



ارائه شده توسط :

سایت ترجمه فا

مرجع جدیدترین مقالات ترجمه شده

از نشریات معابر

# مطالعه ای مختصر در خصوص طبقه بندی توالی

چکیده :

طبقه بندی توالی دارای طیف وسیعی از کاربرد ها نظری تحلیل ژنوم، بازیابی اطلاعات، انفورماتیک سلامت، امور مالی و تشخیص ناهنجاری ها می باشد. متفاوت از انجام طبقه بندی بر روی بردار ها ای ویژگی، توالی ها معمولاً فاقد ویژگی ها ای صریح می باشند. حتی با فنون انتخاب ویژگی پیشرفته، بعدیت ویژگی ها ای بالقوه بسیار بالا است و ماهیت متوالی ویژگی ها را به سختی می توان درک کرد. این موجب می شود تا طبقه بندی توالی و دنباله به یک ویژگی چالش بر انگیز تر از طبقه بندی بردار ها ای ویژگی تبدیل شود. ما اقدام به طبقه بندی توالی از حیث روش ها و حوزه ها ای کاربرد مختلف می کنیم. ما مرور جامعی را در خصوص انواع مختلف مسائل طبقه بندی توالی نظری طبقه بندی اولیه توالی ها و یادگیری نیمه نظارت شده در زمینه طبقه بندی ها انجام می دهیم.

## -1- مقدمه

طبقه بندی توالی دار ای طیف وسیعی از کاربرد ها می باشد. در تحقیقات ژنومی، طبقه بندی توالی ها ای پروتین به دسته ها ای موجود بر ای یادگیری وظایف و کارکرد ها ای پروتین استفاده می شود(13). در انفورماتیک سلامت، طبقه بندی سری ها ای زمانی ECG (سری ها ای زمانی ضربان قلب) به ما می گوید که آیا داده ها مربوط به یک فرد سالم هستند یا مربوط به یک بیمار مبتلا به بیماری قلبی است(59). در تشخیص نفوذ و ناهنجاری، توالی فعالیت ها ای دسترسی سیستم بر روی یونیکس بر ای تشخیص رفتار ها ای غیر طبیعی و ناهنجاری پایش می شود(33). در باز یابی اطلاعات، طبقه بندی اسناد به مقوله ها ای موضوعی مختلف، توجهات زیادی را به خود جلب کرده است(51). سایر مثال ها ای جالب شامل طبقه بندی توالی ها ای کوئری بر ای تمایز ربات ها ای اینترنتی از کاربر ان انسان (18، 58) و طبقه بندی داده ها ای توالی تر انسفکشن در یک بانک بر ای مبارزه با پول شویی، می باشد(42).

به طور کلی، یک توالی، فهرست منظمی از رویداد هاست. یک رویداد را می توان به صورت یک ارزش نمادین، یک ارزش واقعی عددی، یک بردار با ارزش واقعی یا یک داده نوع پیچیده در نظر گرفت. در این مقاله، داده ها ای توالی یا دنباله ای به زیر انواع زیر در نظر گرفته می شود

- با توجه به القای عالیم و نماد ها  $fE1; E2; E3; \dots; Eng$  فهرست منظمی از نماد ها از الفبای باشد. برای مثال، یک توالی  $DNA$  متشکل از چهار امینو اسید  $A-C-G-T$  و قطعه  $DNA$  نظیر  $ACCCCCGT$  می باشد که یک توالی نمادین ساده است.
- یک توالی نمادین ساده، فهرستی از بردارها می باشد. هر بردار یک زیرمجموعه ای از الفبا( $34$ ) می باشد. برای مثال، برای توالی ایتمها خریداری شده توسط یک مشتری در یک سال، در نظر گرفتن هر تراکنش به صورت یک بردار، یک توالی یا دنباله می تواند به صورت ساعت است (شیر؛ نان) (شیر؛ تخم مرغ) (سیب زمینی؛ پنیر؛ کک) در نظر گرفته شود.
- سری های زمانی ساده دنباله ای از ارزش ها و مقادیر واقعی مرتب شده به ترتیب صعودی می باشد
$$h(t1; 0:1)(t2; 0:3) \dots (tn; 0:3)i$$

یک سری زمانی ساده می باشد که داده های مربوط به مهر زمانی  $t1$  تا  $t2$  را نشان می دهد

سری های زمانی چند متغیره، دنباله و توالی از بردارها ای عددی می باشد. برای مثال

$$h(t1; h0:1; 0:3; 05i)(t2; h0:3; 0:9; 0:8i) \dots (tn; h0:3; 0:9; 0:4i)i$$

یک سری زمانی چند متغیره می باشد.
- در بالا، انواع داده های رویدادها ساده می باشد. در برخی از زمینه ها، نوع داده های رویدادها ممکن است پیچیده باشند. برای مثال، در یک مجموعه داده های پرونده بیمار (برای مثال، <http://www.informsdmcontest2009.org/>) نشان داده می شود. هر بازبینی یا ویزیت یک رویداد است و با اندازه گیری های عددی چندگانه توصیف می شود.
- یک توالی رویداد پیچیده اشاره به شکل کلی از توالیها و دنباله ها دارد
- یک توالی یا دنباله ممکن است حامل یک برچسب باشد. برای مثال، سری های زمانی داده های  $ECG$  بر گرفته از افراد سالم یا بیمار می باشند. یک توالی  $DNA$  مربوط به یک منطقه زن کد کننده یا غیر کد کننده می باشد.
- با توجه به این  $L$  یک مجموعه برچسب باشد، طبقه بندی توالی ابزاری برای یادگیری کلاسیفایر توالی  $C$  می باشد، که دنباله  $s$  را برای یک برچسب کلاس  $l \in L$  در نظر می گیرد و به صورت  $C : s \rightarrow l, l \in L$  تعیین می شود.

