

# ارائهٔ روشی جدید برای طبقه‌بندی

## چندبرچسبی بر مبنای شبکه‌های عصبی

محسن نصیری<sup>۱</sup>, نگین دانشپور<sup>۲\*</sup>

کارشناس ارشد دانشکده مهندسی کامپیوتر، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران<sup>۱</sup>

دانشیار دانشکده مهندسی کامپیوتر، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران<sup>۲\*</sup>

### چکیده

طبقه‌بندی چندبرچسبی نوعی از طبقه‌بندی است که در آن نمونه‌ها می‌توانند صفر، یک یا بیش از یک برچسب داشته باشند؛ به عبارت دیگر هر نمونه بهوسیلهٔ یک مجموعه از برچسب‌ها نمایش داده می‌شود. با توجه به پژوهش‌های اخیر، در نظر گرفتن ارتباط بین برچسب‌ها نتایج بهتری را حاصل می‌کند. در این مقاله برای در نظر گرفتن ارتباط بین برچسب‌ها، در مرحلهٔ نخست از خوشه‌بندی  $k$ -میانگین با محدودیت استفاده و در مرحلهٔ دوم برای هر خوشهٔ یک شبکهٔ عصبی پرسپترون چندلایه در نظر گرفته شده است؛ در نهایت با ترکیب برچسب‌های پیش‌بینی شده بهوسیلهٔ طبقه‌بندها، برچسب‌های نهایی به دست می‌آید. با توجه به اینکه تعداد شبکه‌های عصبی نسبت به حالت معمول افزایش و به تبع آن زمان آموزش داده‌ها بیشتر می‌شود، روش جدیدی برای کاهش ابعاد با استفاده از جمع پراکنده به کار برده شده است. با ارزیابی روش پیشنهادی بر روی مجموعه داده‌های موجود در مقایسه با روش‌های پیشین این نتیجه حاصل شد که روش پیشنهادی در سه مجموعه داده از نوع متن در بسیاری از معیارها مانند دقت، صحت و فاصله همینگ در بین الگوریتم‌ها رتبهٔ نخست را داشته است.

واژگان کلیدی: طبقه‌بندی، طبقه‌بندی چندبرچسبی، خوشه‌بندی، شبکه‌های عصبی.

## Presenting a new method for multi label classification based on neural network

Mohsen Nasiri<sup>1</sup>, Negin Daneshpour<sup>2\*</sup>

Msc, Computer Engineering Department, Shahid Rajaee Teacher Training University, Tehran,  
Iran<sup>1</sup>

Associate Professor, Computer Engineering Department, