

مدل مدیریت منابع انسانی توسط فناوری دیجیتال هوش مصنوعی با تمرکز بر بهینه سازی فرآیندها

سیدامیر محمود فصیح الزمان^۱

تاریخ دریافت: ۱۴۰۳/۰۸/۱۵ تاریخ چاپ: ۱۴۰۳/۱۱/۳۰

چکیده

در عصر دیجیتال، فناوری‌های هوش مصنوعی و کلان داده فرصت‌های جدیدی برای بهبود فرآیندهای مدیریت منابع انسانی ایجاد کرده‌اند. هدف این پژوهش، ارائه یک مدل مبتنی بر فناوری دیجیتال هوش مصنوعی جهت بهینه‌سازی فرآیندهای مدیریت منابع انسانی است. این مدل بر اساس شبکه عصبی پس‌انتشار خطا طراحی شده است و به منظور پیش‌بینی دقیق‌تر حقوق و دستمزد و بهبود مدیریت منابع انسانی به کار می‌رود. روش تحقیق در این پژوهش شامل استفاده از دو دسته روش‌های کیفی و کمی است. از شبکه‌های عصبی مصنوعی برای یادگیری روابط پیچیده میان متغیرها و پیش‌بینی استفاده شده و الگوریتم بهینه‌سازی Nadam برای بهبود کارایی و دقت مدل به کار رفته است. جامعه آماری شامل ۱۱۰ رزومه حسابداران و حسابرسان بوده که داده‌های مرتبط با تجربه کاری، تحصیلات، و موقعیت شغلی به منظور آموزش و آزمون مدل مورد استفاده قرار گرفته است. یافته‌های این پژوهش نشان می‌دهد که مدل پیشنهادی با دقت بالایی در پیش‌بینی حقوق و دستمزد عمل کرده است. نمرات داده‌های آموزشی و آزمون به ترتیب ۰,۷۸ و ۰,۷۷ بوده که نشان‌دهنده عملکرد مناسب مدل است. نتیجه‌گیری نهایی حاکی از آن است که استفاده از مدل‌های هوشمند مبتنی بر یادگیری ماشین، می‌تواند کیفیت تصمیم‌گیری‌ها و فرآیندهای مدیریت منابع انسانی را بهبود بخشد. این رویکرد به مدیران کمک می‌کند تا با دقت بیشتری نیروهای مناسب را جذب و نگهداری کنند.

واژگان کلیدی

هوش مصنوعی، مدیریت منابع انسانی، بهینه‌سازی فرآیندها، شبکه عصبی پس‌انتشار

۱. دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران (شعبه قزوین).

مقدمه

فناوری هوش مصنوعی^۱ به عنوان یکی از تحولات بزرگ دنیای فناوری در دهه های اخیر، تأثیرات شگرفی بر سازمان ها و کسب و کارها داشته است. این فناوری با فراهم سازی ابزاری برای شبیه سازی هوش انسانی و رفتارهای شناختی، به عنوان یک عامل کلیدی برای بقای شرکت ها در محیط های پیچیده و متغیر شناخته می شود (جیاپینگ^۲، ۲۰۲۳). هوش مصنوعی به صورت گسترده ای در مدیریت شرکت ها و تصمیم گیری های مدیریتی کاربرد یافته است، به طوری که مدیران از آن برای انجام وظایف تکراری و خسته کننده روزانه خود بهره می برند. این فناوری همچنین با ارائه ابزارهای پیچیده پایگاه داده و تحلیلی، مدیران را قادر می سازد تا از امور روزمره روتین فاصله گرفته و به وظایف مهم تری متمرکز شوند. از این رو، هوش مصنوعی به یکی از مهم ترین ابزارهای مدیریت و بهره وری در سازمان ها تبدیل شده است (یدیس^۳ و همکاران، ۲۰۲۱). مدیریت منابع انسانی^۴ شامل مجموعه ای از سیاست ها و وظایف سازمانی است که به مدیریت منابع انسانی در یک شرکت اختصاص دارد. این وظایف شامل تدوین استراتژی های منابع انسانی، جذب و انتخاب کارکنان، آموزش و توسعه، مدیریت عملکرد، مدیریت روابط کارکنان، و مدیریت ایمنی و بهداشت کارکنان می شود. با پیشرفت فناوری های هوش مصنوعی، استفاده از این فناوری ها در فرآیندهای مدیریت منابع انسانی به طور چشمگیری افزایش یافته و این تغییرات به شرکت ها امکان می دهد تا با بهبود بهره وری و کاهش هزینه ها، به اهداف استراتژیک خود دست یابند. در واقع، استفاده از هوش مصنوعی در مدیریت منابع انسانی نه تنها فرآیندهای موجود را بهینه سازی می کند، بلکه روند رشد و توسعه منابع انسانی را نیز تسریع می بخشد (ووره^۵ و همکاران، ۲۰۲۱؛ لو^۶ و همکاران، ۲۰۲۱).

یکی از مهم ترین تغییراتی که هوش مصنوعی در حوزه منابع انسانی ایجاد کرده، بهینه سازی فرآیند جذب و استخدام کارکنان است. در دنیای دیجیتال امروزی، داده های زیادی در مورد متقاضیان شغلی در اختیار شرکت ها قرار دارد و این حجم از داده ها به طور روزافزون در حال افزایش است. فناوری های داده کاوی و هوش مصنوعی، ابزارهای پیشرفته ای برای تحلیل این داده ها فراهم می کنند و امکان می دهند که فرآیندهای پیچیده جذب و انتخاب کارکنان به صورت خودکار و کارآمدتری انجام شود. به عنوان مثال، ژانگ^۷ (۲۰۲۱) از تکنیک درخت تصمیم گیری ترکیبی برای ارزیابی داده های مدیریت منابع انسانی استفاده کرد و نشان داد که این روش در مقایسه با روش های توصیه مبتنی بر محتوا و همکاری، با نرخ دقت و بازیابی به ترتیب ۳۵٫۲٪ و ۴۱٫۶٪، بهترین نتایج را ارائه می دهد. وی و جین^۸ (۲۰۲۱) از ترکیب مدل خاکستری بهینه شده و شبکه عصبی انتشار پسرو برای پیش بینی داده های مدیریت منابع انسانی استفاده کردند که نتایج عملی مثبتی به دست آوردند. همچنین، ژو^۹ (۲۰۲۱) نشان داد که یادگیری ماشین می تواند عملکرد و کارایی سیستم های منابع انسانی را بهبود بخشد و تمبه^{۱۰} و همکاران (۲۰۱۹) به کاهش زمان و هزینه های جذب و انتخاب کارکنان

