفاده از این نتایج به‌طور شخصی‌سازی‌شده، در راستای بهبود عملکرد دانش‌آموزان، اقدامات لازم را انجام دهند.

## بحث و نتیجه‌گیری

نتیجه گزارش‌شده در این مقاله به پیش‌بینی موفقیت تحصیلی دانش‌آموزان کمک می‌کند. به‌طور خاص، برای افزایش دقت پیش‌بینی عملکرد دانش‌آموز با استفاده از ویژگی‌های شخصیتی موجود قبل از شروع برنامه تحصیلی جدید دانش‌آموزان، می‌توان از AutoML استفاده کرد. افزایش حاصل در دقت پیش‌بینی دانش‌آموزان در معرض خطر به مؤسسه‌های دانشگاهی و مدارس اجازه می‌دهد تا در حمایت از آن دانش‌آموزان کارآمدتر باشند و در عین حال از کمترین منابع استفاده کنند. نتایج این پژوهش را می‌توان به‌صورت زیر خلاصه کرد:

- در این پژوهش، با استفاده از AutoML، به دقت ۸۶/۱ درصد دست یافتیم. بر این اساس، پژوهشگران در این زمینه را تشویق می‌کنیم تا AutoML را در جست‌وجوی یک مدل بهینه پیش‌بینی عملکرد دانش‌آموز، هنگام استفاده از داده‌های شخصیت، اتخاذ کنند.
- علاوه بر بهبود دقت پیش‌بینی کلی، بهبود دقت پیش‌بینی دانش‌آموزان شکست‌خورده که به توجه و حمایت فوری واحدهای تخصصی در مؤسسه‌های دانشگاهی نیاز دارند، از اهمیت بالایی برخوردار است. حداکثر میزان دقت گزارش‌شده در ادبیات پیش‌بینی شکست دانش‌آموزان، ۷۰ درصد است.
- طبق یافته‌های این پژوهش، بعد وظیفه‌شناسی، در معدل دانش‌آموزان بیشترین تأثیر و بعد روان‌رنجوری کمترین میزان تأثیر در مدل را داشته است.
- با توجه به نتایج مدل، طبق طبقه‌بندی انجام‌شده از میان ۳۱۰ دانش‌آموزی که برای اعتبارسنجی انتخاب شده‌اند، تعداد ۲۹ دانش‌آموز در معرض افت تحصیلی قرار دارند که شماره دانش‌آموزی آن‌ها به مدرسه مدنظر اعلام می‌شود. دانش‌آموزانی در معرض افت تحصیلی در نظر گرفته شده‌اند که در مقایسه با سال گذشته در حداقل ۵ درس، نمرات آن‌ها بیش از ۳۰ درصد افت نشان می‌دهد.

طبق نتایج انجام‌شده از پیشینه پژوهش مشاهده می‌شود که بین عامل‌های برون‌گرایی و وظیفه‌شناسی با استرس تحصیلی رابطه منفی و معنادار و با عامل روان‌تندخویی رابطه مثبت و معنادار وجود دارد. همچنین، ویژگی‌های مثبت شخصیتی از پیامدهای مخرب استرس محافظت می‌کنند و مانع از اختلال تحصیلی می‌شوند (Miguéis et al, 2018). رابطه ویژگی‌های شخصیتی با عملکرد تحصیلی برون‌گرایی و وظیفه‌شناسی، مثبت و مستقیم و با روان‌رنجوری، منفی و معکوس است (Gašević et al., 2016). در پژوهش حاضر نیز عوامل برون‌گرایی و وظیفه‌شناسی از عوامل مثبت در پیشرفت

عملکرد تحصیلی بیان شده است. دو عامل مسئولیت‌پذیری و روان‌رنجوری، با عملکرد هم‌بستگی منفی دارند (Gray et al., 2014). در پژوهش حاضر، عامل مسئولیت‌پذیری هم‌بستگی مثبتی با نمرات را نشان می‌دهد. طبق گفته زین‌الدین، صفت شخصیت توافق و هیجان‌پذیری در پیش‌بینی عملکرد تحصیلی دانشجویان نقش بیشتری دارند که در پژوهش حاضر، بعد وظیفه‌شناسی در معدل دانش‌آموزان بیشترین تأثیر و بعد روان‌رنجوری کمترین میزان هم‌بستگی را با معدل دانش‌آموزان داشته است. همچنین، پژوهش حاضر در مقایسه با پژوهش‌های مشابه از نظر دقت عملکرد مدل، دقت بالایی از خود به ثبت رسانده است که شاید دلیل آن جلوگیری از بیش‌برازش باشد. البته ممکن است تعداد داده‌ها نیز در این موضوع نقش داشته باشد. برای انجام این پژوهش، از داده‌های دوره‌های متوالی یک مؤسسه آموزشی استفاده شده است و می‌توان گفت که داده‌های استفاده‌شده دوره‌ای<sup>۱</sup> هستند که می‌تواند در افزایش دقت نتیجه پژوهش مؤثر باشد. همچنین، در این پژوهش از به‌روزترین الگوریتم‌های داده‌کاوی استفاده شده است و در نهایت از نظر دقت کارکرد با یکدیگر مقایسه می‌شوند، درحالی که در پژوهش‌های مشابه فقط از یک روش استفاده شده است.

