

توسعه یک سامانه پیشنهاد دهنده دوره های آموزشی فنی و حرفه ای
به متقاضیان مهارت آموزی، کارجویان و مهارت آموختگان

محرم منصوری زاده^۱

چکیده

سامانه های پیشنهاد دهنده سعی می کنند در انتخاب گزینه ها و محصولات به کاربران و مشتریان کمک کنند. این مقاله گزارش بخشی از نتایج یک طرح پژوهشی است که در آن یک سیستم پیشنهاددهنده ای توسعه داده شده است که می تواند با دریافت مشخصات هنرجو، دوره های مناسب را به او پیشنهاد دهد. مفاهیم بنیادی مورد نیاز، روشهای قابل استفاده و همچنین معیارهای ارزیابی معرفی شده و در ادامه کارایی روش پیشنهادی به کمک آزمون و ارزیابی بررسی شده است. نتایج بدست آمده نشان می دهد که سیستم پیشنهاد دهنده دوره با دقت مناسبی می تواند مهارجویان را به دوره های آموزشی مناسب هدایت نماید.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی

واژگان کلیدی: دوره آموزشی، پیشنهاد دوره، سامانه پیشنهاددهنده، یادگیری ماشین

^۱ دانشیار مهندسی کامپیوتر، دانشگاه بوعلی سینا، mansoorm@basu.ac.ir

مقدمه

سامانه های توصیه گر سامانه‌های نرم‌افزاری هستند که از الگوریتم‌های ویژه بخصوص در حوزه هوش مصنوعی برای نزدیک کردن مشتریان و کاربران به محصولات و علائق آنها بهره می‌گیرند (Aggarwal, 2016). سیستم‌های توصیه گر یکی از ده‌ها گونه فناوری اطلاعات هستند که به منظور جمع‌آوری، پردازش، بهره‌برداری، مدیریت و نگهداری داده‌ها و اطلاعات استفاده می‌شوند. به صورت خاص فناوری‌های مرتبط با سیستم‌های توصیه گر بر وجه «بهره‌برداری» از داده‌ها و اطلاعات تمرکز دارند. به عنوان مثال، یک کتاب‌فروشی آنلاین برای اینکه بتواند همانند کتاب‌فروشی سنتی به مشتریان دائمی خود خدماتی را ارائه نماید، اطلاعات خرید همه مشتریان خود را ثبت و نگهداری می‌کند. سپس از روی این اطلاعات مشتریان پرمراجعه را شناسایی نموده و علائق موضوعی آنها را بر اساس کتاب‌های خریداری شده شناسایی می‌کند. نهایتاً بر اساس این علاقه‌مندی موضوعی، ماهانه کاتالوگی حاوی کتاب‌های جدید با موضوعات مشابه را به ایمیل مشتری می‌فرستد. این مثال نمونه‌ای کوچک و درعین حال کاملاً واقعی و کاربردی از سیستم‌های توصیه گر است.

آنچه توسعه و به‌کارگیری سامانه‌های توصیه گر را چالش‌برانگیز می‌سازد، تنوع مشتریان در گستره دنیای آنلاین، تغییر عادت مشتریان به مرور زمان، خریدهای مقطعی و متناسب با زمان است. الگوریتم تشخیص علائق مشتری باید به اندازه کافی دقیق و هوشمند باشد که بتواند برای همه نوع مشتری اعم از سن، جنسیت، میزان تحصیلات، محل زندگی و سایر ابعاد شخصی و هویتی پیشنهادهایی منطقی و با احتمال پذیرش بالا بدهد. اینجاست که فناوری‌های مختلف هوش مصنوعی در زمینه یادگیری ماشین و سیستم‌های قانونمند و خبره به عنوان ابزار اصلی و اولیه طراحی و توسعه سیستم‌های پیشنهاددهنده مطرح می‌شوند (Fayyaz, 2020).

یکی از مهم‌ترین کاربردهای سیستم‌های توصیه گر، پیشنهاد دوره‌های آموزشی به کارآموزان و هنرجویان است (Akhtar, 2020). این عمل به دو روش انجام می‌گیرد. در روش اول بر اساس شباهت‌های محتوایی درس‌ها و دوره‌ها با همدیگر، به مشتری که دوره مشخصی را گذرانده دوره‌های مشابه هم پیشنهاد می‌شود. مثلاً به هنرآموزی که ریخته‌گری مقدماتی را گذرانده، دوره پیشرفته ریخته‌گری نیز پیشنهاد و توصیه می‌شود. این روش صرفاً شباهت محتوایی دوره‌ها را در

نظر می گیرد و لزوما اهمیت، کاربردی بودن و تناسب دوره جدید با خواسته های کاربر مانند اشتغال سریع را در نظر نمی گیرد (Deepak, 2018 & Gulzar, Leema).

روش دوم بر اساس عملکرد کاربران و البته شباهت محتوایی دوره ها تصمیم می گیرد. مثلا به هنرآموزی که ریخته گری مقدماتی را گذرانده، تنها در صورتی دوره پیشرفته همان حرفه پیشنهاد می دهد که عده قابل توجهی از هنرآموزان با شرایط مشابه وی قبلا دوره پیشرفته را هم گذرانده باشند. به بیانی دیگر این روش در کنار استفاده از تناسب و تشابه محتوایی دوره ها، شباهت های هنرآموزان مثل سن، جنسیت، محل زندگی و عملکرد آموزشی گذشته آنها را هم در ارائه پیشنهاد خود استفاده می نماید. در این روش می توان با محدود و سفارشی کردن بازه های بررسی عملکرد کاربران و همچنین محل زندگی آنها، به نتیجه روزآمد و پویا رسید (Bakhshinategh, Spanakis, ElAtia, 2017 & Zaiane).