1 Artificial intelligence

2 Jiaping

3 Iodice

4 Human Resource Management

5 Vuorre

6 Luo

7 Zhang

8 Wei and Jin

9 Zhu

10 Tambe

با استفاده از هوش مصنوعی اشاره کردند. به گفته ریکن^۱ (۲۰۱۹)، هوش مصنوعی در فرآیندهای جذب نیروی انسانی و شناسایی نیازهای آموزشی نقش کلیدی دارد و جراحی^۲ (۲۰۱۸) بیان کرد که هوش مصنوعی در حال تغییر رویکردهای مدیریتی و بهبود نتایج سازمانی است. افزایش حجم داده‌های جمع‌آوری شده توسط شرکت‌ها به حدی رسیده است که سیستم‌های سنتی مدیریت منابع انسانی دیگر قادر به مدیریت و تحلیل این داده‌ها نیستند. از این رو، استفاده از فناوری‌های دیجیتال و هوش مصنوعی در این حوزه به یک ضرورت تبدیل شده است. در این راستا، مطالعاتی انجام شده که به طراحی مدل‌های پیش‌بینی حقوق مبتنی بر شبکه‌های عصبی مصنوعی پرداخته‌اند. این مدل‌ها با استفاده از اطلاعات رزومه‌های متقاضیان، می‌توانند حقوق پیشنهادی به آن‌ها را پیش‌بینی کنند و به شرکت‌ها در فرآیند استخدام کمک کنند. این مدل‌ها با دقت بالا و عملکرد بهینه، می‌توانند بهبود قابل توجهی در فرآیندهای مدیریت منابع انسانی مبتنی بر داده‌کاوی ایجاد کنند و کارایی سیستم‌های منابع انسانی را افزایش دهند (گونگ^۳ و همکاران، ۲۰۲۲؛ تمبه و همکاران، ۲۰۱۹). با پیشرفت‌های چشمگیر در زمینه فناوری‌های دیجیتال، به ویژه هوش مصنوعی، مدیریت منابع انسانی در سازمان‌ها نیز به سمت تحول و دیجیتالی شدن حرکت کرده است. با این وجود، چالش‌های بسیاری در این مسیر وجود دارد که سازمان‌ها را وادار می‌کند به دنبال راه‌حل‌های نوآورانه برای بهینه‌سازی فرآیندهای منابع انسانی باشند. یکی از اصلی‌ترین مسائل پیش روی شرکت‌ها این است که چگونه می‌توانند از فناوری‌های هوش مصنوعی برای ارتقای کارایی و اثربخشی فرآیندهای منابع انسانی، از جمله جذب و استخدام، آموزش و توسعه، مدیریت عملکرد و ارتقای رضایت کارکنان بهره ببرند. علی‌رغم مزایای آشکار این فناوری‌ها، بسیاری از شرکت‌ها هنوز نتوانسته‌اند به‌طور کامل از پتانسیل هوش مصنوعی در بهینه‌سازی فرآیندهای خود استفاده کنند. این مسأله پژوهشی به دنبال یافتن راهکارهایی برای ادغام فناوری‌های هوش مصنوعی در مدیریت منابع انسانی است تا با استفاده از مدل‌های نوین مدیریتی، بهره‌وری سازمانی افزایش یابد و از سوی دیگر، هزینه‌ها و زمان صرف شده برای این فرآیندها کاهش یابد. در این راستا، ضرورت انجام این پژوهش از اهمیت روزافزون نقش فناوری‌های دیجیتال و هوش مصنوعی در بهبود فرآیندهای سازمانی و به ویژه مدیریت منابع انسانی ناشی می‌شود. با توجه به رشد سریع داده‌ها و نیاز به مدیریت موثرتر این داده‌ها، استفاده از هوش مصنوعی برای بهینه‌سازی فرآیندهای منابع انسانی به یک ضرورت اجتناب‌ناپذیر تبدیل شده است. این فناوری نه تنها می‌تواند کارایی و سرعت انجام امور منابع انسانی را بهبود بخشد، بلکه قادر است هزینه‌ها را کاهش داده و فرآیندهای پیچیده و زمان‌بر مانند جذب و استخدام کارکنان را به‌صورت خودکار و هوشمندانه انجام دهد. از این رو، پژوهش در این زمینه می‌تواند به سازمان‌ها کمک کند تا با بهره‌گیری از فناوری‌های نوین، به اهداف استراتژیک خود دست یابند و در محیط‌های رقابتی امروز بهتر عمل کنند. همچنین، با توجه به چالش‌های پیش‌روی بسیاری از شرکت‌ها در دیجیتالی کردن مدیریت منابع انسانی، این پژوهش می‌تواند به عنوان یک راهنمای کاربردی برای مدیران در جهت اتخاذ بهترین تصمیمات در این زمینه مورد استفاده قرار گیرد.

1 Rykun

2 Jarrahi

3 Gong

چارچوب نظری پژوهش


مدل‌های مدیریت منابع انسانی ابزارهای مهمی هستند که سازمان‌ها را قادر می‌سازند تا فرآیندهای مختلف مدیریت منابع انسانی را بهینه‌سازی کرده و بهره‌وری و اثربخشی خود را افزایش دهند. این مدل‌ها به مدیران کمک می‌کنند تا در زمینه‌های مختلفی از جمله جذب و استخدام، ارزیابی عملکرد، پرداخت حقوق، آموزش و توسعه، و حفظ منابع انسانی رویکردهای مشخص و ساختاریافته‌ای داشته باشند. مدل‌های مدیریت منابع انسانی بر اساس تجربیات طولانی‌مدت سازمان‌ها و نیازهای روزافزون به بهبود عملکرد منابع انسانی توسعه یافته‌اند (بوهم^۱ و همکاران، ۲۰۲۱). بوتوشا^۲ (۲۰۲۴) بر اهمیت ایجاد محیط کاری مناسب و بهبود فرآیندهای اداری در بانک آلبانی تأکید می‌کند و تطبیق زیرساخت‌های مقرراتی با استانداردهای اتحادیه اروپا را برای حفظ نیروی کار ضروری می‌داند. مددی و همکاران (۱۴۰۳) نشان دادند که یادگیری ماشین و هوش مصنوعی از طریق تأثیر بر فرهنگ و رهبری سازمانی، به بهبود مدیریت منابع انسانی و در نهایت افزایش عملکرد منجر می‌شود. محمدی و محمدی (۱۳۹۸) با ارزیابی مدل حسابداری ارزش منابع انسانی دریافتند که این مدل معیارهای لازم برای گزارشگری مالی را پوشش نمی‌دهد. گیلدیال و پراساد^۳ (۲۰۲۳) نیز بر نقش کلیدی منابع انسانی در موفقیت سازمان‌ها تأکید کرده و مدلی مبتنی بر یادگیری عمیق برای بهبود مدیریت منابع انسانی پیشنهاد کرده‌اند. در پژوهش حاضر، سه مدل اصلی مدیریت منابع انسانی یعنی مدل 3P، مدل 4P و مدل 5P مورد بررسی قرار می‌گیرد. مدل 3P یکی از مدل‌های پایه‌ای و ساده در مدیریت منابع انسانی است که تمرکز آن بر تحلیل شغل، ارزیابی عملکرد، و توزیع حقوق و مزایا است. این مدل با تحلیل شغل به عنوان نقطه شروع، به تقسیم‌بندی مسئولیت‌های شغلی کارکنان می‌پردازد و بر اساس این تقسیم‌بندی، شاخص‌ها و برنامه‌های ارزیابی عملکرد طراحی می‌شوند. در نهایت، نتایج ارزیابی عملکرد به عنوان مبنایی برای تعیین حقوق، مزایا، و پاداش‌ها به کار گرفته می‌شوند. این مدل به طور ویژه برای سازمان‌هایی که به دنبال یک سیستم ساده و کارآمد برای مدیریت منابع انسانی هستند، مناسب است. اما یکی از نقاط ضعف این مدل، عدم توجه کافی به استراتژی‌های توسعه سازمان و نوآوری است. همچنین، مدل 3P بیشتر بر نیازهای شغلی متمرکز است و به کارکنان به عنوان دارایی‌های استراتژیک سازمان توجه کمتری دارد (بوم^۴ و همکاران، ۲۰۱۹).

