

یک سیستم توصیه گر مبتنی بر محتوی برای پیشنهادات فروش و کوپن های

تجارت الکترونیک

چکیده

شرکت های تجارت الکترونیک پاداش محور هر روزه هزاران تخفیف و کوپن را به صورت آنلاین به نمایش می گذارند. مشتریانی که برای خدمات کوپن آنلاین ثبت نام می کنند یا یک ایمیل خودکار را با تخفیفات انتخاب شده دریافت می کنند و یا این که تخفیفات خاص را در صفحه اول وب سایت شرکت انتخاب می کنند. تخفیفات آنلاین با کیفیت بالا انتخاب شده و از طریق این دو ابزار با استفاده از یک فرایند دستی که در آن گروهی از کارشناسان مسئول ارزیابی تازگی، محبوبیت محصول، تمایلات خرده فروش و سایر معیارهای مربوط به کسب و کار کار می کنند، تحویل می شوند. این فرایند بر هزینه و زمانبر بوده و بر طبق سلیقه و اولویت کاربران و یا سابقه خرید آنها نیست. در این مطالعه، ما یک سیستم توصیه گرمبتنبر محتوی را پیشنهاد می کنیم که فرایند انتخاب کوپن را ساده تر کرده و توصیه را برای بهبود نرخ کلیک و در نهایت نرخ تبدیل، شخصی سازی می کند. در مقایسه بامعیار مبتنی بر محبوبیت، سیستم توصیه گر مبتنی بر محتوی موجب بهبود شاخص های F از 0.21 تا 0.85 شده و نرخ کلیک برآورد شده را از 1.20 تا 7.80 درصد افزایش می دهد. سیستم آزمایشی امروزه برای آزمون A/B با مشتریان واقعی زمان بندی شده است.

مفاهیم CCS

- روش های محاسبه: طبقه بندی و درخت رگرسیون
- محاسبه کاربردی: خرید آنلاین

کلمات کلیدی: سیستم های توصیه گر، شخصی سازی، تخفیفات و کوپن های تجارت الکترونیک

1- مقدمه

سرویس های تجارت الکترونیک پاداش محور یک بخش آنلاین سریع رشد می باشد که از طریق اهرم قیمت های تخفیف خورده از یک شبکه گسترده ای از شرکت های وابسته، تخفیف های نقدی (کش بک) به مشترکان ارائه می کنند.

معمولاً، یک مصرف کننده از وب سایت شرکت برای جست و جوی محصولات خاص، خرده فروشان و یا کلیک بر روی یکی از تخفیفات برجسته منتشر شده استفاده می کنند. سپس خریداران به وب سایت های خرده فروشان مربوطه هدایت می شوند. یک بازدید از وب سایت از طریق این هدایت موسوم به گردش خرید می باشد. در عین حال، مشترکین ایمیل های روزانه خودکار را با رایج ترین تخفیفات دریافت می کنند. شکل 1 قطعه ای از یک ایمیل خودکار روزانه را نشان می دهد که دارای یک فهرستی از تخفیفات و کوپن های فعلی است. محتوای وب سایت و ایمیل به طور دستی توسط کارشناسانی که بر تحویل با کیفیت ترین تخفیفات به مشتریان متمرکز هستند سازمان دهی می شود.

فروشنده الف	پارک آبی +10 درصد بازپرداخت نقدی
فروشنده ب	فروش 48 ساعته: بیش از 50 درصد تخفیف
فروشنده پ	بیش از 65 درصد تخفیف برای آیتم های با قیمت عادی + با پیک رایگان
فروشنده ت	روز آخر، 40 درصد تخفیف
فروشنده ث	روز آخر، تخفیف 40 درصد همه لباس های شنا، حول ساحل

شکل 1: مثالی از پیام تبلیغات از طریق ایمیل شامل تخفیفات و کوپن ها

این فرایند سازمان دهی تبلیغات به طور دستی بسیار دشوار است و برای میلیون ها مشتری آنلاینی که پیشنهادات تخفیف یکسانی را صرف نظر از سابقه خرید یا جست و جوی قبلی خود دریافت می کنند کافی نیست. یک سیستم توصیه گر قادر به پوشش دادن اولویت ها و سلیق مشتریان از طریق بهینه سازی انتخاب کوپن بر اساس سابقه و تشابه میان کاربران و یا آیتم ها می باشد. با این حال، در مقایسه با سیستم های توصیه گر سنتی در سایر حوزه ها نظیر فیلم (6-10) و موسیقی (16)، تخفیفات خرید به دلایل متعددی متفاوت می باشند: 1- کوپن ها آیتم های به شدت فراری هستند که تنها در یک دوره زمانی محدود اعتبار دارند و پس از تاریخ انقضا، حذف می شوند 2- مشتریان استفاده کننده از کوپن ها، تحت تأثیر گردش حساب و حجم معامله بالایی قرار دارند 3- جمعیت کاربران و مشتریان معمولاً بین اقلیت کاربران دایمی و اکثریت کاربران موقت متغیر

است و 4- تخفیفات آنلاین به ندرت مانند تخفیفات مربوط به حوزه فیلم و موسیقی ارزیابی و رتبه بندی می‌شوند.

در نتیجه، حوزه تخفیفات آنلاین در معرض مسئله شروع و راه اندازی سرد (4) قرار دارد که در آن تاریخچه کلیک یا جست و جو برای یک آیتم جدید کافی نیست و یا بر عکس، یک تاریخچه کافی برای یک مشترک جدید وجود ندارد. روش‌های فاکتور گیری ماتریس در برابر مسئله شروع سرد ضعیف بوده (4) و قادر به پوشش دادن برخی از ویژگی‌های ضروری برای مدل سازی اولویت‌های آیتم‌های بسیار فرار و جمعیت زیادی از مشتریان نمی‌باشد.

به همین دلیل، ما رویکرد فیلترینگ مبتنی بر محتوی (CBF) را اتخاذ کردیم که در آن از کوپن‌ها و ویژگی‌های مشتریان برای ایجاد یک مدل طبقه بندی تصادفی که احتمال پسین را برای یک کوپن انتخاب شده توسط مشتری پیش بینی می‌کند استفاده می‌کنیم. ما به بازخورد ضمنی کاربران متکی هستیم که به طور غیر مستقیم اولویت‌ها و سلايق کاربران را از طریق رفتاری نظیر کلیک کردن بر روی تخفیفات خاص در یک لیست رتبه بندی شده بیان می‌کند. این معمولاً یک سیگنال نويزدار در مقایسه با بازخورد صریح نظیر ارزیابی‌ها و ارائه نظرات می‌باشد با این حال با اریبی‌ها و سوگیری‌های فراوانی در تاریخچه و سابقه کلیک توسط کاربر همراه است (15-23).

با این حال، استفاده از اطلاعات کلیک چالش برانگیز تر است زیرا مستقیماً منعکس کننده رضایت کاربران نبوده و در عین حال علايم و نشانه‌هایی در خصوص آیتم‌های نامناسب در اختیار نمی‌گذارد (بازخورد منفی) (18) که خود از اهمیت زیادی برای ایجاد یک مدل تمایزی مؤثر برخوردار است. در این مقاله، ما به بررسی شیوه استفاده از بازخورد ضمنی نويزدار برای ایجاد مدل CFB برای توصیه‌های تخفیف و کوپن می‌پردازیم. اهداف اصلی به شرح زیر هستند:

- ما روشی را برای ایجاد نمونه‌های منفی از داده‌های بازخورد ضمنی توصیف می‌کنیم
- ما آزمایشات گسترده‌ای را برای مقایسه مدل‌های یادگیری مختلف انجام می‌دهیم
- ما اثبات می‌کنیم که رویکرد ما با توجه به معیار و معیار کران بالا مؤثر است.

2- رویکردهای مدل سازی

ما به طور رسمی به مسئله توصیه کوپن به عنوان فیلترینگ مبتنی بر محتوی (17) با بازخورد ضمنی می‌پردازیم. فرض کنید که M و n به ترتیب تعداد کاربران و کوپن‌ها باشند. برای هر تعامل خرید در ماتریس $Y \in \mathbb{R}^{M \times N}$ ، کاربر u_i در معرض تعدادی کوپن L قرار گرفته و یک کوپن خاص c_j را انتخاب و یک بازخورد ضمنی $y_{u_i, c_j} = 1$ و $y_{u_i, c_k} = 0$ را به ازای همه آیتم‌های دیگر در فهرست با طول L تولید می‌کند که در آن $k \neq j$ و $k = \{0, 1, \dots, L-1\}$ است. پیش‌بینی یک بار گردش خرید کاربر برای تخفیفات آنلاین نیازمند برآورد تابع $\hat{y}_{u_i, c_j} = f(u_i, c_j | \Theta)$ است که در آن \hat{y}_{u_i, c_j} امتیاز پیش‌بینی شده تعامل آنلاین (u_i, c_j) بوده و Θ نشان‌دهنده پارامترهای مدل برای یادگیری و F تابع نگاشت بین پارامترها و امتیازات پیش‌بینی شده است. یادگیری می‌تواند با استفاده از الگوریتم طبقه‌بندی یادگیری ماشینی صورت گیرد که تابع هدف نظیر زیان لجستیک یا زیان آنتروپی متقاطع (12) را بهینه‌سازی می‌کند.

با این حال، بررسی دقیق‌تر بازخورد ضمنی مورد استفاده برای مدل سازی $y_{u_i, c_k} = 0$ لزوماً به این معنی نیست که کاربر u_i تخفیف y_{u_i, c_k} را دوست ندارد، با این حال صرفاً نشان‌دهنده اولویت انتخاب در این تعاملات است. کاربر می‌تواند به لیست تخفیفات مراجعه کند و یک آیتم دیگر که متفاوت از C_j است را انتخاب کند. این موجب می‌شود تا مدل سازی پیش‌بینی چالش برانگیزتر شود زیرا بازخورد ضمنی کاربر نویزدار بوده و بازخورد منفی وجود ندارد. در این رابطه، ماتنها بازخورد مثبت را در نظر گرفته و پیش‌بینی‌های میزان خرید و بازدید را به صورت مسئله طبقه‌بندی یک طبقه (OCC) (21) مدل سازی کرده‌اند که در آن ما تنها از نمونه‌های مثبت استفاده کرده و به طور مصنوعی نمونه‌های منفی را از تاریخچه خرید کاربر استخراج (مشتق) می‌کنیم. به منظور مدیریت فرایند طبقه‌بندی، ما دوروش یادگیری غیر پارامتری را که در برابر ویژگی‌های نویزدار انعطاف‌پذیر و در برابر داده‌های پرت مقاوم هستند و نیز قادر به مدیریت ویژگی‌های مفقود هستند (ولی لزوماً در برابر برچسب‌های نویزی مقاوم نیستند) بررسی می‌کنیم 1- جنگل‌های تصادفی (5-12، فصل 15)، 2- درخت افزایش‌گرادیان (9).

