

Distinguishing Multiple Concurrent Esophageal Motility Disorders using High-Resolution Manometry

Rafieivand, Safa¹ / Moradi, Mohammad Hassan² / Momayez Sanat, Zahra^{3*} / Asl Soleimani, Hosein⁴

¹ - Ph.D. Student, Biomedical Engineering Department, Amirkabir University of Technology, Tehran, Iran

² - Professor, Biomedical Engineering Department, Amirkabir University of Technology, Tehran, Iran

³ - Assistant Professor, Digestive Diseases Research Institute, Tehran University of Medical Sciences, Tehran, Iran

⁴ - Professor, Digestive Diseases Research Institute, Tehran University of Medical Sciences, Tehran, Iran

ARTICLE INFO

DOI: 10.22041/ijbme.2023.2014226.1866

Received: 24 October 2023

Revised: 20 November 2023

Accepted: 28 November 2023

KEYWORDS

Esophageal Manometry
Esophageal Mobility Disorders
Multi-Label Classification
Fuzzy Classification

ABSTRACT

Esophageal mobility disorders are a type of digestive system problem characterized by abnormal bolus movement in the esophagus. The standard diagnostic method for these kinds of disorders is High-Resolution Manometry (HRM). Despite the availability of guidelines like “Chicago” for the analysis of HRM results, diagnosis is still a challenging task that relies on the physician's skills or requires additional assessment modalities. Additionally, it is typical for esophageal mobility disorders to co-occur in one person, leading to a more complex situation for problem identification. The current study focuses on cases who suffering from more than one disorder simultaneously. Then the problem of disorder identification can be interpreted as a multi-label classification problem. Consequently, the fuzzy classifier architecture that was previously introduced for automatic single-disorder diagnosis by the authors is modified. The presented classifier in this paper not only learns the input space from the samples but also utilizes the comorbidity of disorders to enhance the prediction results. The outcomes show that adding this information to the learning procedure of the base classifier enhances its performance and generates a new fuzzy classifier that overcomes other multi-label classifiers. The presented method is able to differentiate esophageal mobility disorders with an average Hamming loss of 0.18 ± 0.08 which is better than other competitor methods.

*Corresponding Author

Address: Digestive Diseases Research Institute, Tehran University of Medical Sciences, Tehran, Iran

Postal Code: 1411713014

E-Mail: z-msanat@sina.tums.ac.ir

Tel: +98-21-82415104





تشخیص اختلالات توام حرکتی مری بر اساس دادگان مانومتری رزولوشن بالا

رفیعی‌وند، صفا^۱ / مرادی، محمدحسن^۲ / ممیز صنعت، زهرا^{۳*} / اصل سلیمانی، حسین^۴

^۱ - دانشجوی دکتری، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

^۲ - استاد، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

^۳ - استادیار، پژوهشکده‌ی بیماری‌های گوارش و کبد، دانشگاه علوم پزشکی تهران، تهران، ایران

^۴ - استاد، پژوهشکده‌ی بیماری‌های گوارش و کبد، دانشگاه علوم پزشکی تهران، تهران، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2023.2014226.1866

پذیرش: ۷ آذر ۱۴۰۲

بازنگری: ۲۹ آبان ۱۴۰۲

ثبت در سامانه: ۲ آبان ۱۴۰۲

چکیده

واژه‌های کلیدی

اختلالات حرکتی مری یکی از بیماری‌های سیستم گوارش است که در آن حرکت توده‌ی غذایی در طول مری به صورت طبیعی اتفاق نمی‌افتد. روش استاندارد برای تشخیص این موارد، بهره‌گیری از مانومتری رزولوشن بالا است. علی‌رغم وجود راهنماهای پزشکی مانند راهنمای شیکاگو برای تحلیل نتایج مانومتری، این موضوع کماکان امر دشواری بوده که نیاز به تجربه‌ی بالای پزشک و یا استفاده از دیگر روش‌های کمکی ثانویه برای تشخیص دارد. از سوی دیگر بسیاری از اختلالات مذکور می‌توانند به صورت توام در یک فرد ظاهر شده و تشخیص‌گذاری را پیچیده‌تر کنند. تمرکز این مطالعه روی بیمارانی با بیش از یک اختلال به صورت توام بوده و موضوع تشخیص بیماری به صورت یک مساله‌ی طبقه‌بندی چندبرچسبی مطرح شده است. از این رو ساختار طبقه‌بند فازی که پیش‌تر توسط نویسندگان این مقاله به منظور تشخیص تک‌بیماری معرفی شده، توسعه یافته است تا علاوه بر یادگیری فضای ورودی نمونه‌ها، از اطلاعات هم‌شیوعی اختلالات نیز برای بهبود پیش‌بینی استفاده کند. نتایج به دست آمده نشان داده که اضافه کردن این اطلاعات به فرایند تعلیم طبقه‌بند نه تنها عمل کرد آن را نسبت به حالت پایه به شکل قابل ملاحظه‌ای افزایش داده، بلکه منجر به ساختاری از طبقه‌بندی کننده‌ی فازی شده است که نسبت به روش‌های دیگر طبقه‌بندی چندبرچسبی برتری دارد. روش معرفی شده قادر است با هزینه‌ی همینگ متوسط 0.118 ± 0.008 اختلالات حرکتی مری را تشخیص دهد که نسبت به سایر روش‌ها عمل کرد بهتری به شمار می‌آید.

مانومتری مری

اختلالات حرکتی مری

طبقه‌بندی چندبرچسبی

طبقه‌بندی فازی

*نویسنده‌ی مسئول

نشانی: پژوهشکده‌ی بیماری‌های گوارش و کبد، دانشگاه علوم پزشکی تهران، تهران، ایران

تلفن: ۰۲۱-۸۲۴۱۵۱۰۴-۹۸

پست الکترونیک: z-msanat@sina.tums.ac.ir

کد پستی: ۱۴۱۱۷۱۳۰۱۴

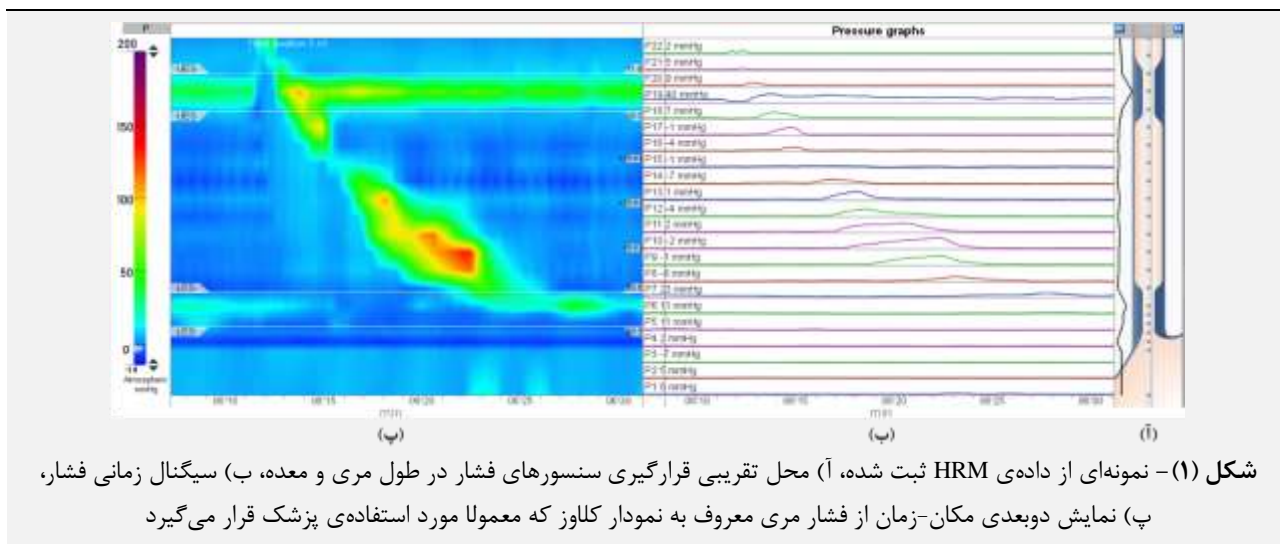


۱- مقدمه

یکی از بخش‌های مهم در سیستم گوارش، حرکت و جلو رفتن توده‌ی غذا در طول لوله‌ی گوارش است. به طور خاص در اولین مرحله، توده‌ی غذایی جویده شده باید از حفره‌ی دهانی و از طریق مری به معده منتقل شود. در این فرایند، عضلات متعددی از جمله عضلات اسفنکتر فوقانی و تحتانی مری و عضلات صاف اطراف مری درگیر هستند که برای یک بلع موفق باید هر یک در زمان صحیح و با شدت مناسب فعال شوند. در غیر این صورت فرد دچار انواع اختلالات حرکتی مری شده که با علائمی هم‌چون درد قفسه‌ی سینه، احساس گیر کردن غذا در گلو (دیسفاژی^۱) و ... همراه است که زندگی فرد مبتلار را به شکل قابل ملاحظه‌ای تحت تاثیر قرار می‌دهد [۱].