در طبقه بندی توالی، هر توالی مربوط به تنها یک برچسب کلاسی بوده و توالی کل بر ای دسته بند قل از دسته بندی وجود دارد. هم چنین سناریو ها ای مختلف دیگری بر ای طبقه بندی توالی وجود دارد. بر ای مثال، بر ای توالی یا دنباله علایم یک بیمار در بلند مدت، شر ایط سلامتی بیمار می تواند تغییر کند. هم چنین سناریو ها ای دیگری بر ای دسته بندی توالی وجود دارد. بر ای مثال، بر ای یک دنباله و توالی ای از علایم بیمار در یک دوره بلند مدت، شر ایط سلامتی بیمار می تواند تغییر کند. بر ای توالی استریمینگ، که به صورت توالی نامحدود در نظر گرفته می شود، به جای پیش بینی یک برچسب کلاس، امکان پیش بینی یک توالی از رویداد ها وجود دارد. این مسئله نیز به صورت یک فرا یند دسته بندی توالی قوی در نظر گرفته شده است. در این مقاله، ما در مورد انواع مختلف طبقه بندی توالی در بخش 3 صحبت می کنیم.

سه چالش مهم دیگر در طبقه بندی توالی وجود دارد. اولا، بیشتر دسته بند ها نظیر درختان تصمیم گیری و شبکه ها ای عصبی، تنها داده ها ای ورودی را به صورت بردار ویژگی ها در نظر می گیرد. دوما، حتی با روش ها ای مختلف انتخاب ویژگی، می تواند یک توالی را به مجموعه ای از ویژگی ها تبدیل می کند. این ویژگی ها بسیار مهم هستند. بعدیت فضای ویژگی بر ای داده ها ای توالی می تواند بسیار بالا باشد و محاسبه می تواند پر هزینه باشد. سوما، علاوه بر نتایج طبقه بندی صحیح در برخی از موارد، امکان دست یابی به دسته بند قابل تفسیر وجود دارد. ایجاد ک دسته بند توالی قابل تفسیر سخت است زیرا ویژگی ها ای صریح وجود ندارد.

در این مقاله ما مروء مختصرا بر روی روش ها ای طبقه بندی و دسته بندی توالی موجود ار ایه می کنیم. چون بیشتر مطالعات فعلی بر دسته بندی توالی سنتی متمرکز هستند، بخش دوم خلاصه ای از روش ها ای اصلی را بر ای این کار ار ایه می کند. در بخش سوم، ما در مورد انواع فعالیت ها ای دسته بندی توالی نظیر استریمینگ دسته بندی توالی و دسته بندی اولیه توالی ها صحبت می کنیم. در بخش چهارم، ما خلاصه ای از دسته بندی توالی را از دیدگاه کاربردی نظیر داده ها ای سری زمانی، داده ها ای متنی و داده ها ای ژنومی را ار ایه می کنیم. در بخش 5 نیز نتیجه گیری ار ایه شده است.

## 2- روش های طبقه بندی توالی

روش های طبقه بندی توالی را می توان به سه نوع اصلی تقسیم کرد:

- اولین دسته، طبقه بندی مبتنی بر ویژگی است که توالی را به یک بردار ویژگی تبدیل کرده و سپس از روش‌ها برای طبقه بندی سنتی استفاده می‌کند. انتخاب ویژگی نقش مهمی در این نوع روش‌ها ایفا می‌کند.
- دومین دسته، طبقه بندی مبتنی بر فاصله توالی است. تابع فاصله‌ای تشابه بین توالی‌ها را اندازه‌گیری کرده و کیفیت طبقه بندی را تعیین می‌کند
- سومین مقوله طبقه بندی مبتنی بر مدل نظیر استفاده از مدل مارکوف پنهان و سایر مدل‌های اماری برای طبقه بندی توالی‌هاست
- در ادامه این بخش ما یک سری روش‌های معرف را در سه دسته ارائه می‌کنیم. برخی از روش‌ها از چندین مقوله استفاده کرده‌اند. برای مثال، می‌توان از SVM با استخراج ویژگی‌ها یا تعریف شاخص‌های فاصله‌ای استفاده کرد. طبقه بندی توالی با استفاده از SVM در بخش 2-3 خلاصه شده است. همه روش‌ها ای بحث شده در این بخش، طبقه بندی توالی سنتی می‌باشند.

## 2- طبقه بندی مبتنی بر ویژگی

روش‌های طبقه بندی سنتی نظیر درختان تصمیم‌گیری و شبکه‌های عصبی، برای طبقه بندی بردار‌ها ویژگی‌هایی می‌شوند. یک شیوه برای حل مسئله طبقه بندی توالی، تبدیل توالی به بردار ویژگی‌ها از طریق انتخاب ویژگی است

برای یک توالی نمادین، ساده‌ترین راه، در نظر گرفتن هر عنصر به صورت یک ویژگی است. برای مثال، یک توالی  $ACG$  را می‌توان به صورت یک بردار  $ACG$  در نظر گرفت. با این حال، ماهیت متوالی توالی‌ها را نمی‌توان با این تبدیل توجیه کرد. برای حفظ ترتیب عناصر در یک توالی، یک قطعه کوچک از نماد‌های متوالی  $K$  موسوم به  $K$ -گرم معمولاً به عنوان یک ویژگی انتخاب می‌شود. با توجه به مجموعه‌ای از  $K$  گرم‌ها، یک توالی را می‌توان به صورت بردار حضور یا غیاب  $K$ -گرم تعیین کرد. گاهی اوقات امکان تطبیق غیر دقیق با  $K$ -گرم وجود دارد. با استفاده از ویژگی‌های  $K$ -گرم، توالی‌ها را می‌توان با روش طبقه بندی سنتی نظیر SVM تعیین کرد. یک خلاصه‌ای از روش‌های انتخاب ویژگی مبتنی بر  $K$ -گرم برای طبقه بندی توالی را می‌توان در (16) یافت.