1-2 تولید نمونه‌های منفی

هنگام اتکاء به بازخورد ضمنی کاربر، یک شیوه پذیرفته شده این است که آیتم‌های با رتبه بالا که بر روی آن‌ها کلیک نشده است، احتمالاً از اهمیت کم‌تری نسبت به آیتم‌های کلیک شده دارند (20). در محیط‌های صنعتی، نه رتبه کوپن و نه فهرست کوپن ارائه شده به کاربران، قابل دسترس نمی‌باشند. در این صورت استخراج گردش‌های خرید منفی (یعنی کوپن‌های غیر مرتبط) توسط ابزارهای دیگر لازم است. برای مجموعه‌های آموزشی و آزمایشی منفی، ما روش توصیف شده در زیر را دنبال می‌کنیم

برای هر گردش خرید، ما سه مورد را استخراج کردیم: کاربر، کوپن و زمان کلیک

- تاریخچه گردش خرید کاربر بازیابی شد و همه کوپن‌های کلیک شده توسط کاربر تا زمان کلیک فعلی انتخاب گردید

- با توجه به زمان کلیک مورد نظر، همه کوپن‌های غیر منقضی در آن زمان بازیابی می‌شوند. ما این را مجموعه داده S می‌نامیم.

- ما همه کوپن‌های کلیک شده توسط کاربر را از مجموعه کوپن‌های غیر منقضی حذف کرده و مجموعه داده $U=S-A$ را بدست آوردیم

- به طور یکنواخت 2-4-8 و 9 کوپن از U انتخاب شده و از هر مجموعه داده، فهرستی از گردش‌های خرید منفی برای شبیه سازی نمونه‌های منفی در مجموعه داده ایجاد شد.

توجه کنید که ما اندازه‌های متفاوتی از مجموعه‌های منفی را برای اهداف ارزیابی نمونه برداری کردیم با این حال نتایج را برای مجموعه‌های منفی با اندازه 9 گزارش کردیم زیرا نزدیک‌ترین مقدار به شرایط سیستم واقعی است که در آن یک فهرست متشکل از 10 تخفیف به کاربر ارائه شده و او یکی از آن‌ها را انتخاب می‌کند.

2-2 جنگل‌های تصادفی

مدل‌های جنگل‌های تصادفی (5، 12، فصل 15) از فنون بسته بندی برای غلبه بر مسئله واریانس بالا و اربیبی پایین درخت تصمیم استفاده می‌کنند. یک مدل جنگل تصادفی، میانگین نتایج چندین درخت تصمیم نویزدار و نسبتاً بدون اربیب آموزش دیده در بخش‌های مختلف از یک مجموعه آموزشی را محاسبه می‌کند. روش کلی برای ایجاد مدل RF از مراحل زیرپیروی می‌کند (12، فصل 15).

به ازای $b = 1, \dots, B$ ، که در آن b تعداد کل درختان بسته بندی شده است:

1- N نمونه را از مجموعه آموزشی استخراج کرده و یک درخت T_b را با استفاده از مراحل زیر برای هر گروه پایانه تا زمان رسیدن به حداقل اندازه گروه n_{min} ایجاد کنید.

الف: به طور تصادفی m ویژگی را از کل p ویژگی انتخاب کنید که در آن $m \leq p$ است

ب: بهترین انشعاب گره را در میان m ویژگی انتخاب کنید

پ: گره‌های انتخاب شده را به دو گره فرزند تقسیم کنید.

2- درخت بدست آمده را ذخیره کنید $\{T_b\}_1^B$

به منظور تعیین کیفیت تقسیم گره، شاخص‌های ناخالصی جینی یا شاخص‌های آنتروپی متقاطع را می‌توان برای تقسیم استفاده کرد (12، فصل 9) برای فرایند طبقه بندی، پیش بینی، رأی اکثریت میان نتایج حاصل از گروه

بندی درخت است. به عبارت دیگر، اگر $\hat{C}_b(x)$ پیش بینی طبقه برای درخت جنگل تصادفی b_{th} باشد، سپس

طبقه پیش بینی شده $\hat{C}_{rf}^B(x) = \text{majority vote}\{\hat{C}_b(x)\}_1^B$ است.

2-3 درختان افزایش گرادیان

درخت افزایش گرادیان (GBT) (9) تابع زیان را بهینه سازی می‌کنند $\mathcal{L} = E_y[L(y, F(x)|X)]$ که در آن

$F(x)$ به سختی قادر به مشخص کردن تابع نظیر درخت تصمیم $f(x)$ نسبت به X می‌باشد. مقدار بهینه تابع

به صورت $F^*(x) = \sum_{m=0}^M f_m(x, a, w)$ بیان می‌شود که در آن $f_0(x, a, w)$ فرض اولیه بوده و

به صورت صعود افزایشی بر X می‌باشد که از طریق روش بهینه سازی تعریف می‌شود. $\{f_m(x, a, w)\}_{m=1}^M$

پارامتر a_m از $f_m(x, a, w)$ نشان دهنده نقاط تقسیم متغیرهای پیش بین بوده و w_m بیانگر وزن افزایشی بر

روی گره‌های برگ درختان تصمیم متناظر با مجموعه آموزشی تقسیم شده X_j به ازای منطقه J است. برای

محاسبه $F^*(x)$ ، ما بایستی به ازای هر دور افزایش m را محاسبه می‌کنیم

$$\{a_m, w_m\} = \arg \min_{a, w} \sum_{i=1}^N L(y_i, F_m(x_i)) \quad (1)$$

که $F_m(\mathbf{x}) = F_{m-1}(\mathbf{x}) + f_m(\mathbf{x}, \mathbf{a}_m, \mathbf{w}_m)$ می‌باشد. این معادله نشان دهنده مرحله گرادیان نزولی است

$$F_m(\mathbf{x}) = F_{m-1}(\mathbf{x}) + \rho_m (-g_m(\mathbf{x}_i)) \quad (2)$$