1 Boehm

2 Botusha

3 Gildhiyal & Prasad

4 Boon




شکل ۱، مدل 3p مدیریت منابع انسانی

مدل 4P مدیریت منابع انسانی به عنوان توسعه‌ای بر مدل 3P معرفی شده است و با افزودن دو عنصر اساسی یعنی "افراد" و "موقعیت‌ها"، ساختار پیچیده‌تری ایجاد می‌کند. هسته اصلی این مدل شامل "یک مرکز، دو نقطه اساسی، و چهار تطبیق عمده" است. مرکز این مدل بر استراتژی سازمان استوار است و دو نقطه اساسی آن شامل افراد و موقعیت‌های شغلی است. این مدل سعی می‌کند تا تطبیق بهتری بین افراد و موقعیت‌ها، بین موقعیت‌ها با یکدیگر، و بین افراد و سازمان برقرار کند. یکی از مهم‌ترین مزایای مدل 4P این است که علاوه بر مدیریت عملکرد و توزیع حقوق و مزایا، به مدیریت کیفیت و توسعه کارکنان نیز توجه دارد. در این مدل، مدیریت کیفیت به عنوان یکی از مؤلفه‌های کلیدی تعریف می‌شود که هدف آن ارزیابی و بهبود مستمر کیفیت عملکرد کارکنان است. همچنین، مدیریت عملکرد در این مدل به صورت یک چرخه بسته تعریف می‌شود که شامل برنامه‌ریزی عملکرد، حمایت از اجرای عملکرد، ارزیابی عملکرد، و توسعه کارکنان است (آرورا و کوماری^۱، ۲۰۲۱؛ نوبل^۲ و همکاران، ۲۰۲۱).


1 Arora and Kumari

2 Noble



شکل ۲، مدل 4P مدیریت منابع انسانی

مدل 5P مدیریت منابع انسانی یکی از پیشرفته‌ترین مدل‌ها در این زمینه است که پنج عنصر اساسی شامل ادراک، انتخاب، قرارداد، حرفه‌ای و حفظ منابع انسانی را در بر می‌گیرد. این مدل به سازمان‌ها کمک می‌کند تا فرآیندهای منابع انسانی خود را به شکلی یکپارچه‌تر و جامع‌تر مدیریت کنند. در مدل 5P، ادراک به معنای تقسیم‌بندی بخش‌های سازمان بر اساس نیازهای کسب و کار و توصیف دقیق مشاغل است. انتخاب به فرآیند جذب و انتخاب کارکنان با استفاده از روش‌های علمی ارزیابی استعدادها اشاره دارد. جایگذاری به معنای تخصیص مناسب افراد به مشاغل و فراهم کردن مسیرهای ارتقا برای کارکنان است. حرفه‌ای‌سازی به آموزش و توسعه کارکنان برای بهبود مهارت‌ها و فراگیری فناوری‌های جدید تأکید دارد. در نهایت، حفظ منابع انسانی به ایجاد یک سیستم انگیزشی برای حقوق و دستمزد و جلوگیری از فرار مغزها اشاره دارد. در مدل 5P، تمرکز بر جنبه‌های مختلف مدیریت منابع انسانی از جمله ارزیابی کیفیت و تحلیل شغلی، جذب و انتخاب، پیکربندی و استفاده از منابع انسانی، آموزش و توسعه، و ارزیابی و پرداخت است. این مدل به سازمان‌ها امکان می‌دهد تا با ایجاد یک سیستم یکپارچه و جامع، بهره‌وری و اثربخشی منابع انسانی خود را بهبود بخشند و با استفاده از ابزارهای مختلف، از جمله ارزیابی عملکرد و توسعه حرفه‌ای، نیروی کار خود را به‌طور مداوم بهبود دهند (دروس^۱ و همکاران، ۲۰۲۱).



شکل ۳، مدل 5P مدیریت منابع انسانی

این مدل‌ها هر یک بر اساس نیازها و استراتژی‌های مختلف سازمان‌ها طراحی شده‌اند و می‌توانند به بهبود عملکرد کلی منابع انسانی در سازمان کمک کنند. انتخاب مدل مناسب برای هر سازمان بستگی به اهداف استراتژیک، ساختار سازمانی، و نیازهای ویژه آن سازمان دارد.

تحلیل مدل پیش‌بینی حقوق


در فرآیند استخدام سنتی، بررسی و انتخاب رزومه‌ها به‌طور معمول به‌صورت دستی انجام می‌شود. در این روش، تصمیم‌گیری در مورد اینکه آیا متقاضی شرایط لازم را داراست یا خیر، بر اساس عواملی مانند سن، تحصیلات و تجربه کاری انجام می‌شود. این روش نیازمند توانایی داوری درست از سوی مدیران استخدام است و ممکن است به دلیل حضور خطاهای انسانی، منجر به انتخاب‌های نادرست شود. خطاهای انسانی یکی از چالش‌های اصلی این روش به شمار می‌آید، زیرا قضاوت فردی ممکن است تحت تأثیر تعصبات ذهنی و فاکتورهای غیرمنطقی قرار گیرد (سانگ^۱ و همکاران، ۲۰۲۱). علاوه بر این، هر موقعیت شغلی معمولاً دارای یک بازه حقوقی مشخص است، اما در نهایت میزان دقیق حقوق غالباً توسط بخش مدیریت قرارداد تعیین می‌شود. این فرآیند ممکن است تحت تأثیر عوامل ذهنی و انسانی قرار گیرد که می‌تواند منجر به عدم سازگاری بین سطح توانمندی متقاضی و حقوق پرداختی شود. در چنین شرایطی، نبود استانداردهای عینی و دقیق برای ارزیابی و تعیین حقوق باعث می‌شود که فرآیند تعیین حقوق به‌شدت به تصمیمات شخصی و نه به ارزیابی‌های علمی و مبتنی بر داده وابسته باشد (ژانگ^۲ و همکاران، ۲۰۲۱). یکی از چالش‌های اصلی در فرآیند مدیریت منابع انسانی، محدودیت در استفاده از داده‌های کمی برای پشتیبانی از تصمیمات مربوط به تعیین حقوق است. به‌طور معمول، تنها تحلیل‌های کیفی انجام می‌شود و داده‌های کافی برای ارزیابی دقیق و کاهش تأثیر عوامل ذهنی