اندازه ویژگی های کاندید که به صورت  $K - گرم$  هستند  $1 \leq k \leq l$  is  $2^l - 1$  می باشد. در صورتی که  $K$

یک عدد بزرگ باشد، اندازه ویژگی های می تواند بزرگ تر باشد. چون همه ویژگی های به طور یکسان بر ای طبقه بندی اهمیت دارند، چانزو لو(12) از تست گاما بر ای انتخاب یک زیر مجموعه بهینه ای از ویژگی های با  $K - گرم$  استفاده کرده است. یک الگوریتم زنگنه ای برای یافتن زیر مجموعه بهینه از ویژگی های محلی استفاده می شود.

بر عکس مجموعه ویژگی های مبتنی بر  $K - گرم$ ، لیش و همکاران(30-34) یک روش انتخاب ویژگی مبتنی بر مدل را ارائه کرده اند. این ویژگی های به صورت قطعات توالی کوتاهی هستند که معیار های زیر را دارند ۱- حداقل در یک دسته دیده می شوند ۲- حداقل در یک کلاس یا دسته متمایز هستند ۳- اضافی نباشند. معیار(2) به معنی این است که ویژگی بایستی ارتباط و همبستگی معنی داری با یک کلاس داشته باشد. افزونگی در معیار ۳ را می توان بر ای طبقه بندی ویژگی و تعمیم ویژگی استفاده کرد. یک الگوریتم ویژگی کاوی کار امد، بر ای کاوش ویژگی های بر طبق معیار های پیشنهاد می شود. نتایج ازمایشی در(30) نشان می دهد که مقایسه با روش در نظر گرفتن هر عنصر به عنوان ویژگی، انتخاب ویژگی مبتنی بر الگو موجب بهبود صحت تا ۱۰ تا ۱۵ درصد می شود.

چالش انتخاب ویژگی مبتنی بر الگو در توالی های نمادین ابزاری بر ای جست و جوی ویژگی های مطابق با معیار هاست. جی و همکاران یک الگوریتم را بر ای کاوش توالی های با محدودیت فاصله پیشنهاد کرده اند. این الگوریتم که از عملیات بولین و چارچوب رشد پیشوند استفاده می کند، حتی با استانه فرکانس پایین کار امد است سری های زمانی به صورت عددی هستند. روش های انتخاب ویژگی بر ای توالی های نمادین را نمی توان به آسانی به داده های سری های زمانی به کار برد. گسسته سازی می تواند موجب از بین رفتن اطلاعات شود. بی و همکاران(65) روش انتخاب ویژگی ای را پیشنهاد کردند که قابل کاربرد مستقیم به سری های زمانی عددی است. اشکال مختلف سری های زمانی نشان دهنده یک دسته خاص بوده و به عنوان یک ویژگی بر ای طبقه بندی سری های مورد استفاده قرار می گیرد. بر ای یک فرایند دو دسته ای، یک واحد به صورت بخشی از سری های زمانی است که بر ای تفکیک داده های اموزشی به دو بخش بر اساس فاصله از واحد استفاده شده و موجب بیشینه سازی از داده های اموزشی بر ای بهینه سازی اسفاده می شود. بر ای ایجاد یک دسته بند، فرایند انتخاب شکل با ساخت درخت تصمیم گیری تلفیق می شود

اگرچه زیر توالی ها جزو ویژگی های مفید می باشند، با این حال آنها قادر به توصیف ویژگی های محلی با توالی بلند هستند. اگر اول و همکار ان (5) یک روشی را برای پوشش دادن ویژگی های جهانی و محلی توالی ها برای طبقه بندی توسعه داده اند. اگر اول و همکار ان (5) تجزیه موجک را برای توصیف توالی نمادین بر روی وضوح های مختلف اصلاح کرده است. با ضرایب تجزیه متفاوت، موجک ها بیانکر تغییرات در دامنه ها و بازه های مختلف چهانی تا محلی است.

با استفاده از تجزیه موجک و دسته بندی مبتنی بر قاعده، روش تجزیه موجک عملکرد بهتری نسبت به دسته بند نزدیک ترین همسایه بر روی مجموعه داده های توالی و مجموعه داده های توالی ژئومی دارد. به طور خلاصه، روش های موجود از دیدگاه های زیر متفاوت می باشند:

- کدام معیار ها بایستی برای انتخاب ویژگی های نظیر منحصر به فرد، فرکانس و طول استفاده شوند؟
- در کدام زمینه انتخاب ویژگی منعکس کننده ماهیت متوالی توالی، محلی و جهانی می باشند؟
- آیا انطباق ها بایستی دقیق یا غیر دقیق با فاصله ها باشند؟
- آیا انتخاب ویژگی بایستی در فرآیند ایجاد یک دسته بند و یا مرحله پیش پردازش مجزا تلفیق شوند؟

## 2- دسته بندی مبتنی بر فاصله توالی

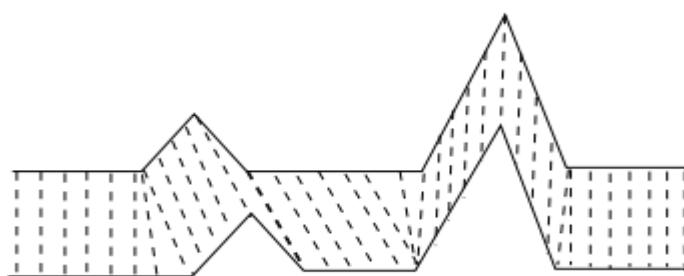
روش های مبتنی بر فاصله توالی، یک تابع فاصله ای را برای اندازه گیری تشابه بین جفت توالی ها ارایه می کنند. وقتی این توابع فاصله ای انتخاب شدن، می توان از روش های دسته بندی موجود نظیر دسته بند نزدیک ترین همسایه K و SVM با هسته همسوی محلی برای دسته بندی توالی استفاده کرد.