که در آن ρ_m طول مرحله و $g_m(\mathbf{x}_i) = \left[\frac{\partial L(\mathbf{y}, F(\mathbf{x}))}{\partial F(\mathbf{x})} \right]_{F(\mathbf{x}_i)=F_{m-1}(\mathbf{x}_i)}$ جهت جست و جوست. برای

حل \mathbf{a}_m و \mathbf{w}_m ، همبستگی توابع پایه $f_m(\mathbf{x}_i; \mathbf{a}, \mathbf{w})$ را با $-g_m(\mathbf{x}_i)$ تعیین می‌کنیم که در آن گرادیانها نسبت به توزیع داده‌های آموزشی تعریف می‌شوند. به ویژه با استفاده از بسط سری تیلور، می‌توانیم راه حل‌های فرم بسته را برای \mathbf{a}_m و \mathbf{w}_m بدست بیاوریم. می‌توان نشان داد که

$$\mathbf{a}_m = \arg \min_{\mathbf{a}} \sum_{i=1}^N (-g_m(\mathbf{x}_i) - \rho_m f_m(\mathbf{x}_i, \mathbf{a}, \mathbf{w}_m))^2 \quad (3)$$

و

$$\rho_m = \arg \min_{\rho} \sum_{i=1}^N L(y_i, F_{m-1}(\mathbf{x}_i) + \rho f_m(\mathbf{x}_i; \mathbf{a}_m, \mathbf{w}_m)) \quad (4)$$

که می‌دهد

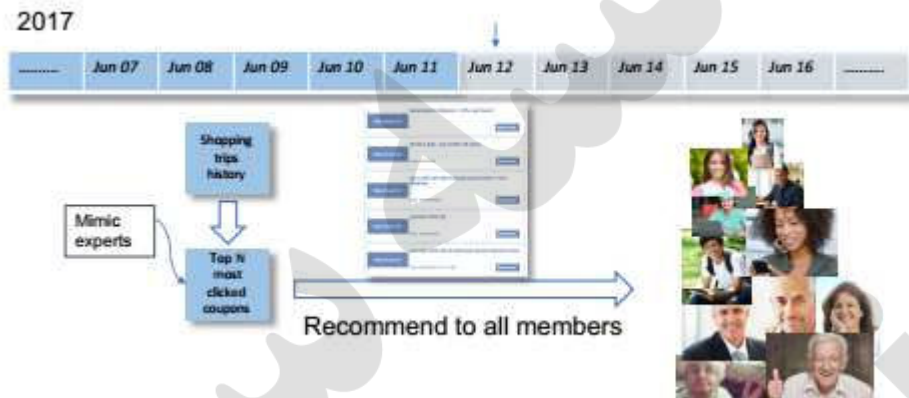
$$F_m(\mathbf{x}) = F_{m-1}(\mathbf{x}) + \rho_m f_m(\mathbf{x}, \mathbf{a}_m, \mathbf{w}_m) \quad (5)$$

هر دور افزایش گرادیان، اوزان \mathbf{w}_m را بر روی برگ‌ها به روز رسانی کرده و به ایجاد یک درخت جدید در تکرار بعدی کمک می‌کند. انتخاب بهینه پارامترهای درخت تصمیم بر اساس بهینه سازی $f_m(\mathbf{x}, \mathbf{a}, \mathbf{w})$ با استفاده از زیان لجستیک است. برای GBT، هر درخت تصمیم مقاوم به عدم توازن و داده‌های پرت است (12) و $F(\mathbf{x})$ به طور دلخواه قادر به تقریب مرزهای تصمیم پیچیده است.

4-2 معیار مبتنی بر محبوبیت

به منظور ارزیابی کارکردهای سیستم توصیه گر کوپن، ایجاد یک شاخص معیار که با عملکرد سیستم توصیه گر فعلی همبستگی داشته باشد لازم است. با این حال، فرایند توصیه کوپن فعلی رانمی توان به طور آفلاین

ارزیابی کرد زیرا توصیه‌ها از طریق انتخاب دستی خرده فروشان و تخفیفات رایج و محبوب انجام می‌شود. فهرست کوپن‌ها از طریق ایمیل روزانه و یا بازدیدهای صفحه اول وب سایت در اختیار همه کاربران قرار می‌گیرد. همه کاربران، فهرست یکسانی از کوپن‌ها را صرف نظر از سابقه خرید یا اولویت مشاهده می‌کنند. مقایسه مستقیم با این سیستم نیازمند انتشار هر دو روش‌های توصیه‌ای از طریق تست AB با مشتریان واقعی است.



شکل 2: انتخاب کوپن معیار مبتنی بر محبوبیت با در نظر گرفتن همه کوپن‌های معتبر قبل از تاریخ گردش خرید (بازدید)

به عنوان یک رویکرد جایگزین، ما یک ارزیابی معیار افلاین را بر اساس کوپن‌های محبوب پیشنهاد می‌کنیم که در آن میزان محبوبیت از نرخ کلیک استخراج می‌شود. علاوه بر معیارهای محبوبیت، سایر دلایل مربوط به کسب و کار در خصوص انتخاب تخفیف در شرایط فعلی وجود دارند، با این حال برای معیار و اهداف شبیه سازی، حق انتخاب کم‌تری در خصوص معیارهای محبوبیت داریم.