به منظور بررسی عمل‌کرد حرکتی مری از روشی به نام مانومتری بهره گرفته شده که در انواع رزولوشن بالای آن حداقل ۱۹ سنسور فشار از طریق یک کاتتر در طول مری قرار گرفته و

فشار مری در طول مدت فرایند بلع ثبت می‌شود [۲]. نمونه‌ای از یک ثبت مانومتری که در آن سیگنال‌های فشار هر سنسور به همراه تصویر ساخته شده از این سیگنال‌ها مشخص بوده در شکل (۱) نشان داده شده است. تشخیص‌گذاری نوع اختلال حرکتی توسط پزشک متخصص عمدتاً بر اساس راهنمایی موسوم به شیکاگو [۳] همراه با به کارگیری اطلاعات آزمون‌های تشخیصی دیگر مانند تصویر رادیولوژی و تست بلع باریم^۲ انجام می‌شود. اگر چه وجود این راهنمای استاندارد تا حد زیادی فرایند تشخیص را بهبود داده اما مطالعات نشان می‌دهد که تشخیص اختلال بر اساس داده‌ی مانومتری رزولوشن بالا^۳ (HRM) به دلیل عواملی هم‌چون یکسان نبودن تعیین پارامترهای کمی مرتبط با HRM در بین پزشکان مختلف [۴]، وجود عوامل ثانویه مؤثر در استانداردسازی تشخیص مانند نژاد، قد و وزن [۶] و تفاوت در سیستم‌های اندازه‌گیری [۷] هم‌چنان امری چالش برانگیز است.



شکل (۱) - نمونه‌ای از داده‌ی HRM ثبت شده، (آ) محل تقریبی قرارگیری سنسورهای فشار در طول مری و معده، (ب) سیگنال زمانی فشار، (پ) نمایش دوبعدی مکان-زمان از فشار مری معروف به نمودار کلاوز که معمولاً مورد استفاده‌ی پزشک قرار می‌گیرد

مطالعات معدودی در راستای معرفی روش‌های تشخیص خودکار با استفاده از HRM انجام شده است. قریب به اتفاق این مقالات مربوط به سه سال اخیر بوده که این موضوع نشان دهنده‌ی اهمیت یافتن رویکرد استفاده از رایانه در تشخیص‌گذاری HRM است. کارنییل و هم‌کارانش یک مدل ریاضی پارامتری برای سیگنال فشار ثبت شده در مری ارائه کرده‌اند [۸]. آن‌ها با تحلیل شباهت توزیع پارامترهای مدل در هر سنسور فشار قادر به تشخیص برخی از اختلالات حرکتی مری شده‌اند [۹]. اخیراً ونگ و هم‌کارانش با رویکرد یادگیری عمیق تلاش کرده‌اند تا روشی برای تشخیص شدت اختلال ارائه دهند. آن‌ها ابتدا با استفاده از یک شبکه‌ی کانولوشنال دوبعدی محل بلع‌ها را تشخیص داده و سپس با ویژگی‌های به دست آمده از یک شبکه‌ی کانولوشنال دوطرفه‌ی LSTM بلع‌ها را در سه گروه نرمال، خفیف و شدید دسته‌بندی کرده‌اند [۱۰]. آن‌ها همچنین رویکرد مشابهی را برای درجه‌بندی شدت موج فشاری حرکت پریستالتیک مری^۴ با استفاده از شبکه‌های عصبی گرافی به کار گرفته‌اند [۱۱]. در تحقیق کو و هم‌کارانش از سه شبکه‌ی عصبی کانولوشنال مجزا برای طبقه‌بندی الگوی بلع، الگوی فشرده شدن مری^۵ و رگرسیون مقدار IRP^۶ (از جمله پارامترهای

مطالعات معدودی در راستای معرفی روش‌های تشخیص خودکار با استفاده از HRM انجام شده است. قریب به اتفاق این مقالات مربوط به سه سال اخیر بوده که این موضوع نشان دهنده‌ی اهمیت یافتن رویکرد استفاده از رایانه در تشخیص‌گذاری HRM است.

کارنییل و هم‌کارانش یک مدل ریاضی پارامتری برای سیگنال فشار ثبت شده در مری ارائه کرده‌اند [۸]. آن‌ها با تحلیل شباهت توزیع پارامترهای مدل در هر سنسور فشار قادر به تشخیص برخی از اختلالات حرکتی مری شده‌اند [۹]. اخیراً ونگ و هم‌کارانش با رویکرد یادگیری عمیق تلاش کرده‌اند تا

^۱ Esophageal Contractile Vigor

^۲ Esophageal Pressurization

^۳ Integrated Relaxation Pressure

^۴ Dysphagia

^۵ Barium Swallow Test

^۶ High-Resolution Manometry (HRM)



گراف حاصل از این فرایند باید به فضای ویژگی برده شود تا توسط طبقه‌بند قابل استفاده باشد. برای این کار از یک شبکه‌ی عصبی گرافی^۲ (GNN) بهره گرفته شده است. شبکه‌ی GNN قادر است با حداقل از دست رفتن اطلاعات یک گراف را فشرده سازد و بر خلاف روش‌هایی مانند گراف کرنل‌ها یا استفاده از معیارهای مبتنی بر خصوصیات گره‌ها که محلی هستند می‌تواند خواص عمومی گراف را نیز حفظ کند. در این مقاله از بین شبکه‌های گرافی، شبکه‌های گرافی کانولوشنی انتخاب شده که به دلیل خواص ریاضی خود نسبت به شیفت و مقیاس ورودی مقاوم‌تر هستند. شبکه‌ی به کار گرفته شده شامل سه لایه‌ی کانولوشنال چیشیف [۱۴] با تابع غیرخطی ReLU و یک لایه‌ی خطی در انتهای آن بوده که در مرحله‌ی آموزش به عنوان یک طبقه‌بند تعلیم داده شده است. سپس در مرحله‌ی تست، لایه‌ی خطی حذف شده و خروجی لایه‌ی قبل از آن به عنوان ویژگی مورد استفاده قرار گرفته است. جزئیات این شبکه‌ی مورد استفاده در مقاله‌ی [۱۵] تشریح شده است.

۲-۲- طبقه‌بند فازی چندبرچسبی

تشخیص هم‌زمان چند اختلال برای یک نمونه (بیمار) در فضای طبقه‌بندی به این معنی است که هر نمونه بتواند بیش از یک برچسب داشته باشد. به این موضوع در ادبیات شناسایی الگو، مساله‌ی طبقه‌بندی چندبرچسبی گفته می‌شود. به طور کلی دو رویکرد برای حل این مدل مسائل پیشنهاد شده است. در روش اول، طبقه‌بند‌های موجود به شکلی اصلاح می‌شوند که قادر به حل مساله‌ی چندبرچسبی باشند. برای مثال می‌توان به روش‌های ML-KNN^۳ [۱۶]، ML-DT^۴ [۱۷] و AdaBoost.MH [۱۸] اشاره کرد که به ترتیب نسخه‌های گسترش یافته‌ی روش‌های متداول KNN، درخت تصمیم و AdaBoost هستند. در رویکرد دوم، مساله‌ی چندبرچسبی به یک مساله‌ی دو یا چندکلاسه تقلیل داده می‌شود که در آن خروجی نهایی از ترکیب نتایج طبقه‌بندی کننده‌های پایه به دست می‌آید. ساختارهای طبقه‌بندی ارتباط دودویی^۵، مجموعه‌ی توانی برچسب‌ها^۶ و طبقه‌بند‌های زنجیره‌ای به این منظور توسعه داده شده‌اند [۱۹].