پیشنهاد می‌شود، در مدارس یا مؤسسه‌های آموزشی و حتی دانشگاه‌ها از این مدل و مدل‌های مشابه استفاده شود. همچنین می‌توان با استفاده از یک نرم‌افزار، این پژوهش را توسعه داد و در اختیار مدارس و مؤسسه‌ها قرار داد تا از نتایج آن برای پیشرفت هرچه بهتر دانش‌آموزان استفاده شود. ممکن است پژوهش‌های آتی برای تجزیه و تحلیل نقش متغیرهای روان‌شناختی مختلف و تأثیر آنها بر مدل پیش‌بینی بر آمار توصیفی تکیه کنند. برای پژوهش‌های آتی بهتر است مدل‌های یادگیری ماشین خودکار را در پیش‌بینی موفقیت شغلی دانش‌آموز با استفاده از داده‌های تحصیلی و روان‌شناختی آزمایش کنند.

### فهرست منابع

عربی، پوریا؛ قشقایی، ریحانه و ربانی فرهودی، علی (۱۳۹۴). توسعه اقتصادی آموزش و پرورش با تأکید بر سند تحول بنیادین آموزش و پرورش ایران. *ششمین کنفرانس بین‌المللی اقتصاد، مدیریت و علوم مهندسی*.

Aleksandrowicz, J. W., Klasa, K., Sobański, J. A., & Stolarska, D. (2007). KON-2006-Neurotic Personality Questionnaire. *Psychiatria polska*, 41(6), 759- 778.

Allport, G. W. (1961). *Pattern and growth in personality*. Holt, Reinhart & Winston.

Anglim, J., Horwood, S., Smillie, L. D., Marrero, R. J., & Wood, J. K. (2020). Predicting psychological and subjective well-being from personality: A meta-analysis. *Psychological bulletin*, 146(4), 279.

Backmann, J., Weiss, M., Schippers, M. C., & Hoegl, M. (2019). Personality factors, student resiliency, and the moderating role of achievement values in study progress. *Learning and Individual Differences*, 72, 39-48.



- Bashiri Haddadan, G., Mahmoodi, F., Rezapoor, Y., & Adib, Y. (2016). Describing the experience and perception of teachers and experts from education in multi-grade classes of primary schools in rural areas of Kalibar. *Teaching and Learning Research*, 12(2), 107-120.
- Briley, D.A. & Tucker-Drob, E.M. (2014). Genetic and environmental continuity in personality development: a meta-analysis. *Psychological Bulletin*, 140(5), 1303.
- Clow, D. (2013). An overview of learning analytics. *Teaching in Higher Education*, 18(6), 683-695.
- Costa, L., Demers, L. M., Gouveia-Oliveira, A., Schaller, J., Costa, E. B., De Moura, M. C., & Lipton, A. (2002). Prospective evaluation of the peptide-bound collagen type I cross-links N-telopeptide and C-telopeptide in predicting bone metastases status. *Journal of Clinical Oncology*, 20(3), 850-856.
- Dietz-Uhler, B. & Hurn, J. E. (2013). Using learning analytics to predict (and improve) student success: A faculty perspective. *Journal of interactive online learning*, 12(1), 17-26.
- Elias, T. (2011). Learning analytics. *Learning*, 1-22.
- Eysenck, H. J., & Eysenck, S. B. (2013). *The biological basis of personality. In Personality Structure and Measurement (Psychology Revivals)* (pp. 49-62). Routledge.
- Feurer, M., & Hutter, F. (2019). Hyperparameter optimization. Automated machine learning: Methods, systems, challenges, 3-33.
- Furr, R. M., & Funder, D. C. (2004). Situational similarity and behavioral consistency: Subjective, objective, variable-centered, and person-centered approaches. *Journal of Research in Personality*, 38(5), 421-447.
- Gašević, D., Dawson, S., Rogers, T., & Gasevic, D. (2016). Learning analytics should not promote one size fits all: The effects of instructional conditions in predicting academic success. *The Internet and Higher Education*, 28, 68- 84.
- Harris, J. R. (1995). Where is the child's environment? A group socialization theory of development. *Psychological review*, 102(3), 458.
- Horstmann, K. T., & Ziegler, M. (2020). Assessing personality states: What to consider when constructing personality state measures. *European Journal of Personality*, 34(6), 1037-1059.
- Jalili, S., & Mall-Amiri, B. (2015). The difference between extrovert and introvert EFL teachers' classroom management. *Theory and Practice in Language Studies*, 5(4), 826.
- Jeronimus, B. F., Riese, H., Sanderman, R., & Ormel, J. (2014). Mutual reinforcement between neuroticism and life experiences: a five-wave, 16-year study to test reciprocal causation. *Journal of personality and social psychology*, 107(4), 751.
- Kawamoto, R., Ninomiya, D., Kasai, Y., Kusunoki, T., Ohtsuka, N., Kumagi, T., & Abe, M. (2016). Factors associated with the choice of general medicine as a career among Japanese medical students. *Medical Education Online*, 21(1), 29448.
- Kweik, O. M. A., Hamid, M. A. A., Sheqlih, S. O., Abu-Nasser, B. S., & Abu-Naser, S. S. (2020). Artificial Neural Network for Lung Cancer Detection. *International Journal of Academic Engineering Research (IJAER)*, 4(11).
- Marbouti, F., Diefes-Dux, H. A & Madhavan, K. (2016). Models for early prediction of at-risk students in a course using standards-based grading. *Computers & Education*, 103, 1-15.