یکی از مهم ترین انگیزش های استفاده از سیستم توصیه گر بر اساس شباهت های هنرجویان و دوره ها این است که اطلاعات آموزشی همه هنرجویان به صورت متمرکز ثبت و مدیریت می گردد. علاوه بر این، بر اساس اطلاعات هویتی آنها می توان اشتغال آنها را هم رهگیری نموده و پایگاهی غنی از وضعیت نیروی کار کشور تهیه نمود. این پایگاه دارایی بسیار ارزشمندی است که می تواند منشا بسیاری از تحلیل های محتوایی با رویکردهای داده محور بوده و زیربنای تصمیم گیری های خرد و کلان باشد.

در این مقاله سامانه پیشنهاد دهنده دوره آموزشی به هنرجویان معرفی شده و مراحل توسعه آن توضیح داده می شود. ارزیابی های کمی و کیفی نشان می دهد که سامانه توسعه داده شده می تواند برای پیشنهاد دوره به هنرجویان و مهارت آموزان مفید باشد.

ساختار ادامه مقاله به این صورت است که در ادامه روشهای مختلف قابل استفاده برای طراحی چنین سامانه ای معرفی شده و سپس نتایج ارزیابی آنها ارائه می گردد. پس از آن یکی از روشهای انتخاب شده و به عنوان گزینه اصلی برای سیستم پیشنهاد دهنده توسعه می یابد. نهایتا در بخش آخر این گزینه مورد بررسی و ارزیابی قرار می گیرد.

توسعه سامانه پیشنهاددهنده

سامانه توصیه گر را از مناظر مختلف مانند مسئله یادگیری بانظارت^۱ و زیرمجموعه های آن یعنی طبقه بندی^۲ و رگرسیون^۳ یا تخمین تابع^۴ می توان دید (Ricci, 2015). در این چارچوب، از علاقه مند هنرجوی فنی و حرفه ای و همچنین دور های آموزشی ویژگی هایی استخراج شده و سپس مدلی یادگیری می شود که بتواند با تعمیم آموخته های خود به داده های جدید، دوره های مناسب را به این هنرجویان پیشنهاد دهد (Deepak, 2018 & Gulzar, Leema, Foreman,) (2013).

دیدگاه دیگر می تواند بر اساس یادگیری بدون نظارت^۵ و زیرمجموعه های آن مانند خوشه بندی^۶ شکل بگیرد (Tong, 2022 & Han, Pei). در این دیدگاه کاربران و دوره های آموزشی به صورت بردارهای مرکب تعریف و سپس خوشه بندی می شوند. دوره های آموزشی کاربر جدید بر اساس نزدیکی و شباهت به این خوشه ها استخراج و پیشنهاد می گردد (Upendran, Chatterjee, Sindhumol, Bijlani, 2016 & Flach,) (2012).

شایان ذکر است که رویکرد ترکیبی نیمه نظارتی^۷ هم یکی از گزینه های پیش روست که در آن هم از داده های دارای برچسب و هم از داده های بدون برچسب استفاده می شود (Frank, 2002 & Witten). پالایش یا فیلتر مشارکتی^۸ نماینده اصلی این دیدگاه است (Madani, Erritali, Bengourram, & Sailhan, 2019). با توجه به اینکه هنرجویان با مشخصات همه دوره های فنی و حرفه ای آشنا هستند و و انتخابشان آگاهانه است، در مسئله حاضر این رویکرد بسیار نزدیک به یادگیری بانظارت بوده و از ادبیات پالایش مشارکتی دور می شود.

^۱Supervised Learning

^۲ Classification

^۳ Regression

^۴ Function Estimation

^۵Unsupervised Learning

^۶Clustering

^۷Semi-supervised learning

^۸Collaborative Filtering

یادگیری بانظارت

در این پژوهش از میان روش‌های مختلف، مدل‌هایی را که می‌توانند خروجی احتمالی تولید کنند استفاده کردیم (Guliyev, 2016 & Salahli, Gasimzade, Alasgarova). دلیل تاکید بر این خصلت، نیاز به رتبه‌بندی نتایج و ارائه آنها بر اساس میزان انطباق با شرایط هنرجو است (Deepak, 2018 & Gulzar, Leema). بر این اساس، طبقه بندهای آماری مانند بیز ساده^۱ و رگرسیون لاجیستیک^۲ که خروجی احتمالی تولید می‌کنند قابل استفاده بوده و مدل‌های دیگر مثل درخت تصمیم و ماشین بردارهای پشتیبان که صرفاً برچسب نامی^۳ خروجی تولید می‌کنند قابل استفاده نیستند (Flach, 2012) (Flach, 2012).

در ادامه فرض می‌شود متغیرهای $X = \langle x_1, x_2, \dots, x_n \rangle$ نشان‌دهنده ویژگی‌ها بوده و $y = p(C|X)$ نشان‌دهنده احتمال تعلق نمونه توصیف‌شده با بردار X به کلاس C است. مثلاً X ویژگی‌های یک هنرجو بوده و C یک دوره آموزشی است.

بیز ساده

این مدل همانطور که از نامش پیداست فرض ساده‌کننده‌ای در نظر می‌گیرد که بر اساس آن بین متغیرها یا همان ویژگی‌ها استقلال شرطی برقرار است. یعنی با مشخص بودن برچسب کلاس مد نظر، خروجی y را می‌توان به صورت زیر نوشت:

$$P(C|X) = P(C|x_1) \times P(C|x_2) \times \dots \times P(C|x_n) = \prod_{k=1}^n P(C|x_k) \quad (۱)$$

مزیت این رابطه این است که تاثیر هر ویژگی بر خروجی مورد نظر را به صورت مستقل و تنها در قالب یک مدل توزیع احتمال یک متغیره در نظر می‌گیرد. این توزیع ممکن است توابع شناخته شده‌ای مانند توزیع نرمال بوده و یا به صورت ناپارامتری به وسیله جدول‌های فراوانی نسبی تعریف شده باشد. علاوه بر این به کمک تابع لگاریتم می‌تواند حاصلضرب فوق را در قالب حاصل جمع هم انجام داده و از ناپایداری‌های محاسبات عددی پیشگیری نمود.

