

مروری بر روش های موافقه با تغییرات زمانی در دسته بندی متن

مرضیه سپهر^۱, مرتضی بارای^۲, سمیه کافی^۳

^۱دانشجوی کارشناسی ارشد مهندسی کامپیوتر، دانشگاه صنعتی مالک اشتر

^۲استادیار مجتمع فناوری اطلاعات و ارتباطات، دانشگاه صنعتی مالک اشتر

^۳دانشجوی دکترا مهندسی کامپیوتر، دانشگاه صنعتی مالک اشتر

مسئول مکاتبات: مرضیه سپهر

چکیده

رشد سریع اطلاعات به خصوص رشد سریع وب، دسته بندی متون را به صورت دستی غیرممکن می کند. از این جهت دسته بندی خودکار متن به عنوان یکی از زمینه های تحقیقاتی مهم مورد توجه محققین قرار گرفته است. در دسته بندی متن عموماً داده ها به صورت آفلاین جمع آوری شده و آموزش بر روی این آن ها انجام می شود سپس مدل آموزش دیده به این روش، می تواند برای پیش بینی داده های دیده نشده و رودی مورد استفاده قرار بگیرد. اما در دنیای واقعی متون مدام در حال به روز رسانی هستند و توزیع داده ها و مفاهیم متنی به مرور زمان مستخوش تغییر می شوند به طوری که موجب اثرباری بر روی عملکرد دسته بند می شوند. در این تحقیق، ابتدا به دسته بندی انواع تغییرات ممکن در طول زمان، روش های تشخیص آن و سپس انواع روش های موافقه با تغییرات زمانی در دسته بندی متون پرداخته شده است و سپس به مقایسه روش ها با توجه به نوع تغییرات پرداخته شده است.

کلمات کلیدی: دسته بندی متن، زمان در دسته بندی متن، اثرات زمانی

۱. مقدمه

رشد سریع اطلاعات به خصوص رشد سریع وب، دسته بندی متون موجود را به صورت دستی غیرممکن می کند. از این جهت دسته بندی خودکار متن به عنوان یکی از زمینه های تحقیقاتی مهم مورد توجه محققین قرار گرفته است. هدف از دسته بندی خودکار متن اختصاص خودکار متن، به دسته های از پیش تعیین شده، با توجه به محتوای آن هاست (Sebastiani ۲۰۰۲). در دسته بندی متن عموماً داده ها ابتدا به صورت آفلاین جمع آوری شده و آموزش بر روی آن ها انجام می شود سپس مدل آموزش دیده به این روش، می تواند برای پیش بینی داده های دیده نشده و رودی مورد استفاده قرار بگیرد. در شرایطی که داده ها مدام در حال به روز رسانی هستند، توزیع آنها می تواند در طول زمان تغییر کند به طوری که موجب اثرباری بر روی عملکرد دسته بند شود. لذا مفهوم زمان را می توان به عنوان یک بعد از اطلاعات در نظر گرفت.

دو تعریفی که مرجع (Alonso, Gertz et al. ۲۰۰۷) از مفهوم زمان در بازیابی اطلاعات دارد بدین شرح است: ۱) یک فاصله که دو نقطه تاریخ را در یک زنجیره تاریخی از هم جدا می کند. ۲) یک زنجیره که در آن وقایع در یک توالی تغییر ناپذیر از گذشته، حال و تا آینده رخ می دهد. در تعریف دوم مظنو از واقعه یا رخداد^۱ یک اتفاق است که به اندازه کفايت رخ می دهد به نحوی که در داده ها تاثیر گذار باشد، مثل یک گردهمایی یا فعالیت اجتماعی مانند انتخابات. بر این اساس، زمان، یک پارامتر تاثیر گذار در کاربردهای بازیابی اطلاعات به حساب آمده و تغییرات و نحوه موافقه با آن در تحقیقات به عنوان مختلف مورد بررسی قرار گرفته است.

دسته ای از تحقیقات از این تغییرات با عنوان رانش مفهوم^۲ (Forman ۲۰۰۶, Šilić and Bašić ۲۰۰۹, Nishida and Yamauchi ۲۰۰۸, Rocha, Mourão et al. ۲۰۱۰, Mourão, Rocha et al. ۲۰۱۴) و دسته ای دیگر با تغییر زمانی^۳ (D'hondt, Verberne et al. ۲۰۰۸, Rocha, Mourão et al. ۲۰۱۰, Salles, Rocha et al. ۲۰۱۳) یاد کرده اند. بر اساس تحقیقات انجام شده در این مقاله، تفاوت اصلی بین دسته ای اول و دسته ای دوم مشاهده شد. فرض اصلی دسته ای اول این است که داده ها به ترتیب زمانی ذخیره نشده اند و داده های آزمایشی همیشه جدیدتر از داده های آزمایشی هستند (Rocha, Mourão et al. ۲۰۱۳). بر خلاف دسته ای دوم که فرض می کند داده های آزمایشی می توانند از هر بازه زمانی باشند. در تحقیقات دسته ای اول، داده های مورد بررسی اغلب جریان داده های متنی^۴ هستند. در حالی که تحقیقات دسته ای دوم اغلب بر روی داده های متنی معمولی کار

¹ Event

² Concept drift

³ Temporal variation

⁴ جریان داده دنباله ای پیوسته از داده ها است که به همان ترتیب دریافت مورد دسترسی قرار می گیرند.

کردند. تحقیقات دسته‌ی اول اغلب سعی در شناسایی دقیق زمان تغییر و نوع تغییر داشته و سپس برای مواجهه با تغییر روشی را پیشنهاد داده اند در حالی که در تحقیقات دسته‌ی دوم عموماً از روش‌های ابتکاری و یا پیشفرضها برای تعیین زمان مواجهه با تغییر استفاده کرده‌اند. در این تحقیق سعی شده تا حد امکان یک دید کلی و همه جانبه در این زمینه‌ی اثر زمان در دسته‌بندی خودکار متن و بررسی روش‌های مواجهه با آن ارائه شود. باید توجه داشته که پیش از بررسی روش‌های مواجهه با تغییر، ابتدا به سه سوال مهم باید پاسخ داده شود:

- اثرگذاری تغییرات زمانی به چه نحوی قابل مشاهده هستند؟
- تغییرات زمانی به چه تناوبی رخ می‌دهند؟
- چه زمانی باید نسبت به تغییرات عکس العمل نشان داد؟

بر این اساس، در تحقیق حاضر ابتدا به سه سوال مذکور به ترتیب در بخش‌های دوم، سوم و چهارم پاسخ داده می‌شود و سپس در بخش پنجم به بررسی روش‌های مواجهه با تغییر پرداخته خواهد شد. در بخش پنجم به مقایسه‌ی روش‌ها با توجه به نوع تغییرات پرداخته شده است و در نهایت نتیجه‌گیری ارائه می‌گردد.

۲. اثرات زمانی

از یک دیدگاه تغییرات زمانی را می‌توان بر اساس نحوه اثرگذاری آن به ۳ دسته تقسیم کرد (D'hondt, Verberne ۲۰۱۳Rocha, Mourão et al. et al)

- تغییر در توزیع کلاسها^۱
- تغییر در توزیع کلمات^۲
- تغییر در شباهت کلاسها^۳

در دسته‌ی اول از این نوع تغییر، گذر زمان موجب تغییر در توزیع کلاس‌ها می‌شود. یعنی ممکن است دسته‌هایی از بین بروند یا دسته‌های جدیدی به وجود آیند. علت این مسئله تقسیم شدن یک دسته به دسته‌های کوچکتر و یا ادغام چند دسته با یکدیگر است. برای مثال در ساختار سلسله‌مراتبی موضوعات زیرمجموعه‌ی علوم کامپیوتر در پایگاه ACM ، در سال ۱۹۶۴ دو موضوع بازیابی اطلاعات و هوش مصنوعی متعلق به یک کلاس برنامه‌های کاربردی بودند ولی در حال حاضر هر کدام به ترتیب متعلق به کلاس‌های سیستمهای اطلاعاتی^۴ و روش‌های محاسباتی^۵ هستند.

گاهی اوقات با گذر زمان، کلمات ممکن است در دسته‌ی خاصی از متون وارد شوند، از یک دسته خارج شوند، از دسته‌ای به دسته‌ی دیگر مهاجرت کرده و یا اینکه وزن آن‌ها در یک دسته تغییر کند. در مرجع (Wenerstrom and Giraud-Carrier ۲۰۰۶) از این نوع تغییر با نام تغییر متنی^۶ نام برده شده است. انتقال کلماتی مانند انژری هسته‌ای، غنی سازی، سانتیفیوژها وغیره از دامنه‌ی فیزیک به دامنه‌ی اخبار سیاسی در چند سال اخیر مثالی از مهاجرت کلمات از دسته‌ای به دسته‌ی دیگر است و ورود کلماتی مانند یارانه در دامنه‌ی اخبار سیاسی در زبان فارسی را می‌توان مثالی از ورود کلمات جدید به یک کلاس دانست.

تغییر در شباهت کلاس‌ها اشاره دارد به تکامل تدریجی شباهت بین کلاس‌ها در طول زمان. برای مثال در گذشته، دسته‌ی جرم‌شناسی و بیولوژی به هم شباهتی نداشتند. اما اخیراً به علت استفاده از علم بیولوژی در شناسایی مجرمین این دو دسته به هم ارتباط بیشتری پیدا کرده‌اند. لازم به ذکر است که تغییر در شباهت کلاس‌ها به معنی تغییر در توزیع کلمات بین دو کلاس متفاوت است درحالی که تغییر در توزیع کلمات به تغییر کلمات درون یک کلاس اشاره دارد که می‌تواند منجر به افزایش شباهت بین دو کلاس نیز بشود.