- Matthews, G. (2009). 23 Personality and performance: cognitive processes and models. *The Cambridge handbook of personality psychology*, 400.
- Mayilvaganan, M., & Kalpanadevi, D. (2014, December). Comparison of classification techniques for predicting the performance of students academic environment. *In 2014 International Conference on Communication and Network Technologies* (pp. 113-118). IEEE.
- McAdams, D. P., & Pals, J. L. (2006). A new Big Five: fundamental principles for an integrative science of personality. *American psychologist*, 61(3), 204.
- Miguéis, V. L., Freitas, A., Garcia, P. J., & Silva, A. (2018). Early segmentation of students according to their academic performance: A predictive modelling approach. *Decision Support Systems*, 115, 36-51.
- Nix, R., & Zhang, J. (2017). Classification of Android apps and malware using deep neural networks. *2017 International joint conference on neural networks (IJCNN)*.
- Park, N. (2004). The role of subjective well-being in positive youth development. *The annals of the American academy of political and social science*, 591(1), 25-39.
- Ranjeeth, S., Latchoumi, T., & Paul, P. V. (2020). A survey on predictive models of learning analytics. *Procedia Computer Science*, 167, 37-46.
- Revelle, W.R. (2017). *PSYCH: Procedures for personality and psychological research*. Software.
- Romero, C., Espejo, P. G., Zafra, A., Romero, J. R., & Ventura, S. (2013). Web usage mining for predicting final marks of students that use Moodle courses. *Computer Applications in Engineering Education*, 21(1), 135- 146.
- Sadler-Smith, E. (2016). The role of intuition in entrepreneurship and business venturing decisions. *European Journal of Work and Organizational Psychology*, 25(2), 212-225.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- Strecht, P., Cruz, L., Soares, C., & Mendes-Moreira, J. (2015). A Comparative Study of Classification and Regression Algorithms for Modelling Students' Academic Performance. *International Educational Data Mining Society*.
- Thornton, C., Hutter, F., Hoos, H. H., & Leyton-Brown, K. (2013, August). Auto-WEKA: Combined selection and hyperparameter optimization of classification algorithms. *In Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 847-855).
- Vandamme, J. P., Meskens, N., & Superby, J. F. (2007). Predicting academic performance by data mining methods. *Education Economics*, 15(4), 405.
- Wirth, R., & Hipp, J. (2000, April). CRISP-DM: Towards a standard process model for data mining. *In Proceedings of the 4th international conference on the practical applications of knowledge discovery and data mining* (Vol. 1, pp. 29-39).
- Wong, B. T. M. (2017). Learning analytics in higher education: an analysis of case studies. *Asian Association of Open Universities Journal*, 12(1), 21-40.
- Zeineddine, H., Braendle, U., & Farah, A. (2021). Enhancing prediction of student success: Automated machine learning approach. *Computers & Electrical Engineering*, 89, 106903.

# Prospective Analysis of Students' Academic Performance based on Personality Dimensions with Automatic Machine Learning (Auto ML)

**Babak Sohrabi**\*<sup>1</sup>

*Prof., Department of IT, Faculty of Industrial Management and Technology, College of Management, University of Tehran, Tehran, Iran*

**Iman Raeesi Vanani**

*Associate Prof., Department of IT, Faculty of Industrial Management, Allameh Tabataba'i University, Tehran, Iran*

**Ali Norouzi**

*MSc., Department of IT, Faculty of Industrial Management and Technology, College of Management, University of Tehran, Tehran, Iran*

## Abstract

Predicting students' performance is important for their parents and their teachers. In recent years, learning analytics has been used to evaluate educational data and factors affecting academic performance. Numerous factors, including individual, family, social and environmental characteristics affect this issue. One of the most important individual factors is personality, which we will examine the impact of this factor on academic performance. For this purpose, we analyze the data of a school students in District One of Tehran. Researches in this field has focused on the correlation of different dimensions, but the main purpose of this study is predicting student performance in order to identify students at risk of academic failure, which with the knowledge of the family to improve They take action. The methodology used is CRISP-DM. The Auto ML data mining technique was used for analysis. According to the Accuracy criterion, the classification is more accurate than the artificial neural network method. According to the findings of this study, the conscientious dimension had the greatest effect and the neurotic dimension had the least effect on predicting students' performance.

**Keywords:** Learning Analytics, Personality, Academic Performance, Academic failure.

---

1. Corresponding Author: [bsohrabi@ut.ac.ir](mailto:bsohrabi@ut.ac.ir)