KNN یک روش یادگیری کند بوده و مدل دسته بندی را از قبل محاسبه نمی کند. با توجه به مجموعه داده های توالی T، یک عدد صحیح مثبت K و یک توالی جدید S، دسته بند KNN، نزدیک ترین همسایه K از S را در T پیدا می کند و سپس برچسب دسته غالب را در KNN به صورت برچسب S قرار می دهد.

انتخاب شاخص های فاصله ای برای عملکرد دسته بند های KNN اهمیت زیادی دارند. در ادامه این بخش، ما بر خلاصه سازی شاخص های فاصله ای مختلف برای داده های توالی تاکید داریم. برای دسته بندی سری های زمانی ساده، فاصله اقلیدسی استفاده می شود. برای دو سری زمانی فاصله اقلیدسی به صورت زیر است

$$dist(s, s') = \sqrt{\sum_{i=1}^L (s[i] - s'[i])^2}.$$

فاصله اقلیدسی معمولاً مستلزم دو سری زمانی با طول یکسان است. کوگ و همکار ان(26) نشان داده اند که هنگام کاربرد دسته بند 1NN بر روی سری های زمانی، فاصله اقلیدسی از حیث صحت در مقایسه با سایر شاخص های تشابه، رقابتی خواهد بود. فاصله اقلیدسی به شدت به اعوجاج و انحراف در بعد زمانی حساس است. فاصله تابیدگی زمانی پویا(DTW) بر ای حل این مسئله استفاده شده و نیازمند دو سری زمانی با طول یکسان نیست. ایده DTW همسو سازی سری های زمانی و فاصله ای ارایه شده است. یک مثال از DTW در شکل 1 نشان داده شده است. زای و همکار ان(61) نشان می دهد که در مجموعه ای از داده های کوچک، شاخص های الاستیک نظیر تابیدگی زمانی پویا صحیح تر از فاصله اقلیدسی است. با این حال نتایج تجربی اخیر نشان می دهد که بر روی مجموعه داده های بزرگ، صحت شاخص های الاستیک با فاصله اقلیدسی هم پوشانی دارد تابیدگی زمانی پویا با برنامه ریزی پویا محاسبه شده و دارای پیچیدگی زمانی چند جمله ای است. از این روی، در مجموعه داده های بزرگ پر هزینه است. راتامانتا و همکار ان(48) روشی را برای تسريع فرآیند جست و جوی تشابه DTW با استفاده از محاسبات ارایه کردند. زای و همکار ان(61) از کاهش عددی برای تسريع محاسبه DTW استفاده کرده است. ایده اصلی کاهش تعداد مثال های اموزشی مورد استفاده توسط دسته بند 1NN می باشد و در عین حال امکان تنظیم پویایی پنجره تابیدگی وجود دارد



شکل 1: تابیدگی زمانی پویا

برای توالی های نما دین نظیر توالی های پروتینی و DNA، فواصل مبتنی بر همسو سازی معمولاً استفاده می شوند. با توجه به ماتریس تشابه و نیز جریمه فاصله ای، الگوریتم نیدل من یک امتیاز همسو سازی جهانی بهینه را بین دو توالی و دنباله از طریق برنامه نویسی پویا محاسبه می کند. بر عکس الگوریتم های همسو سازی جهانی،

الکوریتم ها ای همسو سازی محلی نظیر اسمیت واترمن و بلاست، تشابه را بین دو توالی با در نظر گرفتن شبیه ترین مناطق اندازه گیری می کنند

### 3-2 ماشین بردار پشتیبان

یک روش موثر برای دسته بندی توالی SVM می باشد. ایده اصلی استفاده از SVM بر روی داده ها ای توالی، تهیه نقشه توالی بر روی فضای ویژگی و یافتن ابر صفحه با حاشیه حداقل برای تفکیک دو کلاس است. گاهی اوقات، ما نیازی به انتخاب ویژگی صریح نداریم. یکتابع هسته متناظر با یک فضای ویژگی با بعد بالا است. با توجه به دو توالی،  $X, Y$  برخی از توابع هسته ای  $K(x; y)$  را می توان به صورت تشابه بین دو توالی در نظر گرفت. چالش ها ای استفاده از SVM برای طبقه بندی توالی شامل شیوه تعریف فضای ویژگی و توابع هسته و شیوه تسریع محاسبه ماتریس ها ای هسته است یکی از رایج ترین هسته ها برای طبقه بندی توالی، هسته طیف  $K$  یا هسته رشتہ می باشد که توالی را به یک بردار ویژگی تبدیل می کند. لزلی و همکاران (35) یک هسته طیف  $K$  را برای طبقه بندی پروتین پیشنهاد کردند. با توجه به الفبای امینو اسیدی 20 مولفه ای، این طیف شامل همه دنباله ها ای احتمالی با طول  $K$  می باشد که متشکل از عناصر و مولفه ها ای القبا است. برای مثال اگر  $K=3$  باشد، طیف  $K$  دارای ARN, AND, DCN می باشد. با توجه به الفبا،  $A$  یک دنباله  $X$  می باشد که به فضای ویژگی از طریق تابع ترانسفورماتیون تبدیل می شود

$$\Phi_k(x) = (\phi_a(x))_{a \in \mathcal{A}^k}$$

که  $\phi_a(x)$  تعداد دفعاتی است که  $a$  در  $x$  اتفاق می افتد. تابع هسته، محصول نقطه ای بردار ها ای ویژگی است

$$K(x, y) = \Phi_k(x) \cdot \Phi_k(y)$$

با استفاده از الگوریتم درخت پسوند،  $O(kn)$  را می توان در زمان  $K(x, y)$  محاسبه کرد لودهی و همکاران (43) یک هسته رشتہ ای را برای طبقه بندی متنی پیشنهاد کرده است. مشابه با هسته طیف  $k$  در (35)، هسته رشتہ ای از زیر توالی طول  $k$  استفاده کرده است. با استفاده از ضرب تجزیه با طول توالی ها در متن، فاصله به صورت جریمه کد گذاری می شود. تابع هسته یک حاصل نقطه ای از بردار ها ای ویژگی بوده و به

طور کار امد از طریق برنامه نویسی پویا محاسبه می شود. لسلی و همکار ان(36) هسته طیف  $k$  را برای مدیریت عدم انطباق توسعه داده اند. سانبرگ و همکار ان(55) یک هسته با طیف  $k$  با عدم انطباق را پیشنهاد کرده اند. یکی از معایب روش ها ای مبتنی بر هسته این است که تفسیر آن سخت است و کاربر ان به سختی می توان دانش آن را در کنار نتایج طبقه بندی حفظ کنند. سانبرگ یک روشی را برای یادگیری SVM ها ای قابل تفسیر با استفاده از مجموعه ای از هسته ها ای رشته پیشنهاد کرده اند. ایده اصلی، استفاده از یک ترکیب خطی از اوزان می باشد. هر هسته از یک مجموعه ویژگی ها ای منحصر به فرد استفاده می کند. اوزان بیانگر اهمیت ویژگی هاست. پس از یادگیری SVM، کاربر ان می توانند اطلاعات ارزشمندی را در زمینه اهمیت ویژگی ها ار ایه کنند هسته رشته یا هسته با طیف  $k$  را می توان به عنوان یک روش مبتنی بر ویژگی در نظر گرفت. سیگو و همکار ان(49) یک هسته همسوسازی محلی را بر ای دسته بندی توالی پروتین ار ایه کرده است که به عنوان یک روش مبتنی بر فاصله در نظر گرفته می شود. اگرچه فاصله همسوسازی محلی به طور موثر قادر به توصیف تشابه بین توالی هاست، با این حال به طور مستقیم به عنوان تابع هسته ای در نظر گرفته نمی شود زیرا فاقد ویژگی معین بودن مثبت است. سیگو و همکار ان(49)، فاصله همسوسازی محلی را اصلاح کرده و یک هسته معتبر را موسوم به هسته همسوسازی محلی ایجاد کردند که از رفتار همسوسازی محلی پیروی می کند. ارتباط نظری بین هسته همسوسازی محلی و فاصله همسوسازی محلی اثبات می شود. با توجه به دو توالی  $X$  و  $Y$ ، هسته همسوسازی محلی را می توان با برنامه نویسی پویا محاسبه کرد.

هسته ها ای دیگر مورد استفاده بر ای طبقه بندی توالی شامل هسته ها ای چند جمله ای ، هسته ها ای بر گرفته از مدل احتمال گر ایانه و هسته ها ای انتشار می باشند.

## 4-2 دسته بندی مبتنی بر مدل

یک مقوله دیگر از روش ها ای دسته بندی توالی، بر مبنای مدل ها ای تولید کننده است که فرض می کند توالی ها در یک دسته از طریق مدل  $M$  تولید می شود. با توجه به یک دسته ای از توالی ها،  $M$  توزیع احتمال اوالی ها را در یک دسته مدل سازی می کند. این مدل بر اساس فرضیات خاص تعریف می شود. در مرحله اموزش، پارامتر ها ای  $M$  یاد گرفته می شوند. در مرحله دسته بندی، توالی جدید به یک کلاس با بیشترین احتمال نسبت داده می شود.

ساده ترین مدل، دسته بند توالی بیز ساده می باشد. فرض بر این است که با توجه به یک کلاس یا دسته، ویژگی ها در دنباله ها و توالی ها مستقل از یک دیگر می باشند. احتمالات شرطی ویژگی ها در یک دسته در مرحله آموزشی یاد گرفته می شوند. به دلیل سادگی خود، بیز ساده به طور گسترده توسط دسته بندی تصویر و دسته بندی توالی ژنومی استفاده شده اند

با این حال، فرض مستقل بودن در بیز ساده در عمل نقض می شود. مدل مارکوف و مدل مارکوف پنهان قادر به مدل سازی وابستکی میان عناصر در توالی هاست

یاک شنوف و همکار ان(64) از مدل مارکوف رتبه  $K$  برای دسته بندی پروتین و داده های توالی متنی استفاده کردند. در فرآیند آموزش این مدل در شرایط متفاوت و افتر اقی برای افزایش قدرت دسته بندی روش های مبتنی بر مدل آموزش داده می شود. متفاوت از مدل مارکوف، مدل مارکوف پنهان فرض می کند که سیستم مدل سازی شده یک فرآیند مارکوف با حالت های مشاهده نشده است. سریوستاوا و همکار ان(56) از پروفیل HMM برای دسته بندی توالی های زیستی استفاده کرده است. یک پروفیل HMM دارای سه نوع حالت، افزایش، انطباق و حذف می باشد. مثال های آموزشی برای یادگیری احتمال تغییر بین حالت ها و احتمالات حذف استفاده می شود. HMM یاد گرفته شده بیانگر پروفیل مجموعه داده های آموزشی است. یک پروفیل HMM را می توان از توالی های غیر همسو با همسو سازی تدریجی هر مثال با پروفیل موجود یاد گرفت. برای هر دسته، یک پروفیل HMM یادگرفته می شود. در مرحله دسته بندی یک توالی با HMM در هر دسته با برنامه نویسی پویا همسو سازی می شود یک توالی مجهول به یک دسته با بالاترین امتیاز همسویی دسته بندی می شود.