وجه تمایز اصلی انواع مدل‌های ذکر شده، نحوه‌ی یادگیری ارتباط بین برچسب‌ها و میزان پیچیدگی ساختار بوده به طوری که ساختار ارتباط دودویی با وجود مزیت سادگی، دارای پیش‌فرض مستقل بودن برچسب‌ها از یک‌دیگر است که در

معرفی شده در راهنمای شیکاگو) بهره گرفته شده است. سپس از بردار ویژگی حاصل از این سه خروجی برای تمام بلع‌های یک فرد جهت تشخیص نوع اختلال استفاده شده است [۱۲]. هر یک از این مطالعات دارای محدودیت‌های خاص خود بوده که امکان عملیاتی شدن آن‌ها را در فضای کلینیکی کاهش می‌دهد. برای مثال مدل ارائه شده در مقاله‌ی [۸] صرفاً برای برخی اختلالات معتبر است و در مواردی مانند فشار سرتاسری مری^۱ قابل استفاده نیست. از سوی دیگر تفکیک شدت اختلال اگر چه در راهنمای شیکاگو به منظور دسته‌بندی اختلالات ذکر شده اما به سادگی توسط پزشک قابل تشخیص است. با این حال مساله‌ی مهمی که در هیچ یک از مطالعات پیشین به آن اشاره نشده، مواردی است که در آن بیمار به صورت هم‌زمان از چند اختلال حرکتی در مری رنج می‌برد. در این بیماران غالباً مقادیر و آستانه‌های استاندارد در راهنمای شیکاگو معتبر نبوده و تشخیص نهایی وابستگی زیادی به تجربه‌ی پزشک دارد [۱۳]. در این مطالعه با استفاده از یک ساختار طبقه‌بندی کننده‌ی فازی با خروجی چندبرچسبی، یک سیستم تشخیصی معرفی شده است که توانایی تشخیص هم‌زمان چند اختلال را دارد. در ادامه در بخش ۲ ابتدا نحوه‌ی تبدیل دادگان HRM به فضای ویژگی تشریح شده و سپس ساختار طبقه‌بندی کننده‌ی فازی چندبرچسبی معرفی شده است. در نهایت جزئیات پیاده‌سازی و نتایج به دست آمده در بخش ۳ ارائه شده و بخش ۴ نیز به جمع‌بندی و نتیجه‌گیری اختصاص داده شده است.

۲- مواد و روش‌ها

۲-۱- تبدیل داده‌ی خام به فضای ویژگی

سیگنال‌های ثبت شده‌ی HRM دارای ماهیت زمانی-مکانی بوده به طوری که هر سنسور اطلاعات فشار را در مکان مشخصی از مری در طول زمان ثبت می‌کند. از این رو مدل کردن ارتباطات زمانی-مکانی داده می‌تواند گزینه‌ی مناسبی به عنوان ویژگی در این نوع دادگان باشد. به این منظور در هر بلع ۲۵ ثانیه‌ای، سیگنال فشار هر سنسور به ۱۰ قطعه‌ی زمانی جداگانه و بدون هم‌پوشانی تقسیم شده که حاصل آن برای ۲۲ کانال سنسور، ۲۲۰ قطعه‌ی سیگنال زمانی-مکانی است. سپس ارتباط این قطعات به صورت گرافی مدل شده که هر راس آن متناظر با یکی از این قطعات بوده و بین هر دو راس در صورتی یال تشکیل شده است که معیار همبستگی پیرسون بین قطعه‌ی سیگنال‌های متناظر آن‌ها بیش از ۰/۸ باشد.

^۱ Multi-Label Decision Tree

^۵ Binary Relevance (BR)

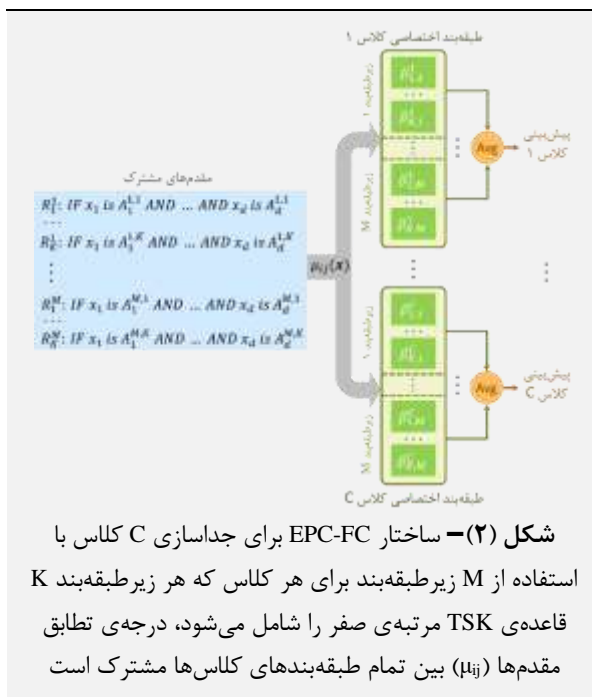
^۶ Label Power-Set (LP)

^۱ Pan-Pressurization

^۲ Graph Neural Network

^۳ Multi-Label K-Nearest Neighbors

در این رابطه $\mu_k(x)$ درجه‌ی انطباق ورودی x با قاعده‌ی k -ام است. در ساختار EPC-FC که در شکل (۲) نشان داده شده یک طبقه‌بند چندکلاسه‌ی نسبتاً پیچیده به چند طبقه‌بند ساده‌تر شکسته شده که هر یک به صورت تخصصی برای جدا کردن یکی از کلاس‌ها آموزش داده شده است. به این ترتیب که مقدم قواعد بین تمام طبقه‌بندها مشترک است اما تالی به تناسب هر کلاس در فرایند یادگیری از دادگان تعلیم، تنظیم می‌شود. این کار به طور قابل ملاحظه‌ای تعداد پارامترهای طبقه‌بند و میزان محاسبات را کاهش می‌دهد [۱۵].



شکل (۲) - ساختار EPC-FC برای جداسازی C کلاس با

استفاده از M زیرطبقه‌بند برای هر کلاس که هر زیرطبقه‌بند K قاعده‌ی TSK مرتبه‌ی صفر را شامل می‌شود، درجه‌ی تطابق مقدم‌ها (μ_{ij}) بین تمام طبقه‌بندهای کلاس‌ها مشترک است

به منظور افزایش تعمیم‌پذیری طبقه‌بندی کننده‌ی اختصاصی هر کلاس از روش یادگیری همبستگی منفی^۲ بهره گرفته شده است. در این روش، طبقه‌بند پایه به چند زیرطبقه‌بند تفکیک شده و تلاش می‌شود خطای آموزش زیرطبقه‌بندها تا حد ممکن مستقل از یکدیگر باشد [۲۳]. به این ترتیب هر زیرطبقه‌بند بخشی از فضای ورودی را یاد گرفته که نهایتاً علاوه بر بهبود تعمیم‌پذیری، احتمال بیش‌برازش را نیز تا حد زیادی کاهش می‌دهد [۲۴]. به صورت رسمی اگر مجموعه‌ی دادگان آموزش به صورت $x_n \in \mathbb{R}^d$ که $D = \{(x_1, t_1), \dots, (x_N, t_N)\}$ بوده که بردار ویژگی و t_n برچسب منتظر آن باشد، خروجی کلی (y_{ens}) به صورت رابطه‌ی (۴) است.

$$y_{ens}(x_n) = \sum_{j=1}^M a_j y_j(x_n) \quad \sum_{j=1}^M a_j = 1 \quad (4)$$

اغلب موارد صحیح نمی‌باشد. برای مثال در طبقه‌بندی تصاویر، در عکس‌هایی که دارای برچسب ساحل باشند، معمولاً برچسب دریا نیز جزو برچسب‌های اختصاص یافته به تصویر است و عدم در نظر گرفتن این هم‌پیشامدی منجر به افت عمل کرد طبقه‌بند می‌شود [۲۰]. در طرف دیگر، روش‌هایی مانند مجموعه‌ی توانی، به ازای در نظر گرفتن تمام ارتباطات برچسب‌ها، نیاز به آموزش تعداد بسیار زیادی طبقه‌بند دارند به طوری که در یک مساله با L برچسب، این ساختار نیاز به 2^L طبقه‌بند دودویی داشته و عملاً استفاده از آن در مسائل بزرگ مقدور نخواهد بود [۲۱]. در این طیف، رویکردهای مبتنی بر اصلاح طبقه‌بندهای پایه منجر به ساختارهای بهینه‌تری می‌شوند که علی‌رغم در نظر گرفتن ارتباطات برچسب‌ها تا حد کافی، از پیچیدگی معقولی نیز برخوردار هستند.

ساختار بیان شده در این مقاله بر اساس طبقه‌بند EPC-FC^۱ ارائه شده که پیش‌تر توسط نویسندگان برای طبقه‌بندی تک‌برچسبی دادگان HRM گسترش یافته و نتایج قابل قبولی را در این موضوع از خود نشان داده است [۱۵].

در ادامه ابتدا ساختار EPC-FC به طور خلاصه تشریح شده، سپس نحوه‌ی گسترش آن برای موضوع چندبرچسبی بیان شده و در نهایت نحوه‌ی آموزش این ساختار نیز شرح داده شده است.