^۱Naïve Bayes^۲Logistic Regression^۳Nominal Labels

رگرسیون لجستیک


مدل رگرسیون لجستیک برای محاسبه احتمال تعلق یک نمونه به کلاس مدنظر از تابع لجستیک استفاده می‌کند.

$$P(C|X) = \frac{1}{1+e^{-h(X)}}, h(X) = a_0 + \sum_{k=1}^n a_k \cdot x_k \quad \text{رابطه (۲)}$$

در رابطه فوق a_0 ها ضرایب وزنی مدل رگرسیونی بوده و طی فرایند یادگیری محاسبه می‌شوند. رگرسیون لجستیک علی‌رغم شکل ساده ای که دارد، مدلی قوی است که به صورت مستقل برای طبقه بندی استفاده می‌شود و هم به عنوان مولفه ای در سایر مدلها مانند شبکه عصبی بکارگرفته می‌شود.

شبکه های عصبی

شبکه عصبی مفهوم استخراج ویژگی را به سطوح ولایه های نورونی تعمیم داده و تلاش می‌کند نمایشی از مسئله به دست بیاورد که در آن ورودی و خروجی از طریق ویژگی های محاسبه شده، به هم مرتبط شوند. قدرت یادگیری و تخمین شبکه عصبی به تعداد لایه ها، نورونها و توابع انتقال آنها بستگی دارد. در لایه های میانی معمولاً از توابع لجستیک و در لایه پایانی هم معمولاً از تابع خطی استفاده می‌شود.



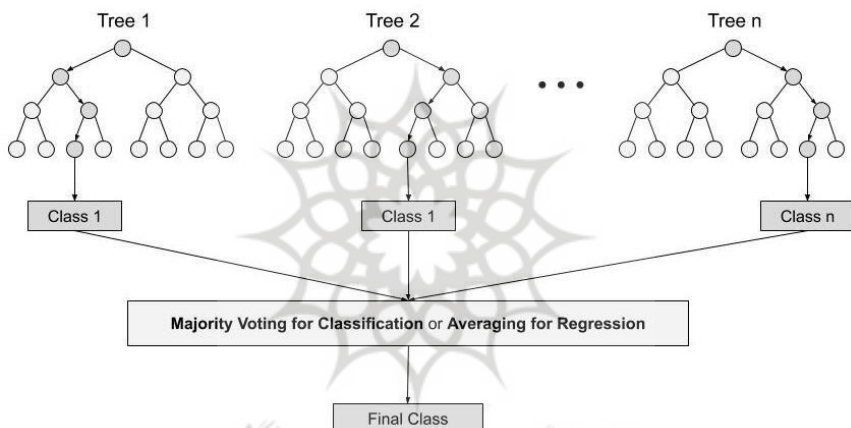
شکل ۱ ساختار یک شبکه عصبی چندلایه

شبکه های لایه ای پیش رو مشهورترین نوع شبکه های عصبی هستند. همانطوری که در شکل بالا نشان داده شده است، در این نوع شبکه هر نورون حاصل جمع وزن دار ورودی ها را

محاسبه نموده و با استفاده از تابع انتقال f خروجی خود را تولید می نماید. نورون های هر لایه به صورت موازی فعال می شوند و لایه ها به صورت ترتیبی اجرا می شوند.

جنگل تصادفی

جنگل تصادفی یکی از قوی ترین مدل های یادگیر گروهی است که در آن تعداد زیادی درخت تصمیم برای تعیین برچسب کلاس یادگیری می شود. سپس در زمان لازم برچسب نمونه بر اساس رای اکثریت این درخت ها تعیین می شود. علاوه بر این حسب نیاز می توان از نسبت رای هر کلاس برای برآورد تقریبی احتمال تعلق نمونه داده شده به آن کلاس استفاده نمود. شکل زیر روش کلی کار این مدل را نشان می دهد.



شکل ۲. جنگل تصادفی برای طبقه بندی

روش های بوستینگ

روش های تقویت یا بوستینگ هم طیفی از طبقه بندهای گروهی هستند که در آنها از مدل های یادگیری ساده، موسوم به یادگیرهای ضعیف، استفاده می شود. همانند جنگل تصادفی در این مدل ها هم رای اکثریت کمابیش تعیین کننده خروجی نهایی است. در برخی موارد این رای گیری ساده و در برخی موارد دیگر وزنی است.