### 3- نسخه های مختلف دسته بندی توالی

در این بخش، ما به مرور مسائل مربوط به طبقه بندی و دسته بندی توالی می پردازیم. این مسائل برای حل چالش ها در زمان استفاده از طبقه بندی توالی در زمینه های مختلف استفاده می شوند. از این روی از پیشوند هایی برای دست یابی به دسته بندی اولیه، طبقه بندی توالی ها با استفاده از هر دو داده های دارای برچسب و بدون برچسب و پیش بینی توالی برچسب ها به جای یک برچسب برای توالی های استریمینگ استفاده می کنیم

#### 1-3 دسته بندی اولیه

بر ای توالی ها ی نمادین موقت و سری ها ی زمانی، مقادیر توالی به ترتیب صعودی مهر زمانی در نظر گرفته می شود. گاهی اوقات پایش و دسته بندی توالی ها در اسرع وقت مطلوب است. بر ای مثال، در مطالعه کودکان پذیرفته شده در بخش مر اقبت ها ی ویژه، نتایج نشان داد که مودکان دار ای الکوی سری زمانی ضربان قلب غیر عادی بودند. به عنوان مثال دیگرف برنالی و همکار ان(9) نشان داده اند که تنها مشاهده پنج بسته اول TCP را می توان دسته بندی کرد. استفاده از ترا فیک انلاین را می توان بدون انتظار بر ای پایان یافتن چریان TCP شناسایی کرد. تا آن جا که ما می دانیم، دیز و همکار ان(14) اولین بار مفهوم دسته بندی اولیه سری ها ی زمانی را ار ایه کرده اند. آن ها به توصیف سری ها ی زمانی از طریق عبار اتی نظیر افزایش و ماندکاری و معمولا و همیشه پرداختند. به این ترتیب ادا بوست (19) بر ای شبیه سازی دسته بندها ی اصلی استفاده می شوند. این دسته بند قادر به انجام پیش بینی بر روی داده ها ی ناقص با مشاهده پسوند ها ی غیر قابل دسترس توالی ها می باشد انبیلال و همکار ان(8) از روش استدلال مبتنی بر مورد بر ای طبقه بندی سری ها ی زمانی جهت پایش خر ابی سیستم در سیستم پویا استفاده کردند. دسته بند KNN بر ای دسته بندی سری ها ی زمانی ناقص با فواصل مختلف استفاده می شود نظیر فاصله اقلیدسی و تابیدگی زمانی پویا. مطالعات شبیه سازی با استفاده از استدلال مبتنی بر مورد نشان داده اند که مهم ترین افزایش صحت طبقه بندی بر روی پیشوند ها از طریق سی تا چهل درصد طول کل اتفاق می افتد

اگرچه در(14-8)، اهمیت دسته بندی اولیه بر روی سری ها ی زمانی شناسایی می شود و برخی از نتایج مفید حاصله شده است، این مطالعه دسته بندی اولیه را به صورت دسته بندی پیش وند ها ی توالی ها در نظر می کیرد. زینگ و همکار ان(62) بر چالش ها ی طبقه بندی اولیه تاکید کردند که آن هم مطالعه تعادل بین صحت طبقه بندی و زمان است. روش ها ی پیشنهادی تنها بر انجام پیش بینی بر اساس اطلاعات جزیی متمرکز است، با این حال به بررسی شیوه انتخاب کوتاه ترین پیشوند بر ای ار ایه پیش بینی مطمئن تاکید دارد. این موجب می شود تا نتایج طبقه بندی اولیه را نتوان به خوبی مورد استفاده قرار دارد.

زینگ و همکار ان(62) مسئله طبقه بندی اولیه را به صورت طبقه بندی توالی ضمن حفظ صحت مورد انتظار فرموله کردند. یک روش مبتنی بر ویژگی بر ای طبقه بندی اولیه در توالی ها ی نمادین پیشنهاد می شود. ایده اصلی، انتخاب مجموعه ای از ویژگی ها ی منحصر به فرد و سپس ایجاد یک رابطه بین دسته بند قاعده و یک

دسته بند درخت تصمیم گیری با استفاده از این ویژگی ها است. در مرحله دسته بندیف یک توالی با همه قواعد و یا شاخه ها به طور هم زمان منطبق می شود تا زمانی که یک پیشوند پیدا شده و توالی طبقه بندی شود. به این ترتیب، یک توالی فور ا زمانی طبقه بندی می شود که صحت و دقیقت مورد انتظار کاربر حاصل شده باشد. روش های پیشنهادی در 62 برخی موفقیت هارا در مدیریت توالی های نمادین با دست یابی به صحت رقابتی با استفاده از نیمی از طول توالی ها نشان داده اند.

یکی از معایب روش ها در (62) این است که قادر به مدیریت سری های زمانی عددی نیست. چون سری های زمانی عددی بایستی به طور انلاین طبقه بندی شوند، از دست رفت اطلاعات موجب می شود تا نتوان برخی از ویژگی های منحصر به فرد را پوشش داد. زینگ و همکاران (63) یک دسته بند اولیه را برای سری های زمانی عددی با استفاده از یادکیری مبتنی بر فاصله ارایه کردند. این روش، طول پیش بینی حداقل را برای هر سری زمانی در مجموعه داده های اموزشی از طریق خوش بندی یاد گرفته و از MLP برای طبقه بندی استفاده می کند. همان طور که در بخش 2 نشان داده شده است، دسته بند 1NN با فاصله اقلیدسی، یک دسته بند صحیح برای دسته بندی سری های زمانی است. یک ویژگی جالب این روش این است که بدون نیاز به صحت مورد انتظار کاربر، دسته بند موجب فعال سازی دسته بندی شده ضمن این که صحت را نیز حفظ می کند.

### 2-3 دسته بندی توالی نیمه نظارت شده

تعداد داده های بدون شناسه و برچسب بیش از داده های دارای شناسه است. برخی از داده های بدون شناسه دارای ویژگی های مشترکی با داده های با شناسه هستند و در عین حال حاوی ویژگی های اضافی ای هستند که توصیف جامع تری را از یک دسته در اختیار می گذارند. از این روی، با استفاده از داده های بدون برچسب و شناسه، یک دسته بند صحیح تر را می توان تولید کرد.

برای طبقه بندی و دسته بندی متن، طیف وسیعی از داده های بدون برچسب و بدون شناسه وجود دارند. نیگام و همکاران (46) یک روش دسته بندی نیمه نظارت شده را برای نشانه گذاری و بر جسب گذاری اسناد پیشنهاد کرده اند. در ابتدا، دسته بند ساده بیز برای دسته بندی نمونه های بدون برچسب پیشنهاد شد. سپس، فرایند بیشینه سازی انتظار برای تعديل پارامتر های دسته بند بیز ساده و دسته بندی مجدد داده های بدون برچسب

در یک تکرار پیشنهاد شد. این فرایند زمانی به پایان می‌رسد که نتایج دسته بندی پایدار باشد. یک سند ممکن است متعلق به چندین دسته باشد و یا دارای برچسب‌های متعددی باشد.