۲-۲-۱- طبقه‌بندی کننده‌ی پایه

طبقه‌بندی کننده‌ی فازی EPC-FC بر اساس ساختار طبقه‌بند استاندارد تاکاشی-سوجینو-کنگ (TSK) مرتبه‌ی صفر ایجاد شده است. در این نوع طبقه‌بند قواعد فازی به صورت زیر است.

$$R_k: IF x_1 is A_1^k AND x_2 is A_2^k \dots x_d is A_d^k THEN y_k(x) = \beta_k \quad (1)$$

در این رابطه R_k قاعده‌ی k -ام ($k=1, \dots, K$) از مجموعه‌ی قواعد، بردار $x = [x_1, \dots, x_d]$ نمونه‌ی ورودی، β_k مقدار ثابت تالی این قاعده و A_i^k تابع عضویت فازی متناظر با بعد i -ام ورودی بوده [۲۲] که در این جا به صورت تابع گوسی مطابق رابطه‌ی (۲) در نظر گرفته شده است.

$$\mu_{ik}(x_i) = \exp\left(-\frac{(x_i - c_{ik})^2}{\delta_{ik}}\right) \quad (2)$$

بدون در نظر گرفتن نافازی‌سازی، خروجی طبقه‌بند TSK به صورت زیر است.

$$y = \sum_{k=1}^K \mu_k(x) y_k \quad \mu_k(x) = \prod_{i=1}^d \mu_{ik}(x_i) \quad (3)$$

^۲ Negative Correlation Learning (NCL)

^۱ Expert-Per-Class Fuzzy Classifier



جزء اول این رابطه خطای هر زیرطبقه‌بند و جزء دوم جریمه‌ی مربوط به NCL بوده که در رابطه‌ی (۵) نیز محاسبه می‌شود. جزء سوم k^r مدل‌کننده‌ی شباهت بین برچسب‌ها بوده و نهایتاً عبارت $\|\beta^r\|_2^2$ عبارت رگولاریزاسیون است. مقادیر λ ، γ و α نیز ثابت بوده و برای تنظیم اثر عبارت جریمه‌ی متناظر کاربرد دارند. عبارت جریمه‌ی k^r مطابق رابطه‌ی (۸) تعریف می‌شود.

$$k^r = \frac{1}{2} \sum_{n=1}^N \sum_{\substack{c=1 \\ c \neq r}}^C \omega_{rc} (y_{ens}^r(x_n) - t_n^c)^2 \quad (۸)$$

در این رابطه $y_{ens}^r(x_n)$ پیش‌بینی طبقه‌بندی‌کننده‌ی اختصاصی کلاس r برای نمونه‌ی x_n و ω_{rc} مطابق رابطه‌ی (۹) وابسته به شباهت بین بردارهای برچسب کلاس c و r است.

$$\omega_{rc} = S([t_1^r, \dots, t_N^r], [t_1^c, \dots, t_N^c]) \in \mathbb{R} \quad (۹)$$

در این رابطه S می‌تواند هر نوع معیار شباهت قابل تعریف بین دو بردار دودویی باشد که در این‌جا از معیار شباهت جاکارد استفاده شده است که به صورت زیر تعریف می‌شود [۲۷].

$$S_{jaccard}(a, b) = \frac{N_{11}}{N_{11} + N_{01} + N_{10}} \quad (۱۰)$$

در این رابطه N_{11} تعداد مواردی که بردارهای a و b هم‌زمان برابر با ۱، N_{10} تعداد مواردی که بردار a برابر ۱ و بردار b برابر صفر و N_{01} تعداد موارد عکس این حالت است.

۲-۲-۳- آموزش طبقه‌بند

برای تعلیم طبقه‌بند باید پارامترهای β_{mk}^c بر اساس داده‌های آموزش مشخص شوند. رابطه‌ی (۷) نسبت به پارامترهای β از درجه‌ی ۲ بوده و یک مساله‌ی بهینه‌سازی مقعر است. لذا با محاسبه‌ی گرادیان و حل معادلات حاصل از آن می‌توان کمینه‌ی تابع را به صورت تحلیلی محاسبه کرد.

$$\frac{\partial e_m^r}{\partial \beta_{jk}^r} = \sum_{n=1}^N \left[\frac{\partial y_m^r}{\partial \beta_{jk}^r} (y_m^r - t_n^r) + \lambda \frac{\partial h_m}{\partial \beta_{jk}^r} \right] + \gamma \frac{\partial}{\partial \beta_{jk}^r} k^r + 2\alpha \beta_{jk}^r = 0 \quad (۱۱)$$

رابطه‌ی (۱۱) به ازای $k=1, \dots, K$ برای هر زیرطبقه‌بند قابل محاسبه است. با توجه به وجود M زیرطبقه‌بند، در مجموع $K \times M$ معادله برای هر طبقه‌بند اختصاصی به دست می‌آید.

در این رابطه، a_j وزن‌های میانگین‌گیری بوده که در این‌جا برابر با $1/M$ در نظر گرفته شده است. بنابراین خطای هر انسمبل را می‌توان بر اساس رابطه‌ی (۵) بیان کرد.

$$e_j = \frac{1}{2} \sum_{n=1}^N (y_j(x_n) - t_n)^2 + \lambda h_j(x_n) \quad (۵)$$

در این رابطه جزء اول خطای مجموع مربعات بوده و جزء دوم جریمه‌ی NCL است که با ضریب λ اعمال شده و در آن h_j مطابق رابطه‌ی (۶) محاسبه می‌شود.

$$h_j(x_n) = (y_j(x_n) - y_{ens}(x_n)) \sum_{p \neq j}^M (y_p(x_n) - y_{ens}(x_n)) = -(y_j(x_n) - y_{ens}(x_n))^2 \quad (۶)$$

توصیف مفهومی h_j را می‌توان به صورت همبستگی بین خطای زیرطبقه‌بند j -ام با دیگر زیرطبقه‌بندها بیان کرد [۲۵].

۲-۲-۲- مدل‌سازی همبستگی برچسب‌ها

اعمال کردن همبستگی برچسب‌ها در طبقه‌بندی چندبرچسبی نقشی کلیدی را ایفا کرده [۲۶] که روش‌های مختلفی برای آن ارائه شده است. در این‌جا تابع هزینه‌ی طبقه‌بند کلی به نحوی اصلاح شده است که خطای طبقه‌بند اختصاصی هر کلاس نه تنها به برچسب کلاس متناظر آن وابسته باشد، بلکه اختلاف پیش‌بینی آن با دیگر کلاس‌ها نیز به تناسب شباهت برچسب دو کلاس دارای جریمه باشد. به بیان ریاضی فرض کنید مجموعه‌ی دادگان تعلیم به صورت $D = \{(x_1, t_1), \dots, (x_N, t_N)\}$ باشد که t_n بردار برچسب‌های نمونه‌ی n -ام به ازای تمام C کلاس موجود بوده و روابط زیر برقرار است.

$$t_n = [t_n^1, \dots, t_n^C] \quad t_n^c \in \{0, 1\} \quad c = 1, \dots, C$$

هم‌چنین بردار زیر در برگیرنده‌ی تمام مقادیر ثابت تالی قواعد TSK برای کلاس c بوده که در آن β_{mk}^c مربوط به قاعده‌ی $k=1, \dots, K$ از زیرطبقه‌بند $m=1, \dots, M$ است.

$$\beta^c = [\beta_{11}^c, \dots, \beta_{1K}^c, \dots, \beta_{M1}^c, \dots, \beta_{MK}^c]_{1 \times MK}$$

در این صورت تابع هزینه‌ی رابطه‌ی (۵) را می‌توان به شکل زیر برای طبقه‌بندی چندبرچسبی اصلاح کرد.

$$e_m^r = \frac{1}{2} \sum_{n=1}^N [(y_m^r(x_n) - t_n^r)^2 + \lambda h_{jm}^r(x_n)] + \gamma k^r + \alpha \|\beta^r\|_2^2 \quad (۷)$$

۳-۲- دادگان HRM

دادگان استفاده شده در این مطالعه مربوط به ۹۶ آزمودنی (۴۵ مرد و ۵۱ زن) با میانگین سنی $47/31 \pm 14/67$ بوده که در پژوهش‌های بیماری‌های گوارش و کبد بیمارستان شریعتی با استفاده از دستگاه Solar GI^۱ ثبت شده است. روال ثبت‌ها بر اساس راهنمای شیکاگو نسخه‌ی ۳ با نرخ نمونه‌برداری ۲۰ هرترز بوده و از هر آزمودنی به طور متوسط $12/58$ ثبت انجام شده است. این دادگان مربوط به اختلالاتی شامل آشالازی نوع ۱، ۲ و ۳، تحرک غیرموثر مری^۲، اسپاسم منتشر مری^۳، عدم وجود حرکات پرستالتیک، فشار بیش از حد اسفنکتر تحتانی مری^۴، فشار کمتر از حد اسفنکتر تحتانی^۵ و گروه نرمال بوده است. جزئیات مجموعه‌ی دادگان در جدول‌های (۱) و (۲) آمده است. در جدول (۱) کاردینالیته‌ی بیان‌گر میانگین تعداد برچسب‌های اختصاص یافته به یک نمونه، چگالی برچسب نمایان‌گر نسبت کاردینالیته‌ی به تعداد برچسب‌های ممکن برای یک نمونه و مجموعه‌ی برچسب‌های یکتا به معنای تعداد ترکیب‌های موجود از برچسب‌ها در کل مجموعه‌ی داده است [۲۸].