۳. انواع تغییر

از دیدگاهی دیگر می‌توان تغییرات زمانی را بر اساس دوره‌ی تناوب آن به ۳ دسته‌ی زیر، تقسیم کرد (D'hondt, Verberne et al. 2014):

- تغییر ناگهانی^۷
- تغییر تدریجی^۸
- تغییر بازگشت کننده^۹

¹ Class distribution

² Term distribution

³ Class similarity

⁴ Information system

⁵ Computing Methodologies

⁶ Contextual drift

⁷ Sudden drift

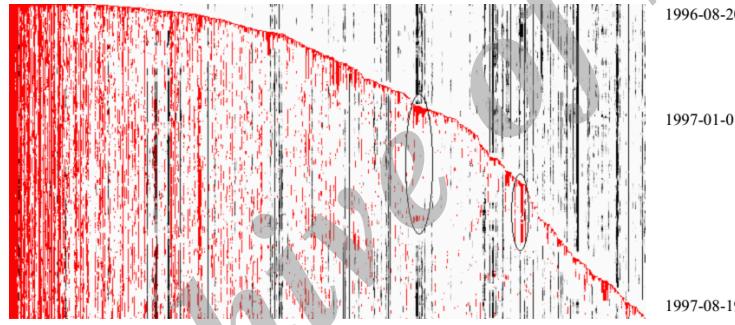
⁸ Gradual

⁹ Recurrent

در تغییرات ناگهانی لحظاتی وجود دارد که در آن توزیع داده در پیکره (توزیع کلاس یا کلمات) به صورت قابل ملاحظه‌ای تغییر می‌کند. این نوع تغییرات در سیستم‌هایی که اطلاعات را متناسب با علاقه‌ی کاربر فیلتر می‌کنند، رایج است. در چنین سیستم‌هایی تغییر ناگهانی علاقه‌ی کاربر موجب کاهش عملکرد سیستم می‌شود. در بعضی از تحقیقات از این نوع تغییر با نام تغییر جهت مفهوم^۱ یاد شده است (Nishida and Yamauchi ۲۰۰۹).

در تغییرات تدریجی نرخ تغییر بایین است. در ساده ترین حالت تغییر تدریجی، نمونه‌های آموزشی از P_j+1 توزیع P_j و P_j+2 تشکیل شده‌اند و به مرور زمان، احتمال مشاهده مثال‌هایی با توزیع P_j کاهش و احتمال مشاهده مثال‌هایی با توزیع P_{j+1} افزایش می‌ابد. نوع دیگری از تغییر تدریجی، تغییر افزایشی^۲ است که در آن داده‌ها از بیش از دو نوع توزیع تشکیل می‌شوند. در این نوع از تغییر تفاوت بین توزیع‌ها بسیار کم است و تغییرات در دوره‌ی طولانی‌تری از زمان دیده می‌شوند (Brzezinski and Stefanowski ۲۰۱۴). بعضی از مراجع تغییرات افزایشی را دسته‌ای جدا از تغییرات تدریجی در نظر گرفته اند (Ditzler ۲۰۱۲). تغییرات بازگشت‌کننده، هر چند وقت یکبار رخ داده و موجب تغییر در مفاهیم وبا توزیع آن‌ها می‌شوند ولی پس از چندی مجدداً مفاهیم قدیمی تکرار می‌شوند و این سیر ادامه پیدا می‌کند (Gama, Žliobaitė et al. ۲۰۱۴). به عقیده‌ی (Forman ۲۰۰۶) این نوع تغییر بیشتر در متون خبری رخ می‌دهد. هر چند بررسی‌های حاصل از تحقیق (Šilić and Bašić ۲۰۱۱) نشان از تغییرات تدریجی در متون خبری است. لذا تشخیص نوع تغییر به پیکره مورد بررسی واپسی است و نیاز به انجام آزمایشات بر روی پیکره مورد نظر دارد.

برای تشخیص این نوع تغییرات معمولاً از روش‌های بصری استفاده می‌شود. برای مثال در مرجع (Forman ۲۰۰۶) برای این منظور یک نمایش بصری جدید از فضای ویژگی ارائه شده است. روش مذکور به این صورت است که با داشتن مجموعه‌ی کل کلمات در تمام روزها (مثلاً برای مدت یک سال)، کلمات بر اساس تاریخی که اولین بار در ۱۰۰ ویژگی برتر دیده شدند مرتب می‌شوند، سپس تصویری تشکیل داده می‌شود که در آن ستون‌ها نماینده‌ی کلمات و سطرها نماینده‌ی روزها هستند و ترتیب روزهای این نحو است که از بالای تصویر به سمت پایین تصویر، به تاریخ روزها افزوده می‌شود. یک پیکسل به شرطی به رنگ قرمز آید که کلمه‌ی مربوط به ستون آن پیکسل در آن روز، جزو ۱۰۰ کلمه‌ی برتر باشد. وگرنه بر اساس میزان اهمیت، به رنگی در طیف سیاه و سفید درمی‌آید به طوری که هر چقدر مشکل‌تر باشد بی‌اهمیت‌تر و هر چه سفیدتر باشد با اهمیت‌تر است. شکل ۱ یکی از تصاویر حاصل از روش مذکور در مرجع (Forman ۲۰۰۶) را نشان می‌دهد.



شکل ۱: نمایش تغییر توزیع کلمات در مرجع (Forman ۲۰۰۶)

در این شکل، مرز قرمز رنگی که از پیکسل‌ها به وجود آمده زمانی را نشان می‌کند که هر یک از کلمات برای اولین بار در ۱۰۰ کلمه‌ی برتر روبرو شده‌اند. این نمایش بصری کمک می‌کند تا نرخ تغییر و نوع تغییر به موضوع مشاهده شود. برای مثال قسمت‌هایی از تصویر که در آن، در یک ستون بعد از چند پیکسل قرمز پیکسل‌های سیاه رویت شده اند نشان دهنده‌ی کاهش اهمیت کلمات مهم بعد از چند روز است و بر عکس، قسمت‌هایی که چندین پیکسل عمودی پیوسته از رنگ قرمز دیده می‌شود یعنی کلمه‌ی مربوط به ستون مذکور در طی چند هفته مدام استفاده شده است (بیضی سمت راست در شکل). همینطور برای تشخیص نوع تغییر نیز با مشاهده‌ی رنگ قرمز در یک ستون به صورتی که در بیضی سمت چپ در تصویر نشان داده شده است می‌توان به یک تغییر بازگشت‌کننده پی برد.