^۱Random Forest

^۲Decision Tree

^۳ Source: <https://www.ml-science.com/random-forest>

^۴ Boosting

ارزیابی کارایی عملکرد

یکی از مهم‌ترین چالش‌های توسعه سیستم‌های توصیه‌گر، ارزیابی کیفیت و کارایی آنهاست. سیستم‌های توصیه‌گر در حوزه‌های مختلفی از تجارت الکترونیک گرفته تا رسانه‌های اجتماعی برای ارائه توصیه‌های شخصی سازی شده و ویژه به مشتریان استفاده می‌شوند. اغلب پژوهش‌ها درباره مزایای توصیه‌ها مانند کاهش بار اطلاعاتی و ایجاد جذابیت برای مشتریان بحث نموده‌اند (Lehner, 2011 & Schröder, Thiele). نتایج و دیدگاه‌های مدیریتی و فنی قابل توجهی هم در این زمینه ارائه شده است. تا آنجا اکنون اغلب سایت‌هایی که به نحوی محصول و حتی مطالب متنوع در اختیار بازدید کننده می‌گذارند، امکاناتی برای ردگیری تک تک بازدید کنندگان و ایجاد پروفایل برای آنها و ارائه پیشنهاد بر اساس این پروفایل‌ها می‌پردازند. در این میان هنوز به روشنی مشخص نیست که چگونه و تا چه حد سیستم‌های توصیه‌گر ارزش افزوده ملموس و قابل اندازه‌گیری (مانند ارزش تجاری) می‌کنند (Ricci, 2015). ایجاد یک سیستم پیشنهاددهنده محصول که قابل اعتماد هم باشد، چالش برانگیز است. در این میان تعریف معنای قابل اعتماد بودن نیز خود چالش دیگری است. با این حال شکی نیست که اندازه‌گیری موفقیت هر سیستم توصیه‌گر از نقطه نظر تجاری بسیار ضروری است. در این بخش به بررسی مهم‌ترین و پرکاربردترین پارامترهای ارزیابی برای سنجش میزان موفقیت یک سیستم پیشنهاددهنده می‌پردازیم. ابتدا سعی می‌کنیم چالش‌هایی که سیستم‌های توصیه‌گر با آن مواجه هستند، درک کنیم سپس معیارهای خاصی را بر سنجش و ارزیابی معرفی می‌کنیم و در انتهای بخش اقدامات خاص هر حوزه کاربردی را ذکر می‌کنیم.

چالش‌های ارزیابی

هر مدل پیش‌بینی یا سیستم توصیه‌ای بدون استثنا به شدت به داده‌ها متکی است. این سیستم‌ها و مدل‌ها توصیه‌های قابل اعتمادی را بر اساس داده‌های واقعی که دریافت کرده و بر اساس آن آموزش دیده‌اند، ارائه می‌کنند. طبیعی است که بهترین سیستم‌های توصیه‌کننده محصول شرکت‌ها و سازمان‌هایی مانند گوگل، آمازون، نتفلیکس یا اسپاتیفای هستند که به حجم زیادی از داده‌ها دسترسی دارند (Dean, Ricci, 2015) (Rajaram, 2007 & Das, Datar, Garg, 2014). برای شناسایی شباهت‌ها و پیشنهاد دادن محصول، کالا یا شی مناسب، سیستم‌های

توصیه گر خوب، داده های این موارد و داده های رفتاری مشتری را ارزیابی می کنند. یادگیری ماشینی هسته اصلی و مهم ترین فعالیت در توسعه سیستم پیشنهاددهنده است. عملکرد یادگیری ماشینی متناسب با حجم داده های مورداستفاده بهبود می یابد. هر چه سیستم دادگان و اطلاعات بیشتری داشته باشد، نتایج بهتری حاصل خواهد شد. لذا حجم مطلوب دادگان به عنوان چالش اصلی مطرح است و جمع آوری دادگان متناسب با بودجه و بازه زمانی قابل استفاده، از اهمیت بسزایی برخوردار است (Rajaram, 2007 & ,Das, Datar, Garg).

چالش دوم در زمینه نقش داده ها در توسعه و ارزیابی سیستم های توصیه گر، این است که داده ها به طور مداوم در حال تغییر هستند. زیرا علاقه مندی و ترجیحات کاربران مدام تغییر می کند. کسب و کارها و محصولاتشان همواره در حال تکامل و به روزرسانی هستند. سیستمی که بر اساس داده های یک برهه طراحی شده، برای کاربری در برهه ای دیگر ممکن است خیلی دقیق و حتی مفید نباشد. آیا سامانه می تواند به صورت اتوماتیک با این تغییرات هماهنگ شود؟ از یک سو توصیه های برخط بر اساس جدیدترین داده ها امکان پذیر است، اما نگهداری و مدیریت آنها نیز دشوارتر است. از سوی دیگر، پردازش دسته ای دادگان و به روزرسانی سامانه توصیه گر در مقاطع مشخص آسان تر و عملیاتی تر است اما تغییرات اخیر داده ها را منعکس نمی کند. همچنین تنظیم و بازیکربندی روش های یادگیری مورداستفاده هم امری است که نباید از آن غافل شد. پارامترها و پیچیدگی الگوریتم مورداستفاده ممکن است در طول زمان نیاز به تغییر داشته باشد که تنها با آزمون و ارزیابی وسیع می توان به مقادیر مطلوب دست یافت.

معیارهای رایج مورداستفاده

همانطوری که پیشتر نیز اشاره شد، سیستم توصیه گر را از مناظر مختلف می توان بررسی و ارزیابی کرد. در چارچوب سیستم های یادگیری ماشینی و در قامت یک سیستم یادگیری بانظارت، معیارهایی مانند دقت پیش بینی، دقت طبقه بندی، دقت رتبه بندی، و معیارهای کیفی تفسیرپذیر انواع اصلی معیارهای ارزیابی برای سیستم های توصیه گر هستند. از منظر یادگیری بدون نظارت معیارهایی مانند شباهت های درون خوشه و تفاوت های بین خوشه ای و همچنین پشتیبانی و اطمینان در ساختارهای شرکت پذیری معیارهای مناسبی هستند (Hastie, Tibshirani, & Wainwright, 2015).

در چارچوب ارتباط و تعامل، معیارهایی مانند تعداد کلیک و بازدید مهم و قابل بحث و بررسی هستند. همچنین از منظر ارزش افزوده تجاری نیز معیارهایی مانند نسبت خریدهای مرتبط با پیشنهادهای ارائه شده اهمیت می یابند (Fayyaz, 2020). محاسبه و ارزیابی این معیارها نیازمند این است که سیستم توصیه گر برای مدتی طولانی در محیط کسب و کار استفاده شود و با جمع آوری اطلاعات و گزارش های عملکردی آن آثار تجاری و کسب و کاری آن روشن شود (Jugovac, 2019 & Jannach). از این رو در زمان توسعه سیستم برای ارزیابی کمی و کیفی آن از معیارهای مبتنی بر یادگیری ماشینی استفاده می شود که شامل مواردی مانند دقت، صحت و فراخوانی است. در ادامه این معیارها به صورت تفصیلی معرفی شده اند (Schröder, Thiele & Lehner, 2011).