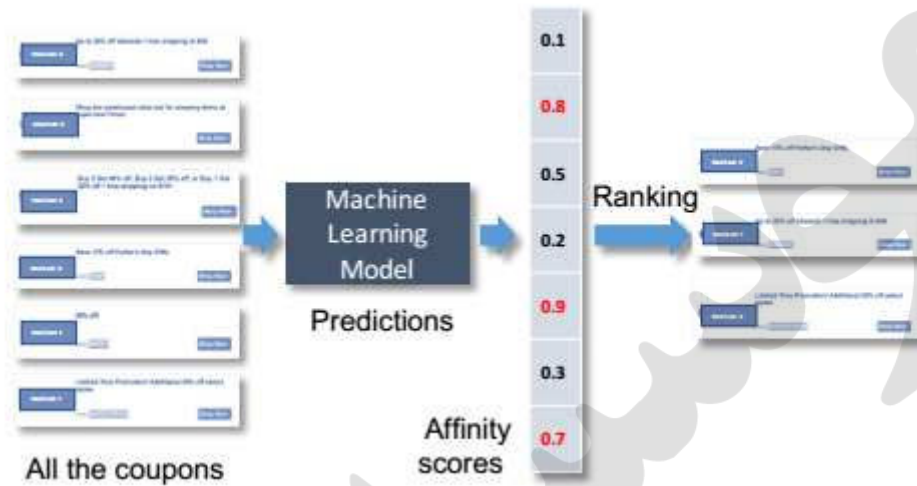
فرض بر این است که محبوبیت تعریف شده توسط کاربر با سیستم توصیه گر فعلی همبستگی دارد و احتمالاً بیانگر یک برآورد کران بالا از عملکرد است. در سطح بالاتر، دومعیار را ارائه می‌کنیم که محبوب‌ترین کوپن‌ها را براساس تنها داده‌های کلیک گذشته (PBB) و تنها بر اساس داده‌های کلیک آینده (God-View) (PBB) که بیانگر یک کران بالاتر قوی است انتخاب می‌کند.

همان طور که در شکل 2 گفته شد، مابدا بازدیدهای کاربران را به بخش‌های آموزشی و آزمایشی به ترتیب بانسبت 90 و 10 درصد تقسیم می‌کنیم. برای هر بازدید در مجموعه آزمایشی، ما مراحل زیر را انجام می‌دهیم:

- ما تاریخ کلیک هر بازدید را استخراج کردیم
 - از مجموعه آموزشی، همه بازدیدهای قبل از تاریخ کلیک را با یک کوپن معتبر استخراج کردیم (یعنی کوپن‌های غیر منقضی در زمان تاریخ کلیک)
 - ما فهرستی از کوپن‌ها را بر اساس نرخ کلیک مرتب کرده و N تا از محبوب‌ترین کوپن‌ها را انتخاب کردیم
 - در صورتی که کوپن در بازدید آزمایشی در N تا از محبوب‌ترین کوپن‌ها قرار گیرد ($N=10$)، یک تطبیق وجود داشته و به این ترتیب پیش بینی صحیح است، در غیر این صورت پیش بینی غلط است
- ایده کلی این است که فهرست سفارشی با محبوبیت بالا، انتخاب کارشناس از طریق شناسایی بهترین تخفیف را برای هر یک از روزهای مورد نظر در مجموعه آزمایشی شبیه سازی می‌کند. ما هم چنین، یک معیار قوی‌تر را تعریف می‌کنیم که در آن به اطلاعات نرخ کلیک آینده پس از بازدید تحت ارزیابی دسترسی داریم. با پیش بینی آینده، امکان ایجادیک معیاری که کران بالای معیار مبتنی بر محبوبیت در زمان توصیه فهرست یکسانی از تخفیفات به کل جمعیت کاربر می‌باشد وجود دارد. ما این معیار را *God-View PBB (GVPBB)* می‌نامیم.

2-5 زمان اجرا

شکل 3 معماری ساده شده سیستم زمان اجرا را نشان می‌دهد. لیستی از هزاران کوپن به سیستم توصیه گر ارسال می‌شود. برای هر عضو شرکت تجارت الکترونیک پاداش محور، هر جفت عضو/ تخفیف توسط سیستم توصیه گر ارزیابی شده و از نظر تشابه ارزیابی می‌شود. فهرست امتیاز حاصله برای رتبه بندی پیش بینی‌ها استفاده شده و سپس به 10 مورد برتر محدود شده و به صورت تبلیغات ایمیل شخصی و یا تخفیفات صفحه اول شخصی سازی شده استفاده می‌گردد.



مدل یادگیری ماشینی، پیش بینی، رتبه بندی، امتیازات وابستگی، همه کوپن‌ها

شکل 3: انتخاب و رتبه بندی کوپن‌های زمان اجرا

3- داده‌ها

ما از داده‌های جمع آوری شده از مشتریانی که مستقیماً بر روی تخفیفات منتشر شده کلیک کرده، و یا خرید الکترونیکی را در وب سایت‌های فروشنده انجام داده بودند و در نتیجه افزودن تخفیفات یا تخفیفات خودکار از طریق افزونه‌های دکمه مرور گر، استفاده کردیم.

داده‌ها شامل اطلاعات تاریخی در مورد کلیک مشتریان (یعنی گردش خرید) برای بازدید از وب سایت‌های خرده فروشان وابسته می‌باشند. داده‌ها برای یک سال نمونه برداری شده و به دلیل قوانین محرمانگی، به صورت ناشناس در نظر گرفته شدند. جدول 1 خلاصه‌ای از توزیع مجموعه داده‌های مختلف از جمله اعضای فعالی که بازدید انجام می‌دهند، تعداد بازدیدها، کوپن‌های کلیک شده و خرده فروشانی که تخفیف ارائه می‌کنند ارائه کرده است.