در مرجع (D'hondt, Verberne et al. ۲۰۱۴) برای تشخیص تغییر بازگشت‌کننده و تدریجی از دو آزمایش متفاوت استفاده شده است. برای تشخیص تغییر تدریجی، توزیع دسته‌های مختلف در طول سال‌های متوالی بررسی می‌شود. منطق نویسنده این است که اگر بین دو سال متالی اندازه‌ی یک دسته تغییر چندانی نداشته باشد، ولی در طول یک دوره‌ی طولانی از زمان، اندازه‌ی آن دسته به طور قابل ملاحظه ای رشد داشته باشد، تغییر داده‌های مربوط به آن دسته تدریجی است. برای تشخیص تغییر بازگشت‌کننده، توزیع کلمات در سال‌های مختلف و برای هر کلاس به صورت جداگانه بررسی می‌شود.

در مقاله‌ی (Šilić and Bašić ۲۰۱۲) برای شناسایی انواع تغییرات ابتدا انواع روش‌های نمونه‌برداری داده‌های آموزشی و آزمایشی از کل داده‌ها ارائه شده است و سپس با بررسی میزان عملکرد دسته‌بندهای ساخته شده بر روی انواع نمونه‌برداری‌ها، نوع تغییر موجود در پیکره مورد بررسی تشخیص

¹ Concept shift

² Incremental

داده شده است. بیشتر روش‌های مواجهه با تغییرات محدود به نوع خاصی از تغییر می‌شوند، در حالی که در واقعیت اغلب ترکیبی از چنین تغییراتی رخ می‌دهد.

۴. انواع روش‌های تشخیص تغییر

بسیاری از الگوریتم‌هایی که برای تطبیق با تغییرات زمانی ارائه شده اند، از یک مدل به روز رسانی ساده استفاده می‌کنند(Katakis, Tsoumacas et al. ۲۰۰۶). به این ترتیب که به محض ورود یک داده به سیستم، به روز رسانی مدل انجام می‌شود. در حالی که این روش‌ها هزینه‌ی بالای دارند. راه دیگر، تشخیص زمان تغییرات و بهروزرسانی مدل در صورتی است که این تغییرات قابل توجه باشند(Tsymbolal ۲۰۰۴). در حقیقت هدف از تشخیص تغییر، شناسایی نقاط و یا بازه‌هایی است که در طول آنها تغییر رخ می‌دهد. در حالت کلی تشخیص تغییر می‌تواند با نظارت و بررسی داده‌ی خام صورت گیرد یا اینکه بر اساس عملکرد حاصل از دسته‌بند انجام شود. بر اساس دسته‌بندی انجام شده در (Gama, Žliobaitė et al. ۲۰۱۴) به طور کلی تشخیص‌دهنده‌های تغییر به سه دسته تقسیم می‌شوند:

۴.۱. تشخیص دهنده‌های مبتنی بر آنالیز ترتیبی

در این روش ابتدا فرض می‌شود که X_1^n یک توالی از نمونه‌های است که در آن زیرمجموعه‌ای از نمونه‌ها مثل $X_1^w \dots X_n^w$ (۱) از یک توزیع مانند P_0 و P_1 زیرمجموعه‌ی دیگر از نمونه‌ها X_w^n (یعنی سایر نمونه‌ها) از توزیعی مانند P_1 تولید شده اند. زمانی که توزیع مثال‌ها در نقطه‌ای مانند W از P_0 به تغییر می‌کند، انتظار می‌رود احتمال مشاهده‌ی زیردنباله‌ای با توزیع P_1 به شدت بالاتر از زیردنباله‌ای با توزیع P_0 شود. میزان شدت باید طوری باشد که نسبت دو احتمال از یک حد آستانه کمتر نباشد. با فرض اینکه نمونه‌های X_i از هم مستقل باشند، یک شاخص آماری برای آزمودن این فرضیه که آیا W نقطه‌ی تغییر است یا نه بر اساس رابطه(۱) محاسبه می‌شود:

$$T_w^n = \log \frac{P(x_w \dots x_n | P_1)}{P(x_w \dots x_n | P_0)} = \sum_{i=w}^n \log \frac{P_1[x_i]}{P_0[x_i]} = T_w^{n-1} + \log \frac{P_1[x_n]}{P_0[x_n]} \quad (1)$$

در این رابطه اگر $T_w^n > L$ باشد آنگاه تغییر تشخیص داده می‌شود. L یک حد آستانه تعريف شده توسط کاربر است.