جدول (۱) - مشخصات مجموعه‌ی داده‌ی HRM

۱۵	مجموعه‌ی برچسب‌های یکتا
۰/۱۳	چگالی برچسب‌ها
۱/۱۸	کاردینالیته‌ی
۱۲۰۸	تعداد نمونه
۹	تعداد برچسب

جدول (۲) - هم‌شیوعی دوبه‌دوی اختلالات موجود در دادگان
 A1: آشالازی نوع ۱، A2: آشالازی نوع ۲، A3: آشالازی نوع ۳،
 Ab: Absent of peristalsis، HO: Hypo-tensive LES

HE: Hyper-tensive LES، No: نرمال

	A1	A2	A3	IEM	DES	Ab	HO	HE	No
No									۷۲
HE		۳۸	۱۰						۷۱
HO				۴۶	۱۳	۹۳	۱۶۷		
Ab				۱۹		۱۵۶			
DES					۸۸				
IEM				۱۸۴					
A3			۶۱						
A2		۳۱۶							
A1	۳۱۱								

^۱ Hyper-Tensive LES

^۲ Hypo-Tensive LES

$$A = \sum_{n=1}^N \mu_{jk} (y_m^r - t_n^r) - 2\lambda \mu_{jk} \left(1 - \frac{1}{M}\right) (y_m^r - y_{ens}^r)$$

$$= \sum_{n=1}^N \mu_{jk} (x_n) \left[(y_j^r(x_n) - t_n^r) - a (y_j^r(x_n) - y_{ens}^r(x_n)) \right]$$

$$a = 2\lambda(1 - 1/M) \quad (12)$$

با جایگذاری روابط (۳) و (۴) در رابطه‌ی (۱۲) و ساده‌سازی آن می‌توان رابطه‌ی (۱۳) را به دست آورد.

$$A = w_1 \sum_{i=1}^K \beta_{ji}^r T(j, k, j, i) + w_2 \sum_{\ell \neq j}^M \sum_{i=1}^K \beta_{\ell i}^r T(j, k, \ell, i) - T^r(j, k)$$

$$T(j, k, \ell, i) = \sum_{n=1}^N \mu_{jk}(x_n) \mu_{\ell i}(x_n) \quad (13)$$

$$T^r(j, k) = \sum_{n=1}^N \mu_{jk}(x_n) t_n^r$$

در این رابطه $w_1 = 1 - a + a/M$ و $w_2 = a/M$ است. به همین ترتیب برای جریسه‌ی چندبرچسبی نیز می‌توان رابطه‌ی (۱۴) را به دست آورد.

$$\frac{\partial}{\partial \beta_{jk}^r} k^r = \gamma \sum_{n=1}^N \sum_{\substack{c=1 \\ c \neq r}}^C \omega_{rc} \frac{\partial y_{ens}^r}{\partial \beta_{jk}^r} (y_{ens}^r(x_n) - t_n^c) \quad (14)$$

$$= w_3 \sum_{m=1}^M \sum_{p=1}^K \beta_{mp}^r T(j, k, m, p) - w_4 \sum_{\substack{c=1 \\ c \neq r}}^C \omega_{rc} T^c(j, k)$$

در این رابطه $w_4 = \gamma/M$ و $w_3 = \gamma(C-1)/M$ است. بنابراین با قرار دادن روابط (۱۳) و (۱۴) در رابطه‌ی (۱۱) می‌توان به مجموعه‌ی معادلاتی به صورت رابطه‌ی (۱۵) رسید.

$$w_1 \sum_{i=1}^K \beta_{ji}^r T(j, k, j, i) + w_2 \sum_{\ell \neq j}^M \sum_{i=1}^K \beta_{\ell i}^r T(j, k, \ell, i) + w_3 \sum_{m=1}^M \sum_{p=1}^K \beta_{mp}^r T(j, k, m, p) + 2a \beta_{jk}^r \quad (15)$$

$$= T^r(j, k) + w_4 \sum_{\substack{c=1 \\ c \neq r}}^C \omega_{rc} T^c(j, k)$$

در رابطه‌ی بالا $M=1, \dots, M$ و $k=1, \dots, K$ است. این رابطه نسبت به ضرایب β خطی است و از این رو می‌توان آن را به صورت ماتریسی بیان و حل کرد.

^۱ Medical Measurement Systems Co.

^۲ InEffective Mobility (IEM)

^۳ Diffuse Esophageal Spasm (DES)



۳- یافته‌ها و بحث

۳-۱- جزئیات پیاده‌سازی

ارزیابی نتایج طبقه‌بندی به شیوه‌ی اعتبارسنجی متقابل یک‌طرفه^۱ انجام شده است. به این منظور در هر اجرای مربوط به اعتبارسنجی، تمام داده‌های بلع متعلق به یک آزمودنی به عنوان داده‌ی تست خارج شده و از مابقی دادگان برای آموزش استفاده شده و این کار به ازای تمام آزمودنی‌های موجود در دادگان تکرار شده است. برای ایجاد مقدم قواعد فازی، بردار $\xi_{jk} = [\xi_{jk}^1, \dots, \xi_{jk}^d] \in \mathbb{R}^d$ برای هر قاعده تعریف شده که در آن $\xi_{jk}^i \sim N(0.5, 1)$ برقرار بوده و اگر $\xi_{jk}^i > 0.5$ باشد بعد i -ام در تشکیل قاعده‌ی R_{jk} شرکت کرده و در غیر این صورت شرکت نخواهد کرد. سپس به هر یک از متغیرهای تشکیل دهنده‌ی قواعد یکی از متغیرهای زبانی خیلی کم، کم، متوسط، زیاد و خیلی زیاد به صورت تصادفی نسبت داده شده است.

طبقه‌بندی کننده‌ی ارائه شده دارای دو پارامتر اصلی M (تعداد زیرطبقه‌بند در هر طبقه‌بند اختصاصی) و K (تعداد قاعده در هر زیرطبقه‌بند) و سه پارامتر جانبی λ ، α و γ است که برای به دست آوردن بهترین نتیجه باید تنظیم شوند. به همین جهت ۱۵٪ از دادگان (۱۰ آزمودنی) به صورت تصادفی به عنوان دادگان اعتبارسنجی^۲ جدا شده و مابقی دادگان در ارزیابی نتایج مورد استفاده قرار گرفته است. آزمایش‌ها نشان داده که فارغ از مقدار دیگر پارامترها، $\lambda=0/6$ مقداری بهینه است. برای به دست آوردن سایر پارامترها، روش جست‌وجوی تصادفی در فضای $3 \leq M \leq 7$ و $15 \leq M \leq 40$ برای پارامترهای اصلی و برای α با مقادیر $\{0/1, 0/2, 0/5, 0/8\}$ و پارامتر γ با مقادیر $\{0, 0/2, 0/4, 0/6, 0/8, 1\}$ صورت گرفته است. در نتیجه مقادیر بهینه‌ی $M=6$ ، $K=40$ ، $\alpha=0/05$ و $\gamma=1$ به دست آمده است.

۳-۲- ارزیابی

در طبقه‌بندی چندبرچسبی علاوه بر معیارهای متداول در طبقه‌بندی تک‌برچسبی، معیارهای دیگری نیز معرفی شده زیرا بر خلاف طبقه‌بندی تک‌برچسبی که خروجی طبقه‌بند به طور کامل درست یا نادرست بوده، در این حالت ممکن است بخشی از خروجی درست و بخش دیگر نادرست باشد. در واقع طبقه‌بند برای یک نمونه‌ی خاص، تعدادی از برچسب‌ها را صحیح و تعداد دیگری را اشتباه پیش‌بینی خواهد کرد. در این‌جا برای مقایسه‌ی عمل‌کرد ساختار بیان شده با دیگر طبقه‌بندها از تعدادی از پرکاربردترین این معیارها بهره گرفته شده است [۲۹].