علاوه بر طبقه بندی متن، زانگ و همکار آن (66) یک طبقه بندی نیمه نظارت شده مبتنی بر HMM را برای داده‌های سری‌های زمانی پیشنهاد کرده‌اند. این روش از داده‌های دارای برچسب برای آموزش پارامترهای EM اولیه HMM مرتبه اول استفاده کرده و سپس از داده‌های بدون برچسب برای تعديل مدل در یک فرایند بهره می‌برد. وی و همکار آن از دسته بند نزدیک ترین همسایه برای طبقه بندی سری‌های زمانی نیمه نظارت شده استفاده کردند. این روش برای مدیریت شرایطی استفاده می‌شود که در آن‌ها تنها یک تعداد کمی از داده‌های دارای برچسب در یک دسته مثبت موجود می‌باشد. در ابتدا، همه داده‌های بدون برچسب به صورت منفی در نظر گرفته می‌شود. سپس دسته بند  $NN^1$  برای دسته بندی داده‌های بدون برچسب در یک تکرار استفاده می‌شود

### 3-3 دسته بندی توالی با یک توالی و دنباله‌ای از برچسب‌ها

همان طور که در بخش 1 بحث شد، برای استریمینگ و ساده سازی طبقه بندی توالی‌لیف به جای پیش‌بینی یک برچسب دسته، پیش‌بینی توالی برچسب‌ها مطلوب‌تر است. کادوس این مسئله را به صورت طبقه بندی توالی قوی در نظر می‌گیرد ولی یک راه حل را برای این مسئله ارایه نمی‌کند.

یک مسئله مرتبط در پردازش زبان طبیعی، موسوم به توالی‌های برچسب‌زنی است. وظیفه این فرایند برچسب‌زنی هر عنصر در یک توالی است. برای مثال، با توجه به یک توالی، که در آن هر کلمه به صورت یک عنصر در نظر گرفته می‌شود، برچسب‌زنی توالی یک کلمه را به یک مقوله نسبت می‌دهد نظیر هویت، عبارت، فعل یا اسم. یک راه حل پیشرفتی، در نظر گرفتن برچسب‌های عناصر در یک توالی مرتبط با یک دیگر است. مسئله برچسب‌زنی با استفاده از زمینه‌های تصادفی شرطی حل می‌شود. این مسئله با سایر روش‌ها نظیر استفاده از مدل ترکیبی HMM و SVM و شبکه عصبی تکراری حل شده است

### 4- کاربرد دسته بندی توالی

دسته بندی توالی دار ای طیف وسیعی از کاربردها می باشد. برای حوزه های کاربردی مختلف فرایند دسته بندی دار ای ویژگی های متفاوتی است. در این بخش، ما روش های اصلی به کار برده شده در زمینه های مختلف را خلاصه می کنیم.

#### 1-4 داده های ژنومیک

در سال های اخیر، حجم زیادی از توالی های دی ان ای و پروتئین در دیتابیس های عمومی نظریه بانک ژنی، دیتابیس توالی نوکلوتیدی EMBL و دیتابیس پروتئین انترز موجود بوده است. برای درک وظایف ژن ها و پروتئین ها، دسته بندی توالی توجه زیادی را در تحقیقات ژنومی به خود معطوف کرده است.

روش های مبتنی بر ویژگی به طور گسترده ای برای طبقه بندی توالی ژنوم استفاده شده اند. برای یک توالی نمادین، ساده ترین راه، در نظر گرفتن هر عنصر به صورت یک ویژگی است. برای مثال، یک توالی CACG را می توان به صورت یک بردار ACCG در نظر گرفت. با این حال، ماهیت متوالی توالی ها را نمی توان با این تبدیل توجیه کرد. برای حفظ ترتیب عناصر در یک توالی، یک قطعه کوچک از نماد های متوالی K موسوم به K-گرم معمولاً به عنوان یک ویژگی انتخاب می شود. با توجه به مجموعه ای از این K-گرم ها، یک توالی را می توان به صورت بردار حضور یا غیاب K-گرم تعیین کرد. گاهی اوقات امکان تطبیق غیر دقیق با K-گرم وجود دارد. با استفاده از ویژگی های K-گرم، توالی ها را می توان با روش طبقه بندی سنتی نظری SVM تعیین کرد. یک خلاصه ای از روش های انتخاب ویژگی مبتنی بر K-گرم برای طبقه بندی توالی را می توان در (16) یافت.

اندازه ویژگی های کاندید که به صورت  $K - \text{گرم هستند}$   $1 \leq k \leq l \text{ is } 2^l - 1$  می باشد. در صورتی که K یک عدد بزرگ باشد، اندازه ویژگی های می تواند بزرگ تر باشد. چون همه ویژگی های به طور یکسان برای طبقه بندی اهمیت دارند، چانزو (12) از تست گاما برای انتخاب یک زیر مجموعه ای از ویژگی های با K-گرم استفاده کرده است. یک الگوریتم ژنتیکی برای یافتن زیر مجموعه بهینه از ویژگی های محلی استفاده می شود. بر عکس مجموعه ویژگی های مبتنی بر K-گرم، لیش و همکاران (30-34) یک روش انتخاب ویژگی مبتنی بر مدل را ارایه کرده اند. این ویژگی های به صورت قطعات توالی کوتاهی هستند که معیار های زیر را دارند 1- حداقل در

یک دسته دیده می شوند 2- حداقل در یک کلاس یا دسته متمایز هستند 3- اضافی نباشند. معیار(2) به معنی این است که ویژگی بایستی ارتباط و همبستگی معنی داری با یک کلاس داشته باشد. افزونگی در معیار 3 را می توان برای طبقه بندی ویژگی و تعمیم ویژگی استفاده کرد. یک الگوریتم ویژگی کاوی کار امد، برای کاوش ویژگی ها بر طبق معیارها پیشنهاد می شود. نتایج ازمایشی در(30) نشان می دهد که مقایسه با روش در نظر گرفتن هر عنصر به عنوان ویژگی، انتخاب ویژگی مبتنی بر الگو موجب بهبود صحت تا 10 تا 15 درصد می شود.