دقت پیش بینی

دقت پیش بینی یا پیش بینی رتبه بندی به این موضوع می پردازد که رتبه بندی های تخمینی توصیه کننده چقدر به رتبه بندی های واقعی کاربر نزدیک است. این نوع اندازه گیری به طور گسترده برای ارزیابی رتبه بندی های غیر باینری استفاده می شود. این معیار بهترین انتخاب برای سناریوهای کاربردی است که در آن پیش بینی دقیق رتبه بندی برای همه محصولات حیاتی است. میانگین خطای مطلق^۱ (MAE)، میانگین مربعات خطا^۲ (MSE)، خطای میانگین مربعات ریشه^۳ (RMSE) و میانگین مطلق خطای نرمال شده^۴ (NMAE) مهم ترین معیارها برای این منظور هستند. در مقایسه با متریک MAE، MSE و RMSE از انحرافات مربع استفاده می کنند و در نتیجه بر خطاهای بزرگتر تأکید می کنند. خطا توسط MAE و RMSE در واحدهای مشابه داده های به دست آمده توصیف می شود، در حالی که MSE واحدهای مربعی را تولید می کند. برای مقایسه نتایج در میان توصیه کنندگان با مقیاس های رتبه بندی مختلف، NMAE معیار MAE را در محدوده مقیاس رتبه بندی مناسب عادی می کند. به عنوان نمونه، در رقابت نتفلیکس^۵، از معیار RMSE برای تعیین

^۱Mean Absolute Error (MAE)

^۲Mean Squared Error (MSE)

^۳Root Mean Squared Error (RMSE)

^۴Normalized Mean Absolute Error (NMAE)

^۵https://en.wikipedia.org/wiki/Netflix_Prize

میزان بهبود در مقایسه با الگوریتم CineMatch و همچنین برنده جایزه استفاده شده است (Lehner, 2011 & Schröder, Thiele).

دقت طبقه بندی

اندازه گیری های دقت طبقه بندی تلاش می کنند تا ظرفیت تصمیم گیری موفق یک الگوریتم توصیه (SDMC) را ارزیابی کنند. آنها برای نیازهای کاربر مانند شناسایی محصولات خوب مفید هستند زیرا تعداد طبقه بندی های درست و غلط را به عنوان موارد مرتبط یا نامربوط تولید شده توسط سیستم توصیه کننده ارزیابی می کنند. معیار SDMAC رتبه بندی دقیق اشیا (دسته بندی صحیح و غلط) را نادیده می گیرد. این نوع معیار به ویژه برای سیستم های تجارت الکترونیکی مناسب است که سعی می کنند کاربران را به انجام اقدامات خاصی مانند خرید محصولات یا خدمات متقاعد کنند.

دقت رتبه

در آمار، دقت رتبه یا پیش بینی رتبه بندی، توانایی توصیه کننده را برای تخمین ترتیب صحیح آیتم ها بر اساس ترجیحات کاربر ارزیابی می کند که به عنوان اندازه گیری همبستگی رتبه شناخته می شود. در نتیجه، اگر فهرست طولانی و مرتبی از کالاها به کاربر داده شود، این نوع اندازه گیری مناسب ترین است.

ترتیب نسبی مقادیر ترجیحی در یک متریک پیش بینی رتبه استفاده می شود که مستقل از مقادیر دقیق ارزیابی شده توسط یک توصیه کننده است. برای مثال، توصیه کننده ای که مرتباً رتبه بندی آیتم ها را پایین تر از اولویت های کاربر واقعی ارزیابی می کند، ممکن است تا زمانی که رتبه بندی صحیح باشد، امتیاز کاملی کسب کند.

• میانگین میانگین دقت @ K و میانگین میانگین فراخوان @ K

برای هر کاربر در مجموعه آزمایشی، یک سیستم توصیه کننده معمولاً یک لیست سفارشی از توصیه ها ایجاد می کند. MAP@K نشان می دهد که لیست موارد توصیه شده چقدر مرتبط است،

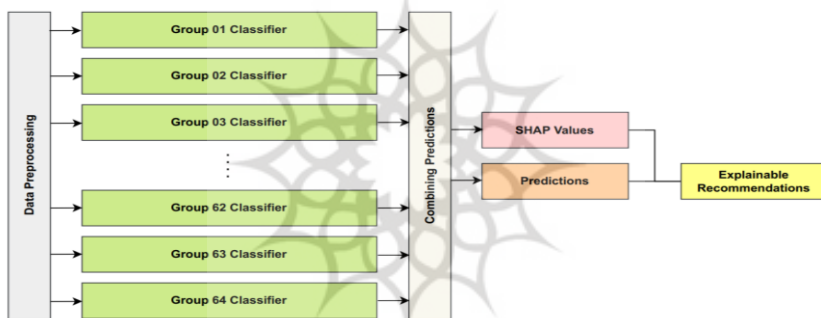
در حالی که MAR@K نشان می‌دهد که توصیه‌کننده چقدر خوب می‌تواند همه موارد موجود در مجموعه آزمایشی را که کاربر به آنها امتیاز مثبت داده است، به خاطر بیاورد.

روش پیشنهادی

روش پیشنهادی برای توسعه سیستم پیشنهاددهنده استفاده از رویکردهای یادگیری ماشینی با تمرکز بر روش‌های نظارتی و بازیابی اطلاعات است. در این راستا ابتدا مجموعه روشهایی را که در بخش که قبل معرفی نمودیم آزمون و ارزیابی نموده و از میان آنها یکی را برای توسعه سیستم نهایی انتخاب می‌کنیم.

ساختار کلی سامانه پیشنهاددهنده

ساختار کلی سیستم سامانه پیشنهاددهنده در شکل زیر نشان داده شده است. هدف از این ساختار ارائه توصیه‌های مناسب و درعین حال تفسیر پذیر به کاربر است. در ادامه مراحل تولید توصیه‌ها از پردازش داده‌ها تا تولید توصیه‌های نهایی توصیف شده است.



شکل ۳ ساختار سیستم پیشنهاددهنده

نحوه انتخاب طبقه بندها

همانطوری که در فصل قبلی هم اشاره شد، در نسخه فعلی سیستم از طبقه بند هایی با قابلیت تولید خروجی احتمالی برای تولید توصیه‌ها استفاده می‌شود. به این صورت که برای هر یک از گروه‌های آموزشی یک طبقه بند مجزا آموزش داده می‌شود. هر طبقه بند، احتمال انتخاب یک گروه آموزشی به خصوص توسط کاربر را برآورد می‌کند. لازم به ذکر است که طبقه بندی‌ها از ۱۵ درصد داده‌ها برای اعتبار سنجی و تعیین برخی پارامترها استفاده می‌کنند. به‌عنوان مثال در نسخه فعلی از طبقه بندی بر اساس Gradient Boosting استفاده می‌شود که این مدل داده‌های اعتبار سنجی را برای تعیین عمق مناسب درخت هابه کار می‌برد. ضمناً طبقه بندی از اطلاعات دیگری مثل نسبت انتخاب گروه‌ها هم برای غلبه بر مشکل عدم توازن داده‌ها استفاده می‌کند. بعد از

برآورد احتمال انتخاب هر گروه، احتمالات همه ی طبقه ها بعد از نرمال سازی مرتب می شوند و گروه های با بیشترین احتمال به کاربر پیشنهاد می شود.

تفسیر توصیه های ارائه شده

یکی از اهداف طراحی این سیستم، ارائه توضیحاتی در مورد توصیه های تولید شده است. برای تفسیر نتایج مدل ها یعنی یافتن متغیر های موثر بر نتیجه و نقش هر کدام، از مقادیر SHAP استفاده شده است. با کمک این مقادیر، به شیوه های مختلفی می توان توضیحاتی مخصوص هر کاربر ارائه داد. به عنوان مثال شناسایی متغیر های با بیشترین تاثیر در توصیه ارائه شده اهمیت زیادی دارد. زیرا ممکن است دلیل اختصاص احتمال پایین به یک دوره، عدم سکونت شخص در استان تهران، تشخیص داده شود. یا نقش مثبت یا منفی مقادیر خاصی از متغیر ها برای تعیین گروه آموزشی، مانند تاثیر افزایش سطح تحصیلات بر احتمال انتخاب یک گروه آموزشی خاص، قابل استخراج است. در پایان با تفسیر مقادیر SHAP توضیحاتی علاوه بر دوره های پیشنهادی، به کاربر ارائه می شود.

محیط مورد استفاده

برای پیاده سازی و آزمون مدل ها از زبان پایتون نسخه ۳٫۷ استفاده شده است. برنامه های پایتون در محیط jupyter Notebook نوشته شده اند. برای پیاده سازی مدل های یادگیر از کتابخانه استاندارد و رایج^۱ scikit-learn استفاده شده است. نوت بوکها همراه این گزارش ارائه می شود. مدل های مورد استفاده بیز ساده، رگرسیون لاجیستیک، شبکه عصبی، درخت تصمیم، جنگل تصادفی و گونه هایی از روشهای بوسستینگ هستند.
 دادگان مورد استفاده

داده های موجود برای این پژوهش مشتمل بر داده های ثبت نامی سال ۱۳۹۷ سازمان آموزش فنی و حرفه ای کشور است. این مجموعه بالغ بر ۱۳۰۰۰۰۰ رکورد است که هر رکورد شامل اطلاعات هویتی، تحصیلی و مهارت آموزی هر شخص است.

اطلاعات ثبت شده برای اشخاص تقریباً همگن است اما تعدادی از رکوردها اطلاعات درست یا کاملی ندارند. کمتر از یکصد رکورد فاقد نام، نام خانوادگی یا هر دو بوده و از مجموعه داده ها حذف شدند. نزدیک به یکهزار رکورد کد ملی نداشتند یا کد ملی آنها به صورت رشته حرفی،

^۱<https://scikit-learn.org/>

کاراکترهای خاص (- و * و /) ثبت شده بود. با توجه به اینکه تعداد این رکوردها قابل توجه بود، حذف نکردیم و به همان صورت وارد مراحل بعدی نمودیم.

برای حفظ محرمانگی داده‌ها در مبادلات، پردازش و گزارش جدول‌های کدینگ تهیه کردیم که مقادیر فیلدهای هویتی را به کدهای معینی نگاشت می‌کرد. مثلاً برای نام همه افراد منحصر به فرد را از استخراج نموده و شماره‌گذاری کردیم. سپس به جای نام هر فرد، شماره نام او را در جدول قرار دادیم. به این ترتیب ضمن حفظ هویت مستقل هر فرد از نشت و انتشار اطلاعات او جلوگیری کردیم. این جدول‌های کدینگ را به صورت محرمانه نگهداری می‌کنیم و تنها در صورت نیاز طبق پروتکل‌های خاصی که دسترسی به آن را محدود کرده، اطلاعات را بازخوانی و بررسی می‌کنیم. این فرایند کدینگ را برای نام خانوادگی، شماره ملی و شماره موبایل هم انجام دادیم.

نتایج یادگیری بانظارت

میانگین دقت مدل‌های مختلف در جدول زیر آمده است. نتایج کامل روش‌های مختلف به تفکیک گروه‌های آموزشی نیز در پیوست‌ها آمده است. در سیستم‌های بازیابی اطلاعات معیار فراخوانی جایگاه ویژه‌ای دارد زیرا به معنی پوشش و واکشی نتایج مرتبط است. چنانچه روش رتبه‌بندی مناسبی اتخاذ شود، پاسخ‌های مرتبط بازیابی شده در اوایل فهرست جای گرفته و پاسخ‌های غیر مرتبط به سمت انتهای فهرست هدایت می‌شوند. از این رو هرچند ممکن است Precision کلی مناسب نباشد، با توجه به رتبه‌بندی، نتایج مفید در ابتدای فهرست حضور بیشتری داشته و Precision@k بالا خواهد بود. لذا ترجیح بر این است که فراخوانی تا حد ممکن بالا باشد. بر اساس این نتایج روش Gradient Boosting برای استفاده در موتور پیشنهاددهنده برگزیده شد.

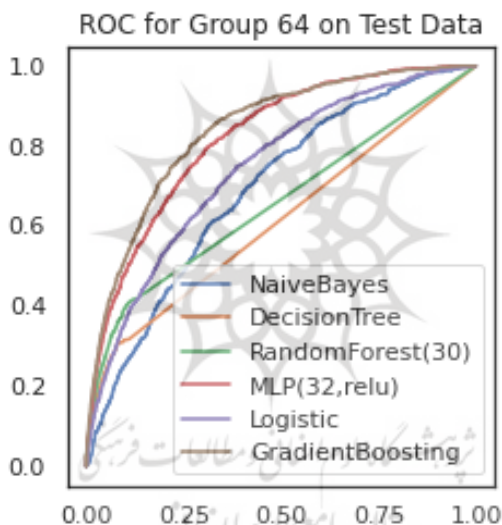
جدول ۱ میانگین معیارهای ارزیابی برای مدل‌های مختلف

آزمون				آموزش				مدل
F1	Precision	Recall	Accuracy	F1	Precision	Recall	Accuracy	
۰,۰۷	۰,۱۸	۰,۰۶	۰,۹۸	۰,۲۶	۰,۸۶	۰,۱۷	۰,۹۸	DecisionTree
۰,۰۸	۰,۰۴	۰,۷۷	۰,۸۴	۰,۰۹	۰,۰۵	۰,۹۳	۰,۸۵	GradientBoost
۰,۰۱	۰,۰۴	۰,۰۶	۰,۹۸	۰,۰۱	۰,۰۵	۰,۰۵	۰,۹۸	Logistic
۰,۰۲	۰,۲۶	۰,۰۳	۰,۹۸	۰,۰۲	۰,۲۹	۰,۰۳	۰,۹۸	MLP
۰,۰۶	۰,۰۳	۰,۸۴	۰,۶۱	۰,۰۶	۰,۰۳	۰,۸۶	۰,۶۱	NaiveBayes

۰,۰۸	۰,۲۱	۰,۰۷	۰,۹۸	۰,۲۸	۰,۷۸	۰,۱۹	۰,۹۹	RandomForest
------	------	------	------	------	------	------	------	---------------------

نتایج یادگیری بدون نظارت

همانطوری که در جدول ۲ مشاهده می شود، عده بسیار کمی از مهارت آموزان بیشتر از یک دوره آموزشی را انتخاب کرده اند. این موضوع کاربری روشهای بدون نظارت مبتنی بر شباهت را به شدت تحت تاثیر قرار می دهد. لذا با توجه به عدم توازن انتخاب رشته های مختلف توسط هنرجویان، خوشه بندی و قواعد شرکت پذیری از مجموعه روش های قابل استفاده حذف شدند.



شکل ۴ منحنی راک برای روش های مختلف و یکی از گروه های آموزشی

جدول ۲ فراوانی توزیع تعداد دوره های انتخاب شده و تعداد هنرجویان

دوره	۱	۲	۳	۴	+۵
هنرجو	۷۷۰۱۵۰	۱۰۶۸۶۷	۳۰۸۱۲	۱۱۷۲۹	۹۶۲۲
نسبت	۰,۸۳	۰,۱۲	۰,۰۳	۰,۰۱	۰,۰۱

روش منتخب و نتایج آن

در شکل ۴ منحنی راک^۱ برای یک گروه آموزشی و روش‌های مختلف ترسیم شده است. سطح زیر منحنی راک بیانگر خوبی از دقت روش‌هاست. همانطوری که در این شکل دیده می‌شود روش بوستینگ انتخاب شده دقت بالاتری نسبت به بقیه روش‌ها دارد.

برنامه توسعه داده‌شده

سامانه پیشنهاددهنده توسعه داده‌شده^۲ یک برنامه پیمانه ای است که در حال حاضر در قالب سه مولفه اصلی «موتور پیشنهاددهنده»، «واسط کاربری تحت وب» و «واسط برنامه‌های کاربردی» طراحی و توسعه داده‌شده است. جزئیات هر یک از این موارد در ادامه توضیح داده می‌شود. سامانه توسعه داده‌شده در هر محیط مجهز به زبان برنامه‌نویسی پایتون قابل استفاده و اجراست. در حال حاضر این سامانه روی یک ماشین لینوکس دبین نسخه ۱۲^۳ استقرار یافته است. زبان برنامه‌نویسی پایتون ۳,۷ بوده و از کتابخانه‌های استاندارد و رایج این زبان استفاده شده است.