از ویژگی‌های بارز کوپن‌ها، توصیفات متنی (برای مثال، 25 درصد تخفیف برای تی شرت های شنای مردانه، زنانه پسرانه، دخترانه، بیش از 30 درصد تخفیف سبک فروش و 50 درصد اضافی از سبک فروش نهایی) و یک بازه تاریخی است که نشان دهنده اعتبار آن‌هاست (برای مثال از 12/18/2016 تا 12/27/2016). به طور اختیاری، کوپن‌ها به سه مقوله طبقه بندی شدند 1- درصد تخفیف (تنزیل)، 2- تخفیف پولی و 3- تخفیف با پیک (ارسال) رایگان برای برندها و محصولات خاص. به علاوه، آن‌ها مستقیماً اشاره به یک محصول یا خرده

فروش خاص دارند. اطلاعات خرده فروشان شامل نام کسب و کار (برای مثال آرایشی بهداشتی استیلا) و مقوله انتخابی (برای مثال سلامت و زیبایی) می‌باشد. جزییات مربوط به مجموعه داده‌های منفی در جدول 1 در بخش قبلی 1-2 توضیح داده شده‌اند.

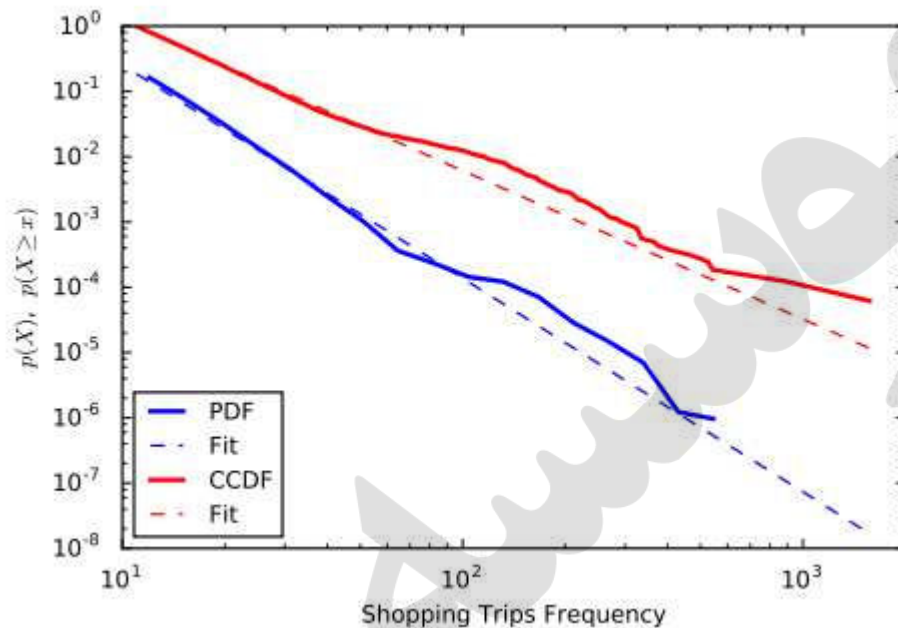
تعداد بازدهیها به ازای هر مشتری از توزیع احتمال قانون توان (1) پیروی می‌کند که در آن داده‌های دامنه سنگین دارای مقدار قابل توجهی از اطلاعات احتمال می‌باشند. شکل 4 تابع چگالی احتمال $p(X)$ (PDF) به رنگ آبی، تابع چگالی تجمعی مکمل $p(X \geq x)$ (CCDF) به رنگ قرمز و برازش توزیع قانون توان متناظر را با پارامترها $x_{min} = 1$ و $\alpha = 3.27$ نشان می‌دهد.

جدول 1: توزیع داده‌های بازدید خرید (گردش خرید) در مجموعه داده‌های متفاوت

خرده فروشان	کوین	بازدید خرید	اعضا	مجموعه داده‌ها
آموزش	15,276	1,037,030	448,055	
	7594	114,300	49,789	
آزمایش	9,705	11,666,592	358,444	
	8,190	1,285,875	39,831	
منفی آموزشی				
منفی آزمایشی				

جدول 2: تعداد داده‌ها و آماره‌های مربوط به مجموعه‌های سر، تنه و دم توزیع بازدهیهای خرید

میانگین	حداکثر	حداقل	درصد	بازدهیهای خرید	اعضا	مجموعه داده
15.79	1,569	8	28.7%	317,623	25,149	سر
4.17	7	3	39.8%	441,533	132,337	تنه
1.31	2	1	31.5%	349,262	333,686	دم



فراوانی بازدید خرید

شکل 4: تابع چگالی احتمال ($p(x)$ آبی) و تابع چگالی تجمعی مکمل ($p(X \geq x)$ قرمز) با برازش توزیع توان

پایین برای $\alpha = 3.27$ و $x_{min} = 1$

بر اساس فراوانی (تعداد) بازدیدهای خرید (به جدول 2 مراجعه کنید)، داده‌ها را به سه بخش تقسیم کردیم. 1- سر که شامل فعال‌ترین اعضا با بیش از 8 بازدید خرید 2- تنه که شامل اعضای با یک نرخ کلیک بین 2 و 7 است و 3- دم، برای افراد با کم‌ترین فعالیت با نرخ کلیک 1 یا 2

این گونه تقسیم بندی داده‌ها در بخش 2-4 برای ارزیابی مسئله شروع سرد مبتنی بر کاربر ارائه خواهد شد.

4- آزمایشات

به منظور ایجاد و ارزیابی جنگل‌های تصادفی، XGboost، و مدل‌های معیار، داده‌ها بر اساس اعضا با استفاده از 90 درصد جمعیت برای آموزش و 10 درصد برای آزمایش تقسیم شده و مجموعه‌های بازدی‌های خرید استخراج شد. تقسیم بندی بر اساس اعضا به جای بازدیدها موجب افزایش شانس پوشش دادن قابلیت‌های تعمیم مدل می‌شود زیرا تاریخچه بازدید خرید کاربران آزمایشی موجب ارزیابی در داده‌های آموزشی نمی‌شود. برای نمونه‌های منفی، که در بخش 1-2 گفته شد، ما 9 بازدید خرید منفی را برای هر نمونه مثبت انتخاب می‌کنیم.