دسفنده و همکار ان(13) به مقایسه عملکرد SVM، HMM و KNN برای دسته بندی داده های توالی ژنومی پرداختند. آن ها نشان داده اند که SVM عملکرد بهتری از سایرین دارد و انتخاب ویژگی نقش مهمی در تعیین صحت دسته بند های SVM ایفا می کند. شی و همکار ان(52) نیز به این نتیجه رسیده اند که Svm موثر ترین روش برای طبقه بندی پروتئین است. علاوه بر صحت، چالش های دیگر دسته بندی توالی ژنومی، شامل تسريع طبقه بندی برای مدیریت داده های حجمیم است.

#### 4-2 داده های سری های زمانی

داده های سری های زمانی نوع مهمی از داده های توالی یا دنباله ای می باشند. در کتابخانه داده های سری های زمانی، داده های سری های زمانی در 22 حوزه از جمله کشاورزی، شیمی، سلامت، مالی، صنعت و غیره جمع اوری شده اند داده های سری های زمانی UCR مجموعه ای از دیتا است ها را به عنوان معیار ارزیابی روش های دسته بندی سری های زمانی ارایه می کند

برای داده های سری های زمانی ساده، برای استفاده از روش های مبتنی بر ویژگی، انتخاب ویژگی یک فرایند چالش بر انگیز می باشد زیرا ما قادر به شمارش ویژگی ها با داده های عددی نیستیم. از اینروی روش های فاصله ای برای طبقه بندی سری های زمانی استفاده می شوند. نشان داده شده است که در مقایسه ها طیف وسیعی از دسته ند ها، SVM، HMM و نزدیک ترین همسایه دارای اهمیت زیادی می باشند. به منظور استفاده از روش های مبتنی بر ویژگی در سری های زمانی ساده، قبل از انتخاب ویژگی، داده های سری های زمانی باقیستی به توالی های نمادین از طریق تبدیل نمادین تبدیل شوند. در مقایسه با روش های فاصله ای، روش های مبتنی بر ویژگی موجب تسريع فرایند دسته بندی شده و یک سری نتایج قابل تفسیر را ارایه می کند. روش های مبتنی بر مدل برای دسته بندی سری های زمانی ساده نظیر HMM استفاده می شوند.

طبقه بندی سری ها ای زمانی چند متغیره برای تشخیص حرکت و اشاره استفاده شده است. داده ها ای چند مغایره از طریق مجموعه ای از سنسور ها برای اندازه گیری حرکت اشیا در مناطق مختلف تولید می شوند. برای دسته بندی سری ها ای زمانی چند متغیره، کادوس و همکاران یک دسته بند مبتنی بر ویژگی را پیشنهاد کرده اند. برخی از فرآئیگی ها برای توصیف روند افزایشی یا کاهشی، سری ها ای زمانی چند متغیره استفاده می شوند. لی و همکاران روشی را برای تبدیل سری ها ای زمانی چند متغیره به یک بردار از طریق تجزیه ارزش عددی و تبدیلات دیکر ارایه کرده اند. SVM برای دسته بندی بردارها استفاده می شود

#### 3- داده های متنی

دسته بندی توالی به طور گسترده ای در بازیابی اطلاعات برای دسته بندی متن و استناد استفاده می شود. رایج ترین روش ها برای دسته بندی متن شامل بیز ساده، و SVM می باشند. دسته بندی متن دار ای انواع مختلفی می باشد که شامل دسته بندی چند برچسبی، دسته بندی سلسله مرتبی، و دسته بندی متن نیمه نظارت شده است. شبستانی و همکاران، یک مطالعه دقیق را بر روی دسته بندی متنی ارایه کرده اند.

#### 5- نتیجه گیری

در این مقاله ما یک مروری بر طبقه بندی و دسته بندی متن داشتیم. داده ها ای توالی به 5 زیر نوع طبقه بندی شد. روش های دسته بندی توالی در روش های مبتنی بر ویژگی، روش های مبتنی بر فاصله توالی و روش های مبتنی بر مدل طبقه بندی شد. سپس دسته بندی توالی متعارف نیز بحث شد. در نهایت، روش های مختلف در حوزه های کاربردی مختلف مقایسه شدند

نتایج نشان می دهد که بیشتر کارها بر دسته بندی توالی های نمادین ساده و سری های زمانی ساده تاکید دارند. اگرچه مطالعات کمی بر روی سری های زمانی چند متغیره وجود دارد مسئله طبقه بندی داده های توالی هنوز حل نشده است. به علاوه بیشتر روش های دسته بندی توالی متعارف تخصیص داده شده است. استریمینگ طبقه بندی توالی، اولیه، نیمه نظارت شده و ترکیبی از این مسائل بر روی داده های توالی پیچیده که دارای کاربردهای زیادی می باشند می توانند چالشی برای مطالعات اینده باشند.



این مقاله، از سری مقالات ترجمه شده رایگان سایت ترجمه فا میباشد که با فرمت PDF در اختیار شما عزیزان قرار گرفته است. در صورت تمایل میتوانید با کلیک بر روی دکمه های زیر از سایر مقالات نیز استفاده نمایید:

✓ لیست مقالات ترجمه شده

✓ لیست مقالات ترجمه شده رایگان

✓ لیست جدیدترین مقالات انگلیسی ISI

سایت ترجمه فا؛ مرجع جدیدترین مقالات ترجمه شده از نشریات معترض خارجی