1 Song

2 Zhang

در دسترس نیستند. این موضوع باعث می شود که استانداردهای ارزیابی حقوق به صورت عینی و دقیق تدوین نشوند و سازمانها در تعیین حقوق با مشکلاتی روبهرو شوند. از این رو، نیاز به استفاده از داده های کمی و مدل های پیش بینی حقوق بر اساس اطلاعات موجود در رزومه ها به عنوان یک راهکار مدرن مطرح شده است (هان^۱ و همکاران، ۲۰۲۱). برای رفع این مشکلات و افزودن عوامل ارزیابی عینی به فرآیند تعیین حقوق، مدل های پیش بینی حقوق با استفاده از اطلاعات موجود در رزومه ها توسعه یافته اند. این مدل ها با استفاده از داده های جمع آوری شده از رزومه ها، سعی می کنند حقوق پیشنهادی را پیش بینی کنند. حقوق پیش بینی شده می تواند به عنوان یک استاندارد پایه برای تعیین حقوق در فرآیند استخدام به کار رود و بر اساس وضعیت های حقوقی موجود تنظیم گردد. با این روش، سازمانها قادر خواهند بود تصمیمات بهتری در زمینه حقوق پرداختی بگیرند و عدالت بیشتری را در فرآیند استخدام به اجرا بگذارند (ژانگ و همکاران، ۲۰۲۱).

پیش بینی حقوق یک فرآیند پیچیده و چندعاملی است که به تحلیل داده های موجود در رزومه متقاضیان بستگی دارد. از آنجایی که مدل های پیش بینی حقوق بر اساس اطلاعات رزومه ها عمل می کنند، کیفیت داده های استخراج شده تأثیر زیادی بر دقت و کارایی این مدل ها دارد. بنابراین، ایجاد و استفاده از مدل های دقیق پیش بینی حقوق نیازمند استخراج ویژگی های مهم از رزومه ها و تحلیل داده های دقیق و کامل است (هان و همکاران، ۲۰۲۱). ویژگی های داده های استفاده شده در این فرآیند در شکل ۴ نشان داده شده است:



شکل ۴، ویژگی های داده های مدل پیش بینی حقوق (SPM)


الگوریتم پس انتشار خطا^۲

یکی از الگوریتم های کلیدی در یادگیری ماشین و به ویژه شبکه های عصبی مصنوعی است که به بهبود نتایج در مواجهه با خطاهای آموزش کمک می کند. این الگوریتم با استفاده از داده های ورودی و وزن های تصادفی اولیه، خطاهای خروجی را محاسبه و وزن ها و آستانه های شبکه از طریق فرآیند پس انتشار به طور مداوم تنظیم و تصحیح می شوند تا

¹ Han

^۲ الگوریتم Backpropagation

خطاها کاهش یابد (ژو^۱ و همکاران، ۲۰۲۱). این فرآیند با الگوریتم گرادیان کاهشی انجام می شود و شبکه را به سمت نتایج دقیق تر هدایت می کند. استفاده از این الگوریتم در شبکه های عصبی پیچیده با تعداد زیادی نورون و لایه های مختلف، ضروری است. عملکرد این الگوریتم بر اساس تکرار مراحل جلو^۲ و عقب^۳ است. ابتدا، شبکه با استفاده از ورودی ها، عملیات را انجام داده و خروجی تولید می کند. سپس، اگر خروجی با مقدار واقعی تفاوت داشته باشد، الگوریتم به عقب برمی گردد و وزن ها را برای کاهش خطا تنظیم می کند. این فرآیند تا زمانی که شبکه به دقت مطلوب برسد ادامه می یابد. اهمیت این الگوریتم در حل مسائل پیچیده ای مانند تشخیص تصاویر و دسته بندی اشیا نمایان می شود، به ویژه در شبکه هایی با تعداد زیادی نورون و لایه های مخفی که یافتن وزن های مناسب زمان بر و پیچیده است. ساختار شبکه عصبی پس انتشار خطا در شکل ۵ نشان داده شده است، این شبکه شامل یک لایه ورودی، یک لایه پنهان و یک لایه خروجی است. در میان این لایه ها، لایه پنهان شامل چندین لایه مختلف است. در داخل شبکه عصبی پس انتشار خطا، نورون های هر لایه به طور مستقل عمل می کنند و تنها ارتباطات یک طرفه بین نورون های لایه های مجاور وجود دارد. سیگنال ورودی از طریق لایه ورودی به لایه پنهان منتقل می شود، سپس توسط تابع لایه پنهان پردازش می شود و در نهایت داده ها به لایه خروجی انتقال می یابند. تابع، داده های لایه خروجی را به نتیجه نهایی تبدیل می کند.



شکل ۵، ساختار شبکه عصبی پس انتشار خطا

روش تحقیق

روش های پیش بینی به طور کلی به دو دسته تقسیم می شوند: ۱- روش های کیفی و ۲- روش های کمی. روش های کیفی بر اساس قضاوت و دیدگاه افراد است و معمولاً زمانی به کار می رود که اطلاعات تاریخی محدودی در دسترس باشد. از نمونه های این روش ها می توان به دلفی و سناریوسازی اشاره کرد. در مقابل، روش های کمی از داده ها و اطلاعات گذشته برای پیش بینی تقاضای آینده استفاده می کنند. روش هایی مانند رگرسیون، برآورد روند، سیستم های خبره و شبکه های عصبی در این دسته قرار می گیرند (منتزر و کان^۴، ۱۹۹۵). شبکه های عصبی مصنوعی که از فرآیند یادگیری

¹ Zhu

² Feedforward

³ Backpropagation

⁴ Mentzer & Kahn

مغز انسان الهام گرفته شده‌اند، قادرند تا روابط پیچیده بین متغیرها را یاد بگیرند و از آن‌ها برای پیش‌بینی استفاده کنند. از مزایای اصلی شبکه‌های عصبی نسبت به مدل‌های ساختاری و سری زمانی، این است که نیازی به فرضیات آماری خاص درباره رفتار متغیرها مانند توزیع احتمالات ندارند (مشیری، ۱۳۸۰). بنابراین، در این پژوهش از شبکه عصبی پس‌انتشار خطا استفاده می‌گردد. همچنین جامعه آماری این تحقیق شامل داده‌های مربوط به رزومه‌ها و اطلاعات شغلی حسابداران و حسابرسان طی دوره زمانی ۱۴۰۲-۱۴۰۳ است. نمونه آماری از ۱۱۰ رزومه تشکیل شده که به دو زیرمجموعه تقسیم شده‌اند: ۱۰ رزومه برای تست و ۱۰۰ رزومه برای آموزش مدل. داده‌های مورد استفاده از رزومه‌ها شامل سن، جنسیت، تحصیلات، دانشگاه، رشته تحصیلی، تجربه کاری، موقعیت شغلی قبلی و محل زندگی است.