برای پوشش دادن وابستگی کاربران/ کوپن‌ها، تعدادی از ویژگی‌ها نظیر ویژگی‌های کوپن و کاربران و نیز ویژگی‌های تاریخچه خرید را آزمایش کردیم. خلاصه‌ای از آن‌ها در زیر آمده است

- ویژگی‌های مبتنی بر کاربر

1- دستگاه‌های مورد استفاده

2- سیستم OS

3- دامنه ایمیل

- ویژگی‌های مبتنی بر کوپن

1- توصیف متن

2- خرده فروش اصلی

3- مقوله خرده فروش

4- اطلاعات تخفیف (ارسال رایگان، تخفیف دلار، تخفیف درصد)

5- اطلاعات کش بک

- ویژگی‌های مبتنی بر تاریخچه و سابقه بازدید خرید

1- تعداد دفعات قبلی بازدید کاربر از این کوپن

2- خرده فروشانی که اخیراً بازدید شده‌اند

3- اطلاعات اخیر مربوط به تخفیف

4- اطلاعات اخیر مربوط به کش بک یا تخفیف نقدی

5- کلمات کلیدی اخیر مربوط به کوپن (از توصیفات)

6- مقوله‌های خرده فروش

7- خریدهای لوکس اخیر

در مرحله پیش پردازش داده‌ها، ما متن را بر اساس فراوانی کلمات کلیدی و سابقه رفتار خرید اعضا رمز گذاری کرده و ویژگی‌های مقوله‌ای را به صورت مدل بردار وان هات دسته بندی کردیم. همه ویژگی‌های دیگر یابه صورت مقادیر دودویی یا مقادیر عددی در نظر گرفته می‌شوند. چون هر دوی مدل‌های RF و XGBoost به

تبدیل ویژگی‌های یکنواخت غیر حساس است، ما از استاندارد سازی و نرمال سازی عددی اجتناب کردیم. ما به طور دقیق نرمال سازی اطلاعات مفقود را مدیریت کرده و متن مفقود را با برچسب unk و هر دو ویژگی‌های مقوله‌ای و عددی را با 0s جایگزین کردیم. پس از پیش پردازش، بهینه سازی جست و جوی شبکه جزئی برای مجموعه‌ای از ابر پارامترهای مهم، عمیق حداکثر درخت و تعداد تخمین گرها به ترتیب تا 15 و 1000 اجرا کردیم. ما از پیاده تخمین گر scikit-learn (19) از درخت جنگل تصادفی و XGboost استفاده کردیم.

1-4 نتایج

جدول 3 نتایج آزمایشی را برای مدل‌های یادگیری ماشینی و معیارها نشان می‌دهد. ما عملکرد را با محدود کردن فهرست پیش بینی رتبه بندی شده به 10 آیتم ارزیابی کردیم. مدل RFC قادر به پیش بینی نرخ کلیک برای 96.80 درصد کوپن‌های تست شده (صحت) می‌باشد، در حالی که XGboost با پیش بینی کلیک صحیح 95.85 درصد و درصد فراخوانی 0.83 درصد برخوردار است. این موجب می‌شود تا نرخ کلیک پیش بینی شده XGboost برابر با 8.30 درصد باشد. هر دوی PBB و GVPBB از فراخو. انی پایین رنج می‌برد زیرا لیست‌های محبوب برای همه کاربران یکسان هستند.


جدول 3: دقت (P)، فراخوانی (R)، شاخص (F)F و نرخ کلیک برای طبقه بندی جنگل تصادفی (RFC)، XGboost، معیار مبتنی بر محبوبیت (PBB) و GVPBB با حداکثر ده کوپن. روش‌های معیار با (*) نشان داده شده‌اند.

Model	P	R	F	NDCG@10	CTR
PBB*	0.91	0.12	0.21	0.776	1.20%
GVPBB*	0.83	0.34	0.48	0.892	3.40%
XGBoost	0.77	0.83	0.80	0.857	8.30%
RFC	0.93	0.78	0.85	0.969	7.80%

به طور کلی، هر دوی XGboost و RFC عملکرد بهتری از ماتریس‌های معیار نشان دادند. علاوه بر دقت، فراخوانی و F، ما متریک بهره جمعی تنزیل یافته نرمال (14) را برای فهرستی از 10 تخفیف ایجاد شده با ترکیب 1 نمونه مثبت با 9 نمونه منفی تصادفاً انتخاب شده گزارش کردیم. NDCG یک شاخص کیفیت رتبه

بندی می‌باشد که موقعیت آیتم‌های کلیک شده را در نظر می‌گیرد. به طور کلی، نمونه‌های مثبت بایستی بالاتر از نمونه‌های منفی رتبه بندی شوند

سپس ماقدام به ارزیابی کیفیت امتیازات برآورد شده با مدل RFC کردیم. احتمالات پیش بینی شده با واسنجی خوب از اهمیت زیادی در زمان استفاده از امتیازات مدل طبقه بندی برای رتبه بندی برخوردارند (18).



شکل 5: منحنی واسنجی احتمال برای مدل RFC. محور X: مقدار پیش بینی شده میانگین، محور Y: کسری از نمونه‌های مثبت

نمودار کالیبراسیون (واسنجی) اطمینان در شکل 5 نشان می‌دهد که مدل RFC دارای یک ارزیابی جزئی حول مقدار پیش بینی شده 0.2 و 0.6 است با این حال به طور کلی این منحنی از رفتار ایده آل با تقلید از خط اریب پیروی می‌کند.