۳۰. فرض کنید نمونه‌های طبقه‌بندی شده به تعداد N و مجموعه‌ی برچسب‌های ممکن برای هر نمونه از $L=\{l_1, \dots, l_c\}$ است. هم‌چنین $Y_i \in L$ مجموعه‌ی برچسب‌های واقعی نمونه‌ی Z_i ، x_i مجموعه‌ی برچسب‌های پیش‌بینی شده توسط طبقه‌بند برای x_i و $r_i(l)$ رتبه‌ی برچسب l در پیش‌بینی طبقه‌بند بوده به طوری که مربوط‌ترین برچسب دارای رتبه‌ی ۱ است. معیار هزینه‌ی همینگ^۳ بیان‌گر درصد برچسب‌هایی که به درستی پیش‌بینی نشده‌اند بوده و به صورت رابطه‌ی زیر تعریف شده که در آن Δ تفاوت مقارن^۴ است.

$$HL = \frac{1}{N} \sum_{i=1}^N \frac{|Y_i \Delta Z_i|}{C} \quad (۱۶)$$

سنجه‌ی F ^۵ بیان‌گر میانگین هارمونیک دقت و نرخ یادآوری بوده و به این منظور از آن استفاده می‌شود که هر دوی این معیارها به صورت توأم ارزیابی شوند. سنجه‌ی F به صورت زیر قابل تعریف است.

$$F = \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

$$\text{Precision} = \frac{1}{N} \sum_{i=1}^N \frac{|Y_i \cap Z_i|}{|Z_i|} \quad (۱۷)$$

$$\text{Recall} = \frac{1}{N} \sum_{i=1}^N \frac{|Y_i \cap Z_i|}{|Y_i|}$$

با استفاده از میانگین‌گیری میکرو و ماکرو می‌توان معیارهای ارزیابی در طبقه‌بند تک‌برچسبی را به چندبرچسبی تعمیم داد. فرضاً اگر EM معیاری باشد که روی کلاس l بر اساس مقادیر مثبت درست (TP)، منفی درست (TN)، مثبت اشتباه (FP) و منفی اشتباه (FN) تعریف شود روابط زیر برقرار است.

$$EM_{macro} = \frac{1}{C} \sum_{\ell=1}^C EM(TP_{\ell}, FP_{\ell}, TN_{\ell}, FN_{\ell}) \quad (۱۸)$$

$$EM_{micro} = EM \left(\frac{1}{C} \sum_{\ell=1}^C TP_{\ell}, \frac{1}{C} \sum_{\ell=1}^C FP_{\ell}, \frac{1}{C} \sum_{\ell=1}^C TN_{\ell}, \frac{1}{C} \sum_{\ell=1}^C FN_{\ell} \right) \quad (۱۹)$$

معیار دقت میانگین نیز به صورت رابطه‌ی زیر است.

$$\text{AvgPrecision} = \frac{1}{N} \sum_{i=1}^N \frac{1}{|Y_i|} \sum_{\ell \in Y_i} \frac{|\{\ell' \in Y_i : r_i(\ell') \leq r_i(\ell)\}|}{r_i(\ell)} \quad (۲۰)$$

^۱ Symmetric Difference

^۵ F-Measure

^۱ Leave-One-Subject-Out

^۲ Validation

^۳ Hamming Loss

طبقه‌بندی کننده‌های چندبرچسبی BR پیدا کرده و می‌توان از آن برای این مساله نیز استفاده نمود. در خصوص هر کدام از طبقه‌بندهای رقیب تلاش شده است تا پارامترهای طبقه‌بند به نحوی تعیین شود که بهترین نتایج به دست آید.

۳-۳- نتایج

نتایج طبقه‌بندی توسط روش ارائه شده‌ی ML-EPC-FC در مقایسه با دیگر روش‌ها در جدول (۳) ارائه شده است. برای مقایسه‌ی بهتر، نتایج در هر یک از معیارهای ارزیابی رتبه‌بندی شده و میانگین رتبه‌های هر طبقه‌بند در انتهای جدول آورده شده است. مشاهده می‌شود که روش ML-EPC-FC در مقابل چهار روش دیگر در مجموع عمل کرد بهتری داشته که این موضوع با تست آماری فریمن نیز در سطح معناداری $\alpha=0/05$ تایید شده است ($\chi^2=9/92$, $p=0/042$).

برای مقایسه از سه طبقه‌بند متداول در زمینه‌ی طبقه‌بندی چندبرچسبی استفاده شده است. روش اول ML-KNN بوده که ایده‌ی اصلی آن بر پایه‌ی الگوریتم K نزدیک‌ترین همسایه است [۱۶]. روش ML-KNN با تخمین احتمال پسین بر اساس همسایه‌های هر نمونه و محاسبه‌ی بیز برچسب نمونه را پیش‌بینی می‌کند. روش دوم RaKEL [۳۱] نام داشته که از انواع طبقه‌بند LP بوده که در آن تعدادی انسمبل برای زیرمجموعه‌های برچسب‌ها به شکل LP ساخته شده و طبقه‌بند پایه نیز SVM خطی در نظر گرفته شده است. نهایتاً روش طبقه‌بند OCC نیز به عنوان نماینده‌ی طبقه‌بندهای زنجیره‌ای انتخاب شده است [۳۲]. در OCC ترتیب قرارگیری طبقه‌بندها بر اساس بیشینه کردن ضریب شباهت^۳ شرطی بهینه می‌شود. علاوه بر این موارد، خود طبقه‌بند پایه‌ی EPC-FC در حالتی که جریمه‌ی چندبرچسبی حذف شود ($\gamma=0$) ساختاری مشابه با

جدول (۳) - مقایسه‌ی عمل کرد طبقه‌بندی کننده‌های مختلف چندبرچسبی در مقابل روش پیشنهادی ML-EPC-FC، بهترین نتیجه برای هر معیار با زیرخط مشخص شده است

ML-EPC-FC	EPC-FC	ML-KNN	RaKEL	OCC	
<u>0/18±0/08</u>	0/24±0/08	<u>0/15±0/07</u>	0/21±0/08	<u>0/15±0/08</u>	Hamming Loss
۳	۵	۱/۵	۴	۱/۵	رتبه
<u>0/23±0/13</u>	0/21±0/10	0/21±0/14	0/17±0/13	0/22±0/15	F-Measure
۱	۳/۵	۳/۵	۵	۲	رتبه
<u>0/44±0/25</u>	0/41±0/19	0/41±0/27	0/35±0/25	0/43±0/31	F Micro
۱	۳/۵	۳/۵	۵	۲	رتبه
<u>0/62±0/23</u>	0/60±0/22	0/58±0/23	0/49±0/23	0/54±0/25	Average Precision
۱	۲	۳	۵	۴	رتبه
۱/۵	۳/۵	۲/۸۷۵	۴/۷۵	۲/۳۷۵	رتبه‌ی میانگین

(اعم از خود سنجی F یا میانگین‌های آن) در این حوزه شاخص‌های معتبرتری هستند.

در خصوص مقایسه‌ی عمل کرد طبقه‌بندی در هر یک از اختلالات می‌توان از معیار مساحت زیر نمودار^۵ نرخ تشخیص مثبت صحیح^۶ نسبت به نرخ تشخیص مثبت غلط^۷ بهره گرفت زیرا این معیار در کنار در نظر گرفتن ویژگی‌های حساسیت و ویژه‌گزینی^۸ طبقه‌بند، مستقل از آستانه‌های انتخابی برای تشخیص برچسب‌ها است و می‌توان از آن به عنوان معیاری نسبتاً جامع استفاده کرد. این معیار برای تمام طبقه‌بندی کننده‌های مقایسه شده در تمام کلاس‌ها در شکل (۳) نشان

با توجه به جدول (۳) اگر چه هر دو طبقه‌بند OCC و ML-KNN دارای کم‌ترین هزینه‌ی همینگ هستند ولی این موضوع الزاماً دلیل بر برتری آن‌ها نیست. معیار همینگ اگر چه به صورت کلاسیک رایج‌ترین معیار ارزیابی بوده اما دارای اشکالی ذاتی در مسائل طبقه‌بندی چندبرچسبی است. در این مسائل ماتریس برچسب‌ها عموماً به میزان بالایی تنک بوده و اکثر درایه‌های ماتریس صفر است. در این حالت، طبقه‌بندی غیرحساس^۴ که قادر به شناسایی موارد مثبت درست در برچسب‌ها نباشد، می‌تواند علی‌رغم هزینه‌ی همینگ پایین، عمل کرد ضعیفی داشته باشد. لذا معیارهای مبتنی بر کمیت F

^۵ Area Under Curve (AUC)

^۶ True Positive Ratio (TPR)

^۷ False Positive Ratio (FPR)