مدل پیش‌بینی حقوق مبتنی بر شبکه عصبی پس‌انتشار خطا

۱- ساختار توپولوژیک شبکه. پیش‌بینی حقوق و دستمزد نوعی مسئله است که چندین ورودی دریافت کرده و تنها یک خروجی تولید می‌کند. بر اساس داده‌هایی که در مرحله تحلیل نیازها استفاده شده‌اند، شبکه عصبی دارای ۱۴ نورون (واحد پردازش) در لایه ورودی است که این ورودی‌ها به شبکه ارائه می‌شوند. همچنین، شبکه تنها ۱ نورون در لایه خروجی دارد که نتیجه نهایی (مثلاً پیش‌بینی حقوق) از آن به دست می‌آید. هیچ روش محاسباتی قطعی برای تعیین تعداد نورون‌های لایه پنهان وجود ندارد. این مقدار به شکل زیر محاسبه می‌شود:

$$n_h = \sqrt{n_i + n_o} + k, \quad (1)$$

که در آن، n_h نمایانگر تعداد نورون‌های لایه پنهان است، n_i تعداد نورون‌های لایه ورودی، n_o تعداد نورون‌های لایه خروجی، و k یک ثابت بین ۱ تا ۱۰ است. شبکه عصبی پس‌انتشار^۱ (BPNN) برای آموزش مکرر استفاده می‌شود و در نهایت، تعداد نورون‌های لایه پنهان به ۱۵ تنظیم می‌گردد.

۲- تابع فعال‌سازی. به‌طور نظری، تابع فعال‌سازی می‌تواند خطی یا غیرخطی باشد. اما وقتی که مشخص نیست مسئله‌ای که با آن روبرو هستیم خطی است یا خیر، بهتر است از تابع فعال‌سازی غیرخطی استفاده کنیم. در حال حاضر، یکی از رایج‌ترین توابع فعال‌سازی، تابع سیگموئید^۲ است. این تابع به این شکل عمل می‌کند که مقادیر ورودی را پردازش کرده و خروجی را بین ۰ و ۱ فشرده می‌کند. نحوه محاسبه تابع سیگموئید به صورت زیر است:

$$f(x) = \frac{1}{1 + e^{-x}}, \quad (2)$$

که در آن e یک ثابت طبیعی است. خروجی تابع سیگموئید بین (۰ و ۱) فشرده می‌شود و این تابع دارای ویژگی‌های مشتق‌پذیری و غیرخطی بودن اشباع‌شده است، بنابراین می‌تواند توانایی نگاشت غیرخطی شبکه عصبی پس‌انتشار را افزایش دهد.

^۱ BP Neural Network

۲. تابع سیگموئید یک تابع ریاضی است که به‌طور گسترده در شبکه‌های عصبی مصنوعی به‌عنوان تابع فعال‌سازی استفاده می‌شود. این تابع ورودی‌های مختلف را به خروجی‌هایی بین ۰ و ۱ تبدیل می‌کند، که به این معنی است که خروجی تابع همیشه در محدوده‌ای بین این دو عدد قرار دارد.

۳- مقدار اولیه پارامترها. این که آیا نتیجه آموزش مدل می تواند به مقدار حداکثر برسد و همگرا شود، به طور عمده به مقدار اولیه پارامترها بستگی دارد. زمانی که وزن های اولیه اتصالات تنظیم می شوند، مقدار حالت هر نورون به ۰ نزدیک است، که این وضعیت اطمینان می دهد که مدل به راحتی در منطقه "اشباع" گیر نکند. در این حالت، شرایط اولیه مناسب تر است. با این حال، نورون های موجود در یک لایه نباید در زمان اولیه سازی وزن های یکسانی داشته باشند. در غیر این صورت، خروجی ها و گرادیان های یکسانی در طول محاسبه به دست می آیند و در نهایت، به روزرسانی های یکسانی انجام می شود که هیچ تغییری ایجاد نمی کند. زمانی که وزن های اتصال یک عدد تصادفی کوچک باشند، این شرایط به راحتی برآورده می شود (حسین^۱ و همکاران، ۲۰۲۰). بنابراین، هنگام مقداردهی اولیه پارامترها، معمولاً وزن های اتصال به صورت یک عدد تصادفی کوچک انتخاب می شوند تا سرعت همگرایی بهینه به دست آید.

۴- تابع خطا. تابع خطا عمدتاً برای اندازه گیری میزان اختلاف بین مقدار پیش بینی شده توسط شبکه و مقدار واقعی استفاده می شود و معیاری برای ارزیابی همگرایی مدل آموزش دیده به شمار می رود. رایج ترین تابع خطا در پیش بینی های رگرسیونی، تابع خطای میانگین مربعات (Mean-Square-Error) است که با E نشان داده شده و به صورت زیر تعریف می شود:


$$E = \frac{1}{2} (Y - Z)^2 \quad (3)$$

که در آن:

$(y_0, y_1, \dots, y_k) = Y$ بردار هدف (مقادیر واقعی) است.

$(z_0, z_1, \dots, z_k) = Z$ بردار خروجی (مقادیر پیش بینی شده) است.

یک مدل SPM مبتنی بر شبکه عصبی پس انتشار ایجاد شده است و فرآیند آموزش این مدل در شکل ۶ نمایش داده شده است.



بهینه سازی مدل پیش‌بینی حقوق

شبکه عصبی پس‌انتشار دارای ساختار ساده و توانایی یادگیری بالایی است، اما همچنین دارای برخی نقاط ضعف مانند سرعت همگرایی کند است. جستجو بر اساس نزول گرادیان ممکن است به راحتی در کمینه محلی فضای پارامترها گیر یفتد. بنابراین، در استفاده عملی، شبکه عصبی پس‌انتشار نیاز به بهینه‌سازی دارد (کیم^۱ و همکاران، ۲۰۲۱). شبکه عصبی پس‌انتشار از روش نزول گرادیان در به‌روزرسانی پس‌انتشار استفاده می‌کند، اما سرعت تکرار کند است و نتیجه مطلوبی ندارد. به همین دلیل، برای بهینه‌سازی نزول گرادیان، از ترکیب مونتوم اضافی و نرخ یادگیری تطبیقی به روش ترکیبی استفاده می‌شود. از میان روش‌های ترکیبی، تخمین مونتوم تطبیقی (Adam) و ترکیب نسترُف و تخمین مونتوم تطبیقی (Nadam) به عنوان روش‌های ترکیبی رایج استفاده می‌شوند. Adam یک الگوریتم بهینه‌سازی ترکیبی است

¹ Kim

که با افزودن یک عبارت تصحیح بایاس و یک عبارت مومنتوم به مومنتوم اضافی به دست می آید. مقدار به روزرسانی آن به صورت زیر داده شده است:

$$\Delta\theta_t = -\frac{\eta}{\sqrt{v_t + \varepsilon}} m_t \quad (4)$$

که در آن

m_t بخش مومنتوم اضافی،

v_t بخش نرخ یادگیری تطبیقی،

η نشان دهنده نرخ یادگیری، و

یک فاکتور هموارکننده برای جلوگیری از صفر شدن معارج است. بخش مومنتوم اضافی m_t و بخش نرخ یادگیری تطبیقی v_t به ترتیب طبق معادلات (۵) و (۶) محاسبه می شوند.