۴.۲. تشخیص دهنده‌های مبتنی بر جداول کنترلی

جدوال کنترل، یادگیری را به عنوان یک فرآیند در نظر می‌گیرند و تکامل این فرآیند را بر اساس میزان رخداد خطای پیشگویی‌های انجام شده توسط یادگیرنده نظارت می‌کنند (Nishida and Yamauchi ۲۰۰۹). براساس این نظارت سیستم در یکی از ۳ حالت تحت کنترل، خارج از کنترل و وضعیت هشدار قرار خواهد گرفت. وضعیت سیستم تا زمانی تحت کنترل است که خطای سیستم ثابت باشد؛ و این یعنی نمونه‌ی آزمایشی ورودی از همان توزیعی آمده است که نمونه‌های قبلی آمداند. وضعیت خارج از کنترل وضعیتی است که خطای طور قابل ملاحظه‌ای در مقایسه با نمونه‌های اخیر افزایش داشته است. لذا به احتمال ۹۹ درصد نمونه‌ی آخر با توزیع متفاوتی نسبت به نمونه‌های قبلی آمده است. وضعیت هشدار حالتی بین دو وضعیت قبلی است. خطای این حالت در حال افزایش است ولی هنوز خارج از کنترل نشده است. افزایش خطای در این حالت ممکن است به علت نویز، کاهش عملکرد مدل پیشگویانه به صورت مقطعي و یا تغییر واقعی باشد. در این وضعیت تعداد بیشتری مثال نیاز است تا بتوان به یک نتیجه‌ی قطعی رسید و تشخیص داد افزایش خطای حاصل از نویز است یا تغییر واقعی. با توجه به توضیحات مذکور، با توجه به فاصله‌ی زمانی بین وضعیت هشدار و وضعیت خارج از کنترل می‌توان نرخ تغییر را مشخص کرد. اگر فاصله‌ی زمانی بین وضعیت هشدار و وضعیت خارج از کنترل کم باشد نشان‌دهنده‌ی سرعت بالای تغییر است و اگر این فاصله زیاد باشد نشان از سرعت پایین تغییر دارد.

۴.۳. تشخیص دهنده‌های مبتنی بر نظارت بر توزیع پنجره‌های زمانی

این روش‌ها عموماً از یک پنجره‌ی مرجع با اندازه‌ی ثابت استفاده می‌کنند که شامل داده‌های قدیمی می‌شود و از یک پنجره‌ی لغزنده استفاده می‌کنند که حاوی جدیدترین نمونه‌ها هستند. مقایسه‌ی بین دو پنجره از مقایسه‌ی بین شاخص‌های آماری توزیع دو پنجره انجام می‌شود. اگر هر دو پنجره دارای شاخص‌های آماری یکسانی نباشند، شروع پنجره‌ی لغزنده به عنوان محل تغییر تعیین می‌شود. شاخص آماری مذکور می‌تواند از روی داده‌های خام و یا عملکرد مدل آموزشی تعریف شود. دو پنجره‌ی مذکور برای مقایسه اینکه اندازه‌ی پنجره‌ی لغزان می‌تواند به صورت تصاعدی رشد کند. نویسنده‌گان مرجع (Kifer, Ben-David et al. ۲۰۰۴) از معیار Chernoff bound برای مقایسه ای آماری توزیع دو پنجره استفاده کرده اند. تحقیق (Vorburger and Bernstein ۲۰۰۶) یک معیار مبتنی بر آنتروپی ارائه کرده است تا تفاوت بین توزیع دو پنجره را نشان دهد. در این روش اگر توزیع دو پنجره مساوی باشد، آنگاه آنتروپی برابر ۱ می‌شود و اگر توزیع‌ها مساوی نباشند مقدار آنتروپی برابر صفر می‌شود. در این روش شاخص آنتروپی به صورت مداوم و در طول زمان نظارت می‌شود و اگر این شاخص از یک حد آستانه‌ی تعریف شده توسط کاربر پایین‌تر بروند نشان‌دهنده‌ی یک تغییر است. در تحقیق (Bach and Maloof ۲۰۰۸) از دو مدل با نام‌های مدل پایدار و مدل واکنشی استفاده شده است. مدل پایدار بر اساس داده‌های آموزشی در طول یک بازه‌ی طولانی از زمان و مدل واکنشی بر اساس یکی بازه‌ی زمانی کوتاه از داده‌های آموزشی ساخته شده است. این تکنیک از مدل واکنشی به عنوان

شاخصی برای تشخیص تغییر استفاده می‌کند. به این صورت که وقتی مدل واکنشی برای یک نمونه نسبت به مدل پایدار عملکرد بهتری از خود نشان می‌دهد نشان دهنده رخداد یک تغییر در بازه زمانی کوتاه مربوط به مدل واکنشی است.

در مقایسه‌ی بین این سه روش می‌توان گفت محدودیت تشخیص دهنده‌های دسته‌ی سوم نسبت به دسته‌ی اول، نیاز به حافظه است. تشخیص دهنده‌های دسته‌ی اول نیازی به ذخیره داده‌ی ورودی ندارند ولی تشخیص دهنده‌های دسته‌ی دوم باید داده‌های موجود در هر دو پنجره‌ی مرجع و لغزنده را در حافظه نگه دارند. مزیت تشخیص دهنده‌های دسته‌ی اول دقت بالاتر آنها نسبت به سایر تشخیص دهنده‌ها است.

۵. روش‌های مواجهه با تغییرات زمانی

در تحقیقات مطالعه شده، چهار شیوه در مواجه با اثرات حاصل از تغییرات زمانی در داده‌ها گزارش شده است) (Nishida, Hoshide et al. ۲۰۱۲)، (Fukumoto, Ushiyama et al. , Gama, Žliobaitė et al. ۲۰۱۴)، (Tsymbal ۱۹۹۶)، (Widmer and Kubat ۲۰۰۴)، (Nishida, Hoshide et al. ۲۰۱۲) در ادامه هر یک از روش‌ها به طور کامل توضیح داده می‌شوند.