^۸ Selectivity

^۱ Random K Label Sets

^۲ Optimized Classifier Chain


^۳ Likelihood

^۴ Non-Sensitive

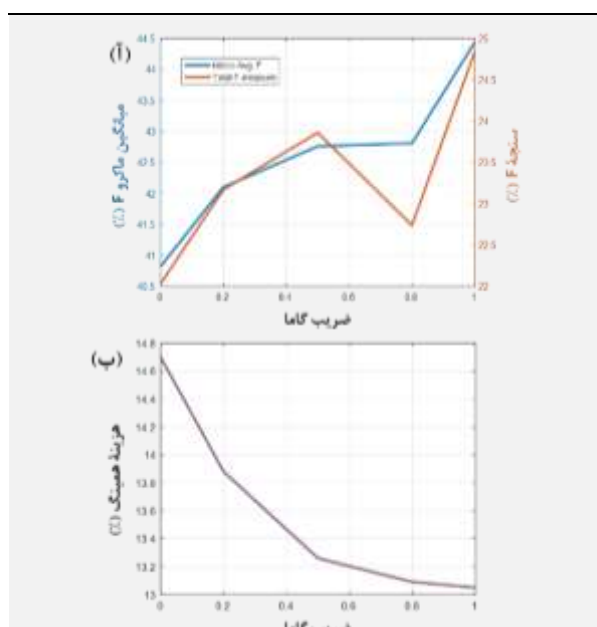


تا ۳ دشوارتر شده که این مشاهده با گزارش‌های بالینی که در آن تشخیص‌گذاری توسط پزشک انجام می‌شود نیز سازگار است [۲]. نمودار ROC طبقه‌بندی‌کننده‌ی ML-EPC-FC به صورت دقیق‌تر در شکل (۴) نشان داده شده که در آن اختلالات HE و آسالازی نوع ۳ کم‌ترین AUC را به خود اختصاص داده‌اند.

داده شده است. با توجه به این شکل می‌توان مشاهده کرد که کلاس HE مربوط به اختلال فشار بیش از حد در اسفنکتر تحتانی مری، مستقل از روش طبقه‌بندی به سادگی قابل تشخیص نیست. به طور مشابه در مورد زیرتیپ‌های اختلال آسالازی نیز می‌توان دید که به ترتیب تشخیص آسالازی نوع ۱



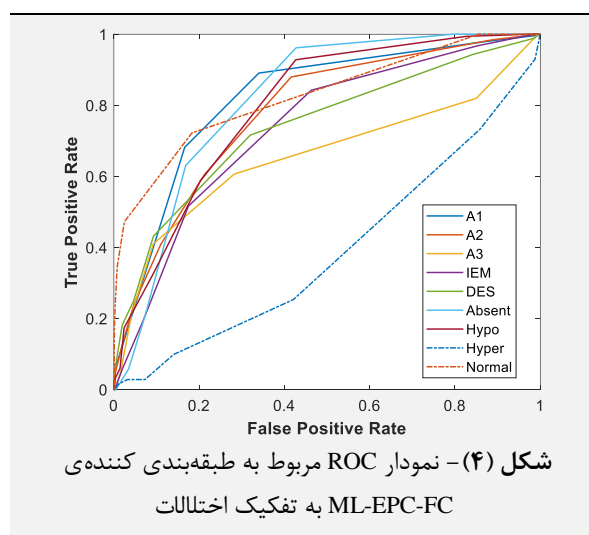
شکل (۳) - مقایسه‌ی معیار AUC در تشخیص اختلالات مختلف به تفکیک طبقه‌بند و کلاس (خط قرمز: مقدار میانگین در هر کلاس)



شکل (۵) - اثر افزایش ضریب جریمه‌ی چندبرچسبی (گاما) روی عمل‌کرد طبقه‌بندی‌کننده‌ی ML-EPC-FC

۴ - نتیجه‌گیری

در این مطالعه تشخیص اختلالات حرکتی مری در شرایطی که بیمار صرفاً دارای یک بیماری نباشد مد نظر قرار گرفته که پیش از این در مطالعات این حوزه مورد بررسی قرار نگرفته است. برای این منظور ساختار طبقه‌بندی‌کننده‌ی فازی چندبرچسبی ML-EPC-FC توسعه داده شده که دارای سه رکن اصلی است. ۱- در این ساختار مجموعه‌ای از طبقه‌بندی‌کننده‌ها به صورت اختصاصی برای هر کلاس در نظر گرفته شده است.



شکل (۵) بیان‌گر اثر افزایش جریمه‌ی حاصل از همبستگی بین برچسب‌ها (جزء k^2 در رابطه‌ی (۷) و ضریب γ مربوط به آن) است. در بخش (الف) این شکل معیارهای مبتنی بر F نمایش داده شده و در قسمت (ب) همین موضوع برای معیار جریمه‌ی همینگ نشان داده شده است. تقریباً در تمام موارد عمل‌کرد طبقه‌بند با افزایش جریمه به صورت یک‌نواخت بهبود پیدا کرده به طوری که بهترین نتایج به ازای ضریب ۱ به دست آمده که به معنی ارزش دادن به همبستگی برچسب‌ها به میزان برابر با خود خطای برچسب است. باید توجه کرد که افزایش این ضریب به مقادیر بیش از ۱ فاقد معنی بوده زیرا معیار جاکارد در رابطه‌ی (۱۰) دارای بازه‌ی بین صفر و ۱ است و افزایش ضریب گاما بیش از ۱ عملاً منجر به اثر عبارت جریمه بیش از خود خطای مجموع مربعات شده که معقول نمی‌باشد.

شده از وی است. مشابه این کار یعنی صحت بر اساس تمام بلع‌های یک آزمودنی در مطالعه‌ی قبلی نویسندگان این مقاله به نتیجه‌ی ۹۲٪ رسیده است [۱۵]. به این ترتیب می‌توان گفت که روش ارائه شده در این مقاله نه تنها نسبت به روش‌های متداول چندبرچسبی برتری دارد بلکه نسبت به روش‌های تک‌برچسبی نیز از عمل‌کرد مناسبی برخوردار است. برای جمع‌بندی باید توجه کرد که در ادبیات این حوزه کم‌تر به موضوع وجود بیماری‌های هم‌شیوع در سیستم‌های تشخیصی پزشکی پرداخته شده است. از طرفی امروزه با گسترش روش‌های طبقه‌بندی، مبحث طبقه‌بندی چندبرچسبی یکی از موضوعات مهمی بوده که حجم زیادی از مطالعات را به خود اختصاص داده است. بنابراین به کارگیری روش‌های طبقه‌بندی چندبرچسبی در تشخیص اختلالات هم‌شیوع می‌تواند منجر به ارائه‌ی سیستم‌های تشخیصی کارآمدتری در آینده شود.

۵- مراجع

- [1] U. C. Ghoshal, Evaluation of Gastrointestinal Motility and its Disorders. New Delhi: Springer India, 2016.
- [2] D. A. Carlson and S. Roman, "Esophageal provocation tests: Are they useful to improve diagnostic yield of high resolution manometry?," *Neurogastroenterol. Motil.*, vol. 30, no. 4, p. e13321, Apr. 2018.
- [3] R. Yadlapati et al., "Esophageal motility disorders on high-resolution manometry: Chicago classification version 4.0 ©," *Neurogastroenterol. Motil.*, vol. 33, no. 1, pp. 1–21, Jan. 2021.
- [4] D. A. Carlson, Z. Lin, W. Kou, and J. E. Pandolfino, "Inter-rater agreement of novel high-resolution impedance manometry metrics: Bolus flow time and esophageal impedance integral ratio," *Neurogastroenterol. Motil.*, vol. 30, no. 6, p. e13289, Jun. 2018.
- [5] M. Jungheim et al., "Calculation of upper esophageal sphincter restitution time from high resolution manometry data using machine learning," *Physiol. Behav.*, vol. 165, pp. 413–424, Oct. 2016.
- [6] L. G. Alcalá Gonzalez, R. A. B. Oude Nijhuis, A. J. P. M. Smout, and A. J. Bredenoord, "Normative reference values for esophageal high-resolution manometry in healthy adults: A systematic review," *Neurogastroenterol. Motil.*, vol. 33, no. 1, Jan. 2021.
- [7] A. Rengarajan, J. Drapekin, A. Patel, and C. P. Gyawali, "Comparison of two high-resolution manometry software systems in evaluating esophageal motor function," *Neurogastroenterol. Motil.*, vol. 28, no. 12, pp. 1836–1843, Dec. 2016.
- [8] E. L. Carniel et al., "A physiological model for the investigation of esophageal motility in

۲- هر طبقه‌بند اختصاصی TSK مرتبه‌ی صفر پایه به تعدادی زیرطبقه‌بند ساده‌تر تجزیه شده و روش آموزش همبستگی منفی برای افزایش ظرفیت یادگیری کل مجموعه‌ی طبقه‌بند اختصاصی اعمال گردیده است.

۳- طبقه‌بندهای اختصاصی هر کلاس به واسطه‌ی شباهت برچسب‌های کلاس‌ها به یک‌دیگر مرتبط شده و عملاً فرایند آموزش تمام طبقه‌بندهای اختصاصی به صورت یک‌پارچه صورت گرفته است.