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (4)$$

$$v_t(i, i) = \beta_2 v_{t-1}(i, i) + (1 - \beta_2) g_t^2(i) \quad (5)$$

که در آن β_1 و β_2 نشان دهنده عوامل کاهش هستند، $g_t^2(i)$ گرادیان به توان دو پارامتر θ در تکرار t ام است. g_t نشان دهنده گرادیان پارامتر است و $v_t(i, i)$ ارزش مورد انتظار گرادیان به توان دو در تکرار t ام را نمایش می دهد. نتیجه محاسبه تمایل دارد به ۰ میل کند، بنابراین، از فرمول انحراف برای اصلاح ضرایب استفاده می شود. انحراف به ترتیب در معادلات (۷) و (۸) نشان داده شده است

$$\widehat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (7)$$

$$\widehat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (8)$$

در اینجا، $\widehat{m}_t$ به جای m_t در معادله (۴) و $\widehat{v}_t$ به جای v_t در معادله ۴ استفاده می شود که می تواند از مشکل تمایل به صفر شدن را برطرف می کند. ضرایب متداول در الگوریتم Adam شامل موارد زیر است:

$$\eta = 0.002, \beta_1 = 0.9, \beta_2 = 0.999, \varepsilon = 10^{-8}$$

الگوریتم Nadam نسخه بهینه سازی شده Adam است. این بهینه سازی با ترکیب گرادیان شتاب یافته نسترف (NAG) و Adam به دست آمده است تا سرعت همگرایی را بهبود بخشد (اتوچ^۱ و همکاران، ۲۰۱۹). میزان به روزرسانی پارامترهای Nadam به این شکل نمایش داده می شود.

$$\Delta\theta_t = -\frac{\eta}{\sqrt{v_t + \varepsilon}} \left(\beta_1 \widehat{m}_t + \frac{(1 - \beta_1) g_t}{1 - \beta_1^t} \right)$$

(۹)

در معادله (۹)، پارامترها همان طور که در الگوریتم Adam توضیح داده شده، استفاده می شوند. Nadam تنها بخش مومنتوم اضافی در Adam را اصلاح کرده است. در عملکرد عملی، Nadam دارای نرخ همگرایی سریع تری نسبت به Adam است. به طور خلاصه، روش بهینه سازی ترکیبی با ترکیب مومنتوم اضافی و روش نرخ یادگیری تطبیقی، این امکان را فراهم می کند که از مزایای هر دو روش به صورت همزمان استفاده شود. بنابراین، این روش ها دارای نرخ همگرایی سریع تر و نوسانات کمتری هستند (بادم^۱ و همکاران، ۲۰۱۸).

پارامترهای تجربی و پیش پردازش داده ها

در پیش بینی حقوق و دستمزد از یک مدل سه لایه شبکه عصبی پس انتشار استفاده شده است. تعداد نوروها در لایه های ورودی، پنهان و خروجی به ترتیب ۱۴، ۱۵ و ۱ است. تابع فعال سازی مورد استفاده، تابع سیگموید است و تابع خطا نیز تابع خطای مربعات میانگین است. برای به روزرسانی پارامترهای شبکه، از روش بهینه سازی ترکیبی Nadam استفاده شده است. داده های آزمایشی SPM، داده های مرتبط با موقعیت ها هستند که از کل داده های موجود در پایگاه داده استخراج شده اند. اطلاعات محتوای رزومه برای پیش بینی حقوق پیشنهادی برای متقاضیان استفاده می شود. روش ارزیابی استفاده شده در این آزمایش، روش حفظ مجموعه است. مجموعه داده با فضای نمونه ۱۱۰ به دو زیرمجموعه تقسیم می شود: یکی با اندازه ۱۰۰ برای مجموعه آموزشی و دیگری با اندازه ۱۰ برای مجموعه آزمون.

از آنجا که مقادیر ویژگی های مجموعه داده آموزشی همگی عددی هستند و اطلاعات استخراج شده از رزومه ها یا داده های به دست آمده از پایگاه داده به صورت متنی است، برخی از اطلاعات به اندازه کافی کامل نیستند. بنابراین، عملیات پیش پردازش انجام می شود تا اطلاعات متنی به داده های عددی تبدیل شوند. برخی از ویژگی های موجود در مجموعه داده خام پیش بینی حقوق غیر عددی هستند. از این رو، عملیات پیش پردازش تبدیل داده های غیر عددی به عددی انجام می شود. دامنه مقادیر برخی از ویژگی ها بسیار بزرگ است، که ممکن است در طول آموزش باعث مشکلات عددی شود. بنابراین، داده ها به صورت زیر نرمال سازی می شوند:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (10)$$


که در آن x_{max} نمایانگر بیشترین مقدار و x_{min} نمایانگر کمترین مقدار در مجموعه داده است. علاوه بر این، در مدل SPM، نتیجه نهایی پیش بینی در محدوده عددی نرمال سازی شده قرار ندارد. بنابراین، لازم است عملیات ضد نرمال سازی انجام شود تا داده های نرمال سازی شده به محدوده اصلی داده ها بازگردانده شوند.

– مقایسه عملکرد روش های مختلف بهینه سازی

در این بخش، عملکرد الگوریتم های مختلف بهینه سازی مورد بررسی و مقایسه قرار گرفته است. این مقایسه شامل اثرات آموزش الگوریتم های بهینه سازی Adam و Nadam در مقابل روش های سنتی مانند نزول گرادیان تصادفی (SGD)، گرادیان شتاب یافته نسترُف (NAG)، گرادیان تطبیقی (Adagrad) و روت مین اسکوار پروپ (RMSProp) می باشد. هدف این مقایسه، سنجش سرعت همگرایی هر الگوریتم و ارزیابی ثبات به روزرسانی آنها در فرآیند آموزش است.


همان طور که در شکل ۷ نشان داده شده است، الگوریتم های ترکیبی Adam و Nadam نسبت به سایر روش های بهینه سازی، از ثبات بیشتری در به روز رسانی ها برخوردارند و سریع تر به همگرایی می رسند.

Comparison of Convergence Speeds: Adam, Nadam, and Other Optimization Methods



شکل ۷، مقایسه سرعت همگرایی روش های بهینه سازی


این نمودار نشان دهنده مقایسه سرعت همگرایی الگوریتم های بهینه سازی Adam، Nadam، و سایر روش های سنتی مانند SGD، NAG، و Adagrad است. همان طور که مشاهده می شود، الگوریتم های ترکیبی Adam و Nadam در مقایسه با روش های دیگر دارای همگرایی سریع تر و پایدارتری هستند. Nadam حتی در مقایسه با Adam دارای نرخ همگرایی بهتری است و سریع تر به حداقل خطا می رسد. روش های سنتی مانند SGD و Adagrad دارای نوسانات بیشتر و همگرایی کندتری هستند که ممکن است به دلیل ویژگی های داده و طبیعت الگوریتم های بهینه سازی باشد. برای مقایسه دقیق تر، اثرات آموزش این الگوریتم ها در شکل ۸ به تصویر کشیده شده است. این نمودار نتایج آموزشی الگوریتم های بهینه سازی مختلف از جمله Adam، Nadam، SGD، NAG، و Adagrad را نشان می دهد. همان طور که مشاهده می شود، الگوریتم های Adam و Nadam در طول دوره های آموزشی بالاترین دقت را به دست آورده اند، در حالی که روش های سنتی تر مانند SGD و Adagrad عملکرد ضعیف تری داشته اند. به خصوص در مقایسه با سایر روش ها با افزایش تعداد تکرارها، به بهترین نتیجه رسیده است. در نمودار نتایج آموزشی، نمره پیش بینی نهایی الگوریتم های مختلف بر اساس دقت آموزش محاسبه شده است. الگوریتم Adam به نمره پیش بینی ۰٫۷۸، در انتهای آموزش (پس از ۲۰۰ دوره) دست یافته است. Nadam بهترین عملکرد را با نمره ۰٫۸۰ به ثبت رسانده است. در مقابل، الگوریتم SGD نمره ۰٫۷۱ و NAG نمره ۰٫۷۵ را به دست آورده اند. همچنین، الگوریتم Adagrad با نمره ۰٫۷۳ عملکرد نسبتاً متوسطی داشته است. در مجموع، Nadam توانسته است بالاترین نمره پیش بینی نهایی را در مقایسه با سایر روش های بهینه سازی کسب کند.