۵.۱. انتخاب نمونه

در روش انتخاب نمونه، هدف انتخاب نمونه‌های مرتبط با داده‌هایی است که از سایر داده‌ها به نمونه‌های آزمایشی نزدیک‌ترند. این شیوه که رایج‌ترین روش برای مواجه با تغییرات زمانی است، از یک پنجره لغزان تشکیل شده است که بر روی آخرین نمونه‌ها حرکت کرده و از مدل ساخته شده‌ی حاصل از آن‌ها برای پیش‌گویی نمونه‌ها در مثال‌هایی که در آینده‌ای بسیار نزدیک وجود دارند استفاده می‌کند (Tsymbal ۱۹۹۶). در این الگوریتم‌ها می‌توان از پنجره‌هایی با اندازه‌ی ثابت استفاده کرد یا اینکه با روش‌های اکتشافی اندازه‌ی پنجره را متناسب با آخرین بازه‌ی تغییر در داده‌ها تنظیم کرد. روش پیشنهادی مرجع (D'hondt, Verberne et al. ۲۰۱۲) سعی در انتخاب پنجره به نحوی دارد که یک تعادل بین جدید بودن داده و اندازه‌ی پنجره برقرار شود. در مرجع (Šilić and Bašić ۲۰۱۲) نشان داده شده است که در صورت وجود رانش مفهوم در داده‌های آموزشی، حتی استفاده از انتخاب نمونه‌رنم به جای کل داده‌ها به عنوان داده‌ی آموزشی، می‌تواند میزان عملکرد دسته‌بند را افزایش دهد. در مرجع (Rocha, Mourão et al. ۲۰۱۳) الگوریتمی به نام Chronos پیشنهاد شده است که به ازای هر نمونه‌ی آزمایشی بخشی از مجموعه‌ی آموزشی به نام محتوای زمانی^۳ را انتخاب می‌کند. این الگوریتم کمک می‌کند تا بزرگ‌ترین محتوای زمانی انتخاب شود به طوری که اثرات ناشی از تغییرات زمانی در عملکرد دسته بند به حداقل برسد.

۵.۲. وزن دهی به نمونه

در این روش به بعضی از نمونه‌ها در طول آموزش وزن بیشتری اختصاص داده می‌شود. نمونه‌ها می‌توانند بر اساس میزان قدمت و میزان ارتباط به مفاهیم جدید وزن دهی شوند) (Tsymbal ۲۰۰۴). روش وزن دهی به نمونه‌ها نیز، فرض می‌کند که نمونه‌های جدیدتر آموزشی برای دسته‌بندی مثال‌های آزمایشی جدید بهتر عمل می‌کنند (Nishida, Hoshide et al. ۲۰۱۲).

۵.۳. یادگیری دسته جمعی

روش یادگیری دسته جمعی مجموعه‌ای از مدل‌های پیشگویی را نگه‌داری کرده و از رای‌گیری بین مدل‌ها یا وزن دهی به آنها در زمان پیشگویی نمونه‌های آزمایشی استفاده می‌کند. معمولاً وقتی مدل‌های جدید اضافه می‌شوند، مدل‌های ضعیف یا قدیمی، حذف شدن مدل‌های قدیمی یا به صورت دوره‌ای است و یا پس از مشاهده‌ی کاهش صحت عملکرد دسته بند انجام می‌شود. هر چند در بعضی از مراجع (Nishida and Yamauchi ۲۰۰۹)، هیچ دسته‌بندی تحت هیچ شرایطی از سیستم حذف نمی‌شود. سیستم پیشنهادی این مرجع (Nishida and Yamauchi ۲۰۰۹) از چندین دسته بند آفلاین و آنلاین برای مواجهه با تغییرات زمانی استفاده کرده است. با شروع کار سیستم با ورود هر مثال جدید دسته‌بند آنلاین به روزرسانی می‌شود، برخلاف دسته‌بند آفلاین که با ورود مثال‌های جدید به روزرسانی نمی‌شوند. در حقیقت دسته‌بندهای آنلاین برای تطبیق با تغییرات تدریجی، مدام در حال یادگیری مثال‌ها هستند و دسته‌بندهای آفلاین برای پاسخ به تغییرات بازگشت کننده استفاده می‌شوند. در (Kolter and Maloof ۲۰۰۷) مجموعه‌ای از دسته‌بندها با قدمت‌های متفاوت ساخته می‌شود به طوری که هر یک از دسته‌بندها شامل نمونه‌هایی مربوط به دوره‌ی خاصی از زمان هستند.