دادگان پزشکی به ویژه دادگانی که در محیط کلینیکی ثبت شده و کنترل‌های خاصی برای تمیز و دقیق بودن داده اعمال نمی‌شود، معمولاً جزو دادگانی هستند که طبقه‌بندی آن‌ها به سادگی مقدور نیست. دادگان HRM استفاده شده در این مطالعه نیز از این نوع هستند. این نوع داده عمدتاً با نویز و آرتیفکت‌های قابل توجهی همراه است. ساختارهای فازی مانند آن‌چه در این مقاله ارائه شده است، مقاومت خوبی نسبت به نادقیق بودن ورودی‌ها دارند که به آن‌ها نسبت به دیگر طبقه‌بندها برتری می‌دهد. از سوی دیگر تجزیه‌ی طبقه‌بند به زیرطبقه‌بندهای مجزا ظرفیت یادگیری را افزایش داده و بهره‌گیری از تکنیک آموزش همبستگی منفی امکان استفاده‌ی کامل از این ظرفیت را با بالا بردن توانایی کاوش طبقه‌بند در مرحله‌ی آموزش ممکن کرده است. نهایتاً دخیل کردن اطلاعات همبستگی برچسب‌ها در فرایند تعلیم را می‌توان وجه تمایز بین ML-EPC-FC و دیگر روش‌های چندبرچسبی دانست. این موضوع با بررسی جدول (۳) بهتر قابل درک است زیرا ساختار EPC-FC علی‌رغم داشتن دیگر ویژگی‌هایی نسبت به OCC، این ویژگی‌ها در ML-EPC-FC موجب شده است تا در طبقه‌بندی داده‌های HRM بتواند نسبت به دیگر طبقه‌بندهای کننده‌های کلاسیک چندبرچسبی از عمل‌کرد بهتری برخوردار باشد. این موضوع با مقایسه‌ی نتایج به دست آمده در مطالعات پیشین که همگی به صورت طبقه‌بندی تک‌برچسبی بوده‌اند نیز قابل بررسی است. به این منظور می‌توان هزینه‌ی همینگ در حالت چندبرچسبی (در این مقاله برابر با ۰.۸۲) را با صحت در حالت تک‌برچسبی مقایسه نمود. روش کارنیل و هم‌کارانش با استفاده از مدل ریاضی برای موج فشار به صحت ۰.۸۰ دست یافته است [۹]. در پژوهش ونگ و هم‌کارانش نیز که در آن صرفاً شدت اختلال بلع در سه سطح طبقه‌بندی شده، صحت ۹۳/۵٪ گزارش شده است [۱۰]. نهایتاً بهترین نتایج در مقاله‌ی [۱۲] با ترکیب چند طبقه‌بند برابر با ۹۱٪ به دست آمده که بر اساس برچسب زدن به هر آزمودنی بر اساس تمام بلع‌های ثبت

- [20] Y. Zhu, J. T. Kwok, and Z.-H. Zhou, "Multi-Label Learning with Global and Local Label Correlation," *IEEE Trans. Knowl. Data Eng.*, vol. 30, no. 6, pp. 1081–1094, Jun. 2018.
- [21] E. Alvares-Cherman, J. Metz, and M. C. Monard, "Incorporating label dependency into the binary relevance framework for multi-label classification," *Expert Syst. Appl.*, vol. 39, no. 2, pp. 1647–1655, Feb. 2012.
- [22] T. Takagi and M. Sugeno, "Fuzzy identification of systems and its applications to modeling and control," *IEEE Trans. Syst. Man. Cybern.*, vol. SMC-15, no. 1, pp. 116–132, Jan. 1985.
- [23] Y. Liu and X. Yao, "Ensemble learning via negative correlation," *Neural Networks*, vol. 12, no. 10, pp. 1399–1404, Dec. 1999.
- [24] G. Brown, J. L. Wyatt, and P. Tiño, "Managing diversity in regression ensembles," *J. Mach. Learn. Res.*, vol. 6, pp. 1621–1650, 2005.
- [25] Z. Wang, X. Pan, G. Wei, J. Fei, and X. Lu, "A faster convergence and concise interpretability TSK fuzzy classifier deep-wide-based integrated learning," *Appl. Soft Comput.*, vol. 85, no. xxx, p. 105825, Dec. 2019.
- [26] E. Lughofer, "Evolving multi-label fuzzy classifier," *Inf. Sci. (Ny)*, vol. 597, pp. 1–23, Jun. 2022.
- [27] S. S. Choi, S. H. Cha, and C. C. Tappert, "A survey of binary similarity and distance measures," *WMSCI 2009 - 13th World Multi-Conference Syst. Cybern. Informatics, Jointly with 15th Int. Conf. Inf. Syst. Anal. Synth. ISAS 2009 - Proc.*, vol. 3, no. 1, pp. 80–85, 2009.
- [28] R. C. Prati, "Fuzzy rule classifiers for multi-label classification," in *2015 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, 2015, vol. 2015-Novem, no. Cmcc, pp. 1–8.
- [29] E. Gibaja and S. Ventura, "Multi-label learning: a review of the state of the art and ongoing research," *Wiley Interdiscip. Rev. Data Min. Knowl. Discov.*, vol. 4, no. 6, pp. 411–444, Nov. 2014.
- [30] M.-L. Zhang and Z.-H. Zhou, "A Review on Multi-Label Learning Algorithms," *IEEE Trans. Knowl. Data Eng.*, vol. 26, no. 8, pp. 1819–1837, Aug. 2014.
- [31] G. Tsoumakas, I. Katakis, and I. Vlahavas, "Random k-Labelsets for Multilabel Classification," *IEEE Trans. Knowl. Data Eng.*, vol. 23, no. 7, pp. 1079–1089, Jul. 2011.
- [32] L. Sun and M. Kudo, "Optimization of classifier chains via conditional likelihood maximization," *Pattern Recognit.*, vol. 74, pp. 503–517, Feb. 2018.
- healthy and pathologic conditions," *Proc. Inst. Mech. Eng. Part H J. Eng. Med.*, vol. 230, no. 9, pp. 892–899, Sep. 2016.
- [9] A. Frigo, M. Costantini, C. G. Fontanella, R. Salvador, S. Merigliano, and E. L. Carniel, "A Procedure for the Automatic Analysis of High-Resolution Manometry Data to Support the Clinical Diagnosis of Esophageal Motility Disorders," *IEEE Trans. Biomed. Eng.*, vol. 65, no. 7, pp. 1476–1485, Jul. 2018.
- [10] Z. Wang, M. Hou, L. Yan, Y. Dai, Y. Yin, and X. Liu, "Deep learning for tracing esophageal motility function over time," *Comput. Methods Programs Biomed.*, vol. 207, 2021.
- [11] Z. Wang et al., "Attention graph convolutional nets for esophageal contraction pattern recognition in high-resolution manometries," *Biomed. Signal Process. Control*, vol. 68, no. April, p. 102734, Jul. 2021.
- [12] W. Kou et al., "A multi-stage machine learning model for diagnosis of esophageal manometry," *Artif. Intell. Med.*, vol. 124, p. 102233, Feb. 2022.
- [13] M. R. Fox et al., "Inter-observer agreement for diagnostic classification of esophageal motility disorders defined in high-resolution manometry," *Dis. Esophagus*, vol. 28, no. 8, pp. 711–719, Nov. 2015.
- [14] M. Defferrard, X. Bresson, and P. Vandergheynst, "Convolutional Neural Networks on Graphs with Fast Localized Spectral Filtering," Jun. 2016.
- [15] S. Rafieivand, M. H. Moradi, Z. Momayez Sanat, and H. Asl Soleimani, "A fuzzy-based framework for diagnosing esophageal mobility disorder using high-resolution manometry," *J. Biomed. Inform.*, vol. 141, p. 104355, May 2023.
- [16] M.-L. Zhang and Z.-H. Zhou, "ML-KNN: A lazy learning approach to multi-label learning," *Pattern Recognit.*, vol. 40, no. 7, pp. 2038–2048, Jul. 2007.
- [17] A. Clare and R. D. King, "Knowledge Discovery in Multi-label Phenotype Data," in *Principles of Data Mining and Knowledge Discovery*, A. De Raedt, L. Siebes, Ed. Springer Berlin Heidelberg, 2001, pp. 42–53.
- [18] R. E. Schapire and Y. Singer, "BoosTexter: A Boosting-based System for Text Categorization," *Mach. Learn.*, vol. 39, pp. 135–168, 2000.
- [19] A. N. Tarekegn, M. Giacobini, and K. Michalak, "A review of methods for imbalanced multi-label classification," *Pattern Recognit.*, vol. 118, p. 107965, 2021.