شکل ۸، نتایج آموزشی الگوریتم های مختلف بهینه سازی


- تحلیل عملکرد مدل SPM بهینه شده

در این بخش، عملکرد مدل پیش بینی حقوق که با استفاده از الگوریتم ترکیبی نادام بهینه سازی شده است، با سایر مدل های رگرسیون در یادگیری ماشین مقایسه می شود. هر الگوریتم ده آزمایش را انجام داده و بهترین نمرات آزمون ثبت شده است که در شکل ۹ نمایش داده شده است.



شکل ۹، مقایسه الگوریتم های پیش بینی رگرسیون حقوق

نتایج حاصل از این آزمایش‌ها نشان می‌دهد که الگوریتم Nadam در مقایسه با سایر الگوریتم‌های رگرسیون مانند Linear، Polynomial و Ridge عملکرد بهتری داشته است. نمرات مجموعه آموزشی و آزمون الگوریتم Nadam به ترتیب ۰٫۷۸ و ۰٫۷۷ است که نشان‌دهنده دقت بالای مدل و نزدیکی نتایج در مراحل آموزش و آزمون می‌باشد. در مقابل، الگوریتم Polynomial با نمرات آموزشی ۰٫۸۱ و آزمونی ۰٫۷۳ نشان می‌دهد که در مجموعه آموزشی عملکرد بالاتری دارد، اما در مرحله آزمون دقت کمتری دارد. سایر الگوریتم‌ها مانند Linear و Ridge نیز نمرات مشابهی کسب کرده‌اند، اما دقت کمتری نسبت به Nadam داشته‌اند. این نتایج تأیید می‌کند که Nadam در پیش‌بینی دقیق‌تر و همگرایی سریع‌تر، نسبت به سایر روش‌ها برتری دارد. در شکل ۱۰، اثر تطبیق پیش‌بینی مدل SPM پس از بهینه‌سازی با نادام به تصویر کشیده شده است.



شکل ۱۰، اثر برازش SPM بهینه شده با نادام بر اساس BPNN

این شکل نشان می‌دهد که مدل SPM پس از بهینه‌سازی با الگوریتم Nadam توانسته است در فرآیند پیش‌بینی حقوق و دستمزد به تطبیق مناسبی بین مقادیر واقعی و پیش‌بینی شده دست یابد. در طول آموزش، داده‌های مربوط به حقوق به خوبی نرمال‌سازی شده‌اند تا مدل بتواند به طور مؤثری به پیش‌بینی‌های دقیق برسد. با وجود بروز برخی خطاهای محاسباتی که ممکن است به دلیل عملیات نرمال‌سازی و ضدنرمال‌سازی رخ داده باشد، این خطاها در محدوده قابل کنترل قرار دارند و تأثیر کمی بر نتیجه نهایی مدل داشته‌اند.

در مجموع، این پژوهش تأیید می‌کند که مدل SPM بهینه‌شده با الگوریتم Nadam، عملکرد بسیار خوبی در فرآیند یادگیری و پیش‌بینی دارد. این تطبیق خوب بین مقادیر واقعی و پیش‌بینی شده نشان از دقت بالای مدل و قابلیت آن در کاربردهای عملی مانند پیش‌بینی حقوق و بهبود فرآیندهای مدیریت منابع انسانی دارد.

نتیجه گیری

در عصر حاضر که به سرعت به سوی دیجیتالی شدن و استفاده از فناوری‌های نوین پیش می‌رود، مفاهیمی چون کلان‌داده و هوش مصنوعی نقشی حیاتی در بهبود فرآیندهای سازمانی دارند. یکی از حوزه‌هایی که به شدت تحت تأثیر این فناوری‌ها قرار گرفته، مدیریت منابع انسانی است. فناوری‌های مدرن، فرصت‌های جدیدی برای جذب و مدیریت استعدادها فراهم کرده‌اند.

با این حال، سیستم‌های سنتی مدیریت منابع انسانی به دلیل محدودیت‌های خود دیگر نمی‌توانند به درستی روابط پیچیده داده‌ها را تحلیل کرده یا پیش‌بینی دقیقی از روندهای آتی ارائه دهند. این خلأ نیاز به رویکردهای نوین در مدیریت منابع انسانی را بیش از پیش مطرح کرده است. در این پژوهش، برای بهبود این وضعیت، مدلی تحت عنوان مدل پیش‌بینی حقوق (مدل پیشنهادی) طراحی شد که مبتنی بر شبکه عصبی پسانتشار است. این مدل به گونه‌ای طراحی شده است که با استفاده از روش‌های پیشرفته یادگیری ماشین و بهینه‌سازی، توانایی پیش‌بینی دقیق‌تری از عملکرد منابع انسانی و مدیریت حقوق داشته باشد. در این پژوهش از الگوریتم بهینه‌سازی ترکیبی به منظور بهبود کارایی و دقت مدل استفاده شد. این الگوریتم به گونه‌ای عمل می‌کند که مدل بهینه‌تر آموزش ببیند و در نتیجه دقت بالاتری در پیش‌بینی‌ها ارائه دهد.

نتایج شبیه‌سازی‌های آزمایشی نشان می‌دهد که مدل پیشنهادی با استفاده از الگوریتم Nadam عملکرد بسیار خوبی داشته است. نمرات به دست آمده از مدل در داده‌های آموزشی ۰,۷۸ و در داده‌های آزمون ۰,۷۷ بوده است، که این نزدیکی نشان‌دهنده دقت بالای مدل در هر دو مرحله یادگیری و آزمون است. این امر بیانگر آن است که مدل پس از بهینه‌سازی، توانسته است به خوبی در فرآیند پیش‌بینی حقوق و دستمزد عمل کند. به طور کلی، این نتایج حاکی از آن است که مدل پیشنهادی در مقایسه با روش‌های سنتی عملکرد بهتری در زمینه پیش‌بینی داشته و توانسته است نتایج دقیقی ارائه دهد. با این حال، این پژوهش با برخی محدودیت‌ها مواجه است. مدل ارائه شده در مرحله فعلی نسبتاً ساده طراحی شده و بهینه‌سازی کامل بر روی ویژگی‌های داده‌ها انجام نشده است. برای افزایش دقت و کارایی مدل در پژوهش‌های آینده، نیاز به گسترش و توسعه داده‌های ورودی و بهبود ساختار مدل وجود دارد. انتظار می‌رود که با انجام این تغییرات، دقت و کارایی مدل به شکل قابل توجهی افزایش یابد.