۵.۴. انتخاب ویژگی

در اکثر تحقیقات تنها سه دسته‌ی قبلی برای مواجه با تغییرات زمانی بیان شده است ولی در تحقیق (Ushiyama et al. ۲۰۱۴) دسته روش انتخاب ویژگی^۴ نیز برای مواجه با تغییرات زمانی ارائه شده است. این رویکرد در چند سال اخیر مورد توجه قرار گرفته و تمرکز را از وزن دهی به نمونه‌ها به سمت وزن دهی به ویژگی‌ها سوق می‌دهد. در این رویکرد برای مواجهه با تغییرات زمانی هر بار به صورت پویا ارزشمندترین ویژگی‌ها (کلمات) انتخاب می‌شوند. در تحقیق (Fukumoto, Ushiyama et al. ۲۰۱۴) ویژگی‌ها یا کلمات مورد استفاده در دسته‌بندی

¹ Ensemble learning

² Feature selection

³ Temporal context

⁴ Feature selection

متن به دو دسته تقسیم شده‌اند، یکی کلمات مستقل از زمان^۱ و دیگری کلمات وابسته به زمان^۲ است که در مرجع (Nishida, Hoshida et al. ۲۰۱۲) به ترتیب کلمات پایدار^۳ و ناپایدار^۴ خوانده می‌شوند. در (Fukumoto, Ushiyama et al. ۲۰۱۴) از روش TWF^۵ برای وزن دهی استفاده شده است با این تفاوت که به جای وزن دهی در سطح نمونه، وزن دهی در سطح ویژگی انجام می‌شود. به این صورت که اگر یک ویژگی وابسته به زمان بود، از وزن دهی بر پایه‌ی TWF و اگر مستقل از زمان بود وزن دهی معمولی برای آن استفاده می‌گردد.

۶. ارتباط بین روش‌های مواجهه با تغییر با نوع تغییر

به طور کلی انتخاب روش مواجهه با تغییر، به نوع تغییر موجود در پیکره‌ی مورد بررسی وابسته است (D'hondt, Verberne et al.). نویسنده‌گان تحقیق (Nishida, Hoshida et al. ۲۰۱۲) معتقدند که روش وزن دهی به نمونه‌ها تنها در مواجهه با تغییر تدریجی خوب عمل می‌کند ولی در مواجهه با تغییر ناگهانی شکست می‌خورد. در تحقیق (Carmona-Cejudo, Baena-García et al. ۲۰۱۱) نتایج مناسبی از انتخاب نمونه برای مواجهه با تغییر تدریجی موجود در دسته‌بندی جریانی از ایمیل‌ها به دست آمده است. به عقیده‌ی (D'hondt, Verberne et al.) یادگیری دسته جمعی برای تغییرات تدریجی و بازگشت کننده خوب عمل می‌کند و بهترین راه مواجهه با تغییر ناگهانی، انتخاب داده‌ی آموزشی تنها از نمونه‌هایی است که با توزیع جدید همخوانی دارند و زمانی که تغییر بازگشت کننده وجود ندارد بهترین راه مواجهه با تغییر این است که مدل هر چند وقت یکبار به روز رسانی شود. به این نحو که مدل‌های قدیمی آموزش دیده تخریب و مدل‌های جدید به جای مدل‌های دسته بندی قدیمی جایگزین شود.

در بعضی تحقیقات برای مواجهه با تغییر تنها به یک روش بسته نمی‌کنند و از ترکیبی از چند روش استفاده می‌کنند. برای مثال در تحقیق (Salles, Rocha et al. ۲۰۱۰) نوعی وزن دهی مبتنی بر زمان به نام TWF برای دسته بندی ارائه شده است. وزن دهی TWF. تغییرات موجود در رابطه‌ی بین کلاس و واژگان را در دوره‌های زمانی مختلف استخراج کرده و در دسته‌بند آن را به دو روش استفاده می‌کند TWF بر روی نمونه‌ها و بر روی امتیاز به دسته‌بندها. در TWF بر روی متون، فاصله‌ی زمانی بین متون آموزشی و آزمایشی به منظور اندازه‌گیری میزان شباهت محاسبه شده و بر این اساس یک متن آموزشی که از لحاظ زمانی نزدیک‌تر به متن آزمایشی است، اهمیت بیشتری پیدا می‌کند. در TWF بر روی دسته‌بندها، امتیاز نهایی به یک کلاس از جمع وزن دار امتیازهای تولید شده توسط دسته‌بندی‌های عادی که در بازه‌های زمانی متفاوت ساخته شده اند به دست می‌آید.

۷. نتیجه گیری

در دسته بندی متن عموماً داده‌ها ابتدا به صورت آفلاین جمع آوری شده و آموزش بر روی آن‌ها انجام می‌شود سپس مدل آموزش دیده به این روش، می‌تواند برای پیش‌بینی داده‌های دیده نشده‌ی ورودی مورد استفاده قرار بگیرد. در شرایطی که داده‌ها مدام در حال به روز رسانی هستند، توزیع آنها می‌تواند در طول زمان تغییر کند به طوری که موجب اثرگذاری بر روی عملکرد دسته بند شود. از آنجایی که انتخاب روش مواجهه با تغییر، به نوع تغییر وابسته است، لذا در این مقاله ابتدا به بررسی انواع تغییرات زمانی پرداخته شد. سپس انواع روش‌های مواجهه با تغییر بیان شد و در نهایت بهترین روش‌های مواجهه با تغییر متناسب با نوع تغییر رخ داده مورد بررسی قرار گرفت. در این مقاله سعی شد تا حد امکان یک دیدگلی و همه جانبه در زمینه‌ی اثر زمان در دسته‌بندی خودکار متن ارائه شده و مسیر را برای سایر محققین در انتخاب روش مناسب برای مواجهه با تغییرات زمانی هموارتر کند.