موتور پیشنهاددهنده دارای یک هسته هوشمند است که از یک مدل یادگیری شده و توابع دسترسی به خدمات آن تشکیل یافته است. این مدل همانطور که در بخش‌های قبلی توضیح داده شد، از رویکرد boosting استفاده می‌کند و بر مبنای xgboost پیاده‌سازی شده است. این مدل بر اساس داده‌های فعلی یادگیری شده است. برای به روزرسانی آن با داده‌های جدید لازم است فرایندهای پیش‌پردازش و آموزش مدل با داده‌های جدید انجام پذیرد. علاوه بر این، هسته هوشمند مولفه ای برای پیشنهاد استاندارد آموزشی هم دارد که با استفاده از الگوریتم‌های همسایگی مانند kNN پیاده‌سازی شده است.

واسط کاربری تحت وب درگاه دسترسی به سامانه پیشنهاددهنده بوده و در قالب یک برنامه وب با استفاده از چارچوب فلسک^۴ پیاده‌سازی شده است. با توجه به اینکه قرار است این سامانه با سایر سامانه‌های سازمان کار کند، در نسخه فعلی حداکثر سادگی لحاظ شده است.

واسط برنامه نویسی مولفه مجموعه از توابع برنامه‌نویسی به زبان پایتون هست که دسترسی سایر برنامه‌های کاربردی به موتور پیشنهاددهنده را ممکن می‌سازد. با استفاده از این مولفه، سامانه

^۱Receiver Operating Characteristic

این سامانه در محیط ارائه شده توسط کارفرما استقرار یافته و قابل استفاده است.^۲

^۳Linux Debian 10, Buster

^۴Flask web development frame work: <https://flask.palletsprojects.com/en/2.1.x/>

پیشنهاددهنده با سایر سامانه ها یکپارچه شده و خدمات در بستر آن سامانه ها هم قابل ارائه خواهد بود.

جمع بندی

در این مقاله توسعه سامانه پیشنهاددهنده گزارش شده است. روش و مدل های منتخب، محیط اجرایی و همچنین سامانه توسعه داده شده به تفصیل معرفی شده است. راهنمای کاربری و وب سرویس مورد نیاز برای اتصال به سایر سامانه ها پایان بخش این گزارش است. با توجه به محدودیت داده ها پیشنهاد می شود در نسخه بعدی از دادگان بیشتری استفاده شود.

سپاس گذاری

بدین وسیله از همکاری آقای امیرعباس اسدی در برنامه نویسی و پیاده سازی الگوریتمها سپاسگزاری می نمایم.

منابع:

1. Aggarwal, C. C. (2016). *Recommender systems*. Springer.
2. Akhtar, A. (2020). Implementation of course recommender system for virtual university of pakistan. *arXiv preprint arXiv:2008.07867*.
3. Bakhshinategh, B., Spanakis, G., Zaiane, O., & ElAtia, S. (2017). A course recommender system based on graduating attributes. *International Conference on Computer Supported Education*, 2, pp. 347-354.
4. Cancino, C., Merigó, J. M., Coronado, F., Dessouky, Y., & Dessouky, M. (2017). Forty years of Computers & Industrial Engineering: A bibliometric analysis. *Computers & Industrial Engineering*, 113, 614-629.
5. Das, A. S., Datar, M., Garg, A., & Rajaram, S. (2007). Google news personalization: scalable online collaborative filtering. *Proceedings of the 10th ACM SIGKDD International Conference on Data Mining and Knowledge Discovery*, (pp. 271-280).
6. Dean, J. (2014). *Big data, data mining, and machine learning: value creation for business leaders and practitioners*. John Wiley & Sons.
7. Fayyaz, Z. a. (2020). Recommendation systems: Algorithms, challenges, metrics, and business opportunities. *applied sciences*, 10(21), 7748.
8. Flach, P. (2012). *Machine learning: the art and science of algorithms that make sense of data*. Cambridge university press.

۹. Foreman, J. W. (2013). *Data smart: Using data science to transform information into insight*. John Wiley & Sons.
۱۰. Gulzar, Z., Leema, A. A., & Deepak, G. (2018). Pcrs: Personalized course recommender system based on hybrid approach. *Procedia Computer Science*, 125, 518-524.
۱۱. Han, J., Pei, J., & Tong, H. (2022). *Data mining: concepts and techniques*. Morgan kaufmann.
۱۲. Hastie, T., Tibshirani, R., & Wainwright, M. (2015). Statistical learning with sparsity. *Monographs on statistics and applied probability*, 143, 8.
۱۳. Jannach, D., & Jugovac, M. (2019). Measuring the business value of recommender systems. *ACM Transactions on Management Information Systems (TMIS)*, 10, 1-23.
۱۴. Madani, Y., Erritali, M., Bengourram, J., & Sailhan, F. (2019). Social collaborative filtering approach for recommending courses in an E-learning platform. *Procedia Computer Science*, 151, 1164-1169.
۱۵. Salahli, M. A., Gasimzade, T., Alasgarova, F., & Guliyev, A. (2016). The use of predictive models in intelligent recommendation systems. *Procedia Computer Science*, 102, 515-519.
۱۶. Schröder, G., Thiele, M., & Lehner, W. (2011). Setting goals and choosing metrics for recommender system evaluations. *UCERSTI2 workshop at the* *۱۳، ۵۳*.
۱۷. Upendran, D., Chatterjee, S., Sindhumol, S., & Bijlani, K. (2016). Application of predictive analytics in intelligent course recommendation. *Procedia computer science*, 93, 917-923.
۱۸. Upendran, D., Chatterjee, S., Sindhumol, S., & Bijlani, K. (2016). Application of predictive analytics in intelligent course recommendation. *Procedia computer science*, 93, 917-923.
۱۹. Witten, I. H., & Frank, E. (2002). Data mining: practical machine learning tools and techniques with Java implementations. *Acm Sigmod Record*, 31, ۷۶-۷۷.

رتال جامع علوم انسانی