در نهایت، نتایج این تحقیق نشان داد که استفاده از مدل‌های هوشمند مبتنی بر یادگیری ماشین و روش‌های بهینه‌سازی در حوزه مدیریت منابع انسانی می‌تواند به طور چشمگیری کیفیت تصمیم‌گیری‌ها و کارایی فرآیندهای مدیریت استعدادها را افزایش دهد. این روش‌ها می‌توانند به مدیران منابع انسانی کمک کنند تا به سرعت به تغییرات محیطی پاسخ داده و استراتژی‌های بهتری برای جذب و نگهداشت نیروهای توانمند اتخاذ کنند.

منابع و مأخذ

محمدی، فروزان. محمدی، نبی الله (۱۳۹۸). ارزیابی جایگاه مدل حسابداری و گزارشگری ارزش منابع انسانی در چارچوب مفاهیم نظری در گزارشگری مالی. چشم انداز حسابداری و مدیریت. ۲ (۱۷). صص ۱۰۵-۱۲۹. #
مددی، یلدا. روحانی، سعید. قلی پور، آرین (۱۴۰۳). طراحی و اعتبارسنجی مدل سیستمی مدیریت منابع انسانی مبتنی بر یادگیری ماشین در بخش بهداشت و درمان، اولین کنفرانس بین المللی مدیریت، مهندسی صنایع، حسابداری و اقتصاد در علوم انسانی. #

مشیری، سعید (۱۳۸۰). پیش بینی تورم با استفاده از مدل های ساختاری، سری های زمانی و شبکه های عصبی. فصلنامه تحقیقات اقتصادی. ۵۸. ۱۸۴-۱۴۷. #

Attouch, H., Chbani, Z., & Riahi, H. (2019). Rate of convergence of the Nesterov accelerated gradient method in the subcritical case $\alpha \leq 3$. ESAIM: Control, Optimisation and Calculus of Variations, 25, 2. #

Badem, H., Basturk, A., Caliskan, A., & Yuksel, M. E. (2018). A new hybrid optimization method combining artificial bee colony and limited-memory BFGS algorithms for efficient numerical optimization. Applied Soft Computing, 70, 826–844. #

Boehm, S. A., Schroder, H., & Bal, M. (2021). Age-related human resource management policies and practices: antecedents, outcomes, and conceptualizations. Work, Aging and Retirement, 7(4), 257–272. #

Boon, C., Den Hartog, D. N., & Lepak, D. P. (2019). A systematic review of human resource management systems and their measurement. Journal of Management, 45(6), 2498–2537. #

Botusha, B. (2024). Human resource management strategy. Interdisciplinary Journal of Research and Development, 11(2), 83. #

Derous, E., Nguyen, H. H. D., & Ryan, A. M. (2021). Reducing ethnic discrimination in resume-screening: a test of two training interventions. European Journal of Work & Organizational Psychology, 30(2), 225–239. #

F. Iodice, M. Romoli, B. Giometto et al. (2021). Stroke and digital technology: a wake-up call from COVID-19 pandemic. Neurological Sciences, 42(3), 805–809. #

Gildhiyal, S., & Prasad, R. (2023). The task-based human resource control and management model using AI-based deep learning model. 2023 IEEE International Conference on Integrated Circuits and Communication Systems (ICICACS). #

Gong, Y., Zhao, M., Wang, Q., & Lv, Z. (2022). Design and interactive performance of human resource management system based on artificial intelligence. PLoS One, 17(1), e0262398. #

Han, J. X., Ma, M. Y., & Wang, K. (2021). Product modeling design based on genetic algorithm and BP neural network. Neural Computing & Applications, 33(9), 4111–4117. #

Hussain, T., Iqbal, N., Maqbool, H. F., Khan, M., Awad, M. I., & Dehghani-Sanij, A. A. (2020). Intent based recognition of walking and ramp activities for amputee using sEMG based lower limb prostheses. Biocybernetics and Biomedical Engineering, 40(3), 1110–1123. #

Jarrahi, M. H. (2018). Artificial intelligence and the future of work: human-AI symbiosis in organizational decision making. Business Horizons, 61(4), 577–586. #

Jiaping, Y. (2023). Enterprise human resource management model by artificial intelligence digital technology. Computational Intelligence and Neuroscience, 2023, Article ID 6186811. 9. #

Kim, K. S., & Choi, Y. S. (2021). Hyadamc: a new adam-based hybrid optimization algorithm for convolution neural networks. Sensors, 21(12), 4054. #

Luo, B. N., Sun, T., Lin, C. H. V., Luo, D., Qin, G., & Pan, J. (2021). The human resource architecture model: a twenty-year review and future research directions. International Journal of Human Resource Management, 32(2), 241–278. #

Mentzer, J. T., & Kahn, K. B. (1995). Forecasting technique familiarity, satisfaction, usage, and application. Journal of Forecasting, 14(5), 465–476. #

Noble, S. M., Foster, L. L., & Craig, S. B. (2021). The procedural and interpersonal justice of automated application and resume screening. International Journal of Selection and Assessment, 29(2), 139–153. #

Rykun, E. (2019). Artificial intelligence in HR management – what can we expect? The Boss Magazine. <https://thebossmagazine.com/ai-hrmanagement>. #

- Song, S., Xiong, X., Wu, X., & Xue, Z. (2021). Modeling the SOFC by BP neural network algorithm. *International Journal of Hydrogen Energy*, 46(38), 20065–20077.#
- Tambe, P., Cappelli, P., & Yakubovich, V. (2019). Artificial intelligence in human resources management: challenges and a path forward. *California Management Review*, 61(4), 15–42.#
- Vuorre, M., Orben, A., & Przybylski, A. K. (2021). There is no evidence that associations between adolescents' digital technology engagement and mental health problems have increased. *Clinical Psychological Science*, 9(5), 823–835.#
- Wei, G., & Jin, Y. (2021). Human resource management model based on three-layer BP neural network and machine learning. *Journal of Intelligent and Fuzzy Systems*, 40(2), 2289–2300.#
- Zhang, A. (2021). Influence of data mining technology in information analysis of human resource management on macroscopic economic management. *PLoS One*, 16(5), e0251483.#
- Zhang, Y. G., Tang, J., & Liao, R. P. et al. (2021). Application of an enhanced BP neural network model with water cycle algorithm on landslide prediction. *Stochastic Environmental Research and Risk Assessment*, 35(6), 1273–1291.#
- Zhu, H. (2021). Research on human resource recommendation algorithm based on machine learning. *Scientific Programming*, 2021, 2021–2110.#
- Zhu, W., Wang, H., & Zhang, X. (2021). Synergy evaluation model of container multimodal transport based on BP neural network. *Neural Computing & Applications*, 33(9), 4087–4095.#