4-2 ارزیابی شروع سرد مبتنی بر کاربر

وقتی که اعضای جدید به سیستم پاداش محور یا تخفیفات جدید ارائه شده توسط خرده فروشان ملحق می‌شوند، سیستم‌های توصیه گر تحت تأثیر پراکندگی داده‌های جدید قرار می‌گیرد که عملکرد پیش بینی را با ارزیابی مواجه می‌سازد (19). به منظور حل این مسئله، یک راهبرد انتخاب متفاوت برای دامنه توزیع استفاده

می‌شود (روش‌های ترکیبی) (19). با این حال، ما برای پوشش دادن اطلاعاتی که با حداقل تاریخچه بازدید خرید تعمیم داده می‌شود، متکی به ویژگی‌های مبتنی بر کوپن و کاربر هستیم.

ما اقدام به ارزیابی مدل RFC با سه بخش از توزیع بازدید خرید کردیم (به بخش 3 مراجعه کنید). جدول 4 نتایج این آزمایش را نشان می‌دهد.

جدول 4: دقت (P)، فراخوانی، شاخص (f)F، نرخ کلیک و NDCG@10 برای مدل RFC در زمان تست کاربران

در بخش‌های دم، تنه و سر توزیع بازدید خرید

Data set	P	R	F	NDCG@10	CTR
Head	0.95	0.77	0.85	0.980	7.70%
Torso	0.94	0.79	0.86	0.985	7.90%
Tail	0.90	0.78	0.84	0.976	7.80%

به طور میانگین، مدل RCF یک مدل کاملاً قوی در سه بخش توزیع است. هنگام تحلیل شاخص‌های پیش بین ویژگی‌های اصلی، تعداد دفعات کلیک بر روی کوپن، از اثرات پیش بینی هستند با این حال تحقیقات بیشتری برای درک بهتر اثرات متقابل ویژگی‌ها لازم است.

6- کارهای مرتبط

مطالعات زیاد انجام شده در خصوص سیستم‌های توصیه گر بر بازخورد صریحی متمرکز است که در آن کاربران اولویت خود را با ارزیابی‌ها (نظر دهی) (10-22) بیان می‌کنند. اخیراً طیف وسیعی از مطالعات انجام شده‌اند که از داده‌های بازخورد ضمنی فراوان استفاده کرده‌اند (3-11-13). با این حال بیشتر این کارها، مسئله را به صورت مدل فیلترینگ مشارکتی چارچوب بندی کرده‌اند. CF به شدت به مسئله شروع سرد حساس است و برای مدیریت آیتم‌های بسیار فرار نظیر کوپن‌ها و تخفیفات آنلاین، فرار است. به علاوه گنجاندن ویژگی‌هایی که خصوصیات کاربران و آیتم‌ها را پوشش می‌دهند سخت است.

سیستم توصیه گر ترکیبی در (11) نزدیک‌ترین سیستم به مطالعه ماست. برای حل مسئله شروع سرد، آن‌ها از بازخورد ضمنی برای توصیه کوپن‌های آنلاین با تلفیق اطلاعات کاربر و ویژگی‌های آیتم‌ها استفاده می‌کنند. در این مطالعه، ماتریس فیلترینگ مشارکتی سنتی، از جمله کاربران و آیتم‌ها، با ویژگی‌های آیتم و کاربر و svd

غنی می‌شوند. با این وجود، سیستم ترکیبی نشان می‌دهد که در آن یک کوپن یا کاربر جدید وجود دارد. در هر صورت، هزاران کوپن جدید در هر روز وجود دارد و آموزش مجدد اغلب غیر عملی است.

مطالعه ما با رویکردهای فیلترینگ مبتنی بر محتوی نظیر (2-8) متناسب است. روش‌های CBF قادر به خلاصه سازی آیتم‌ها بوده و بیانگر اثرات متقابل کاربر/آیتم با رمز گذاری سابقه بازدید خرید می‌باشد. هنگام افزودن تخفیفات جدید، هیچ گونه نیازی به آموزش مجدد نیست، اگرچه استفاده از خرده فروشان جدید نیازمند آپدیت مدل برای پوشش دادن روابط وابستگی کاربر/آیتم جدید بیان شده در بازدیدهای خرید جدید است. بر عکس مدل‌های مبتنی بر CF و SVD، رویکرد مبتنی بر محتوی قادر به استفاده از فنون طبقه بندی مختلف بوده و می‌توانند با CF ترکیب شوند.

6- نتیجه گیری

در این مطالعه، ما یک سیستم توصیه گر کوپن را با فیلترینگ مبتنی بر محتوی توسعه دادیم. ما دو معیار مبتنی بر محبوبیت را آزمایش کردیم و آن‌ها را با هر دو مدل طبقه بندی درخت افزایش گرادیان و جنگل تصادفی مقایسه کردیم. برای حل مسئله طبقه بندی یک طبقه‌ای، چارچوب ما به طور خودکار نمونه‌های منفی را از بازدیدهای خرید مشتریان استخراج کردیم. نمونه‌های منفی، سناریوی انتخاب منفی را شبیه سازی می‌کنیم که در آن یک کوپن، نسبت به ده کوپن، به طور واقعی توسط اعضا انتخاب می‌شود. در این شرایط آزمایشی، هر دو دسته بند XGboost و جنگل‌های تصادفی بهتر از دومعیار دیگر به جز متریک NDCG10 انجام می‌شوند. در آینده، برای بهبود نتایج رتبه بندی، ما مدل‌های طبقه بندی را با توابع هزینه مبتنی بر لیست و مبتنی بر زوج توسعه می‌دهیم. هم چنین، ما مدل‌های خود را تحت ارزیابی‌های تست A/B با مشتریان واقعی ارزیابی و اعتبار سنجی می‌کنیم.