۸. منابع مورد استفاده

- Alonso, O., M. Gertz and R. Baeza-Yates (۲۰۰۷). On the value of temporal information in information retrieval. ACM SIGIR Forum, ACM.
- Bach, S. H. and M. Maloof (۲۰۰۸). Paired learners for concept drift. Data Mining, ۲۰۰۸. ICDM'۰۸. Eighth IEEE International Conference on, IEEE.
- Brzezinski, D. and J. Stefanowski (۲۰۱۴). "Reacting to different types of concept drift: The accuracy updated ensemble algorithm." Neural Networks and Learning Systems, IEEE Transactions on ۲۵(۱): ۹۴-۸۱
- Carmona-Cejudo, J. M., M. Baena-García, R. M. Bueno, J. Gama and A. Bifet (۲۰۱۱). Using GNUsmail to Compare Data Stream Mining Methods for On-line Email Classification. WAPA.

¹ Temporal independent terms

² Temporal dependent terms

³ Stationary

⁴ Bursty

- D'hondt, E., S. Verberne, N. Oostdijk, J. Beney, C. Koster and L. Boves (۲۰۱۴). "Dealing with temporal variation in patent categorization." Information Retrieval: ۲۵-۱
- Ditzler, G. (۲۰۱۲). Incremental Learning of Concept Drift from Imbalanced Data.
- Forman, G. (۲۰۰۷). Tackling concept drift by temporal inductive transfer. Proceedings of the ۱۹th annual international ACM SIGIR conference on Research and development in information retrieval, ACM.
- Fukumoto, F., S. Ushiyama, Y. Suzuki and S. Matsuyoshi (۲۰۱۴). The Effect of Temporal-based Term Selection for Text Classification. Australasian Language Technology Association Workshop. ۲۰۱۴
- Gama, J., I. Žliobaitė, A. Bifet, M. Pechenizkiy and A. Bouchachia (۲۰۱۴). "A survey on concept drift adaptation." ACM Computing Surveys (CSUR) ۴۶(۴): ۴۴
- Katakis, I., G. Tsoumakas and I. Vlahavas (۲۰۰۹). "Dynamic feature space and incremental feature selection for the classification of textual data streams." Knowledge Discovery from Data Streams: ۱۱۶-۱۰۷
- Kifer, D., S. Ben-David and J. Gehrke (۲۰۰۴). Detecting change in data streams. Proceedings of the Thirtieth international conference on Very large data bases-Volume ۳۰, VLDB Endowment.
- Kolter, J. Z. and M. Maloof (۲۰۰۳). Dynamic weighted majority: A new ensemble method for tracking concept drift. Data Mining, ۲۰۰۳. ICDM ۲۰۰۳. Third IEEE International Conference on, IEEE.
- Mourão, F., L. Rocha, R. Araújo, T. Couto, M. Gonçalves and W. Meira Jr (۲۰۰۸). Understanding temporal aspects in document classification. Proceedings of the ۲۰۰۸ International Conference on Web Search and Data Mining, ACM.
- Nishida, K., T. Hoshide and K. Fujimura (۲۰۱۲) Improving tweet stream classification by detecting changes in word probability. Proceedings of the ۳۵th international ACM SIGIR conference on Research and development in information retrieval, ACM.
- Nishida, K. and K. Yamauchi (۲۰۰۹). Learning, detecting, understanding, and predicting concept changes. Neural Networks, ۲۰۰۹. IJCNN ۲۰۰۹. International Joint Conference on, IEEE.
- Rocha, L., F. Mourão, H. Mota, T. Salles, M. A. Gonçalves and W. Meira Jr (۲۰۱۳). "Temporal contexts: Effective text classification in evolving document collections." Information Systems ۳۸(۳): ۳۰۹-۳۸۸
- Rocha, L., F. Mourão, A. Pereira, M. A. Gonçalves and W. Meira Jr (۲۰۰۸). Exploiting temporal contexts in text classification. Proceedings of the ۱۷th ACM conference on Information and knowledge management, ACM.
- Salles, T., L. Rocha, G. L. Pappa, F. Mourão, W. Meira Jr and M. Gonçalves (۲۰۱۰). Temporally-aware algorithms for document classification. Proceedings of the ۳۳rd international ACM SIGIR conference on Research and development in information retrieval, ACM.
- Sebastiani, F. (۲۰۰۲). "Machine learning in automated text categorization." ACM computing surveys (CSUR) ۳۴(1): ۴۷-۱
- Šilić, A. and B. D. Bašić (۲۰۱۲). Exploring classification concept drift on a large news text corpus. Computational linguistics and intelligent text processing, Springer: ۴۳۷-۴۲۸
- Tsymbol, A. (۲۰۰۴). "The problem of concept drift: definitions and related work".
- Vorburger, P. and A. Bernstein (۲۰۰۷). Entropy-based concept shift detection. Data Mining, ۲۰۰۷ICDM'۰۷. Sixth International Conference on, IEEE.
- Wenerstrom, B. and C. Giraud-Carrier (۲۰۰۷). Temporal data mining in dynamic feature spaces. Data Mining, ۲۰۰۷. ICDM'۰۷. Sixth International Conference on, IEEE.
- Widmer, G. and M. Kubat (۱۹۹۶). "Learning in the presence of concept drift and hidden contexts." Machine learning 22(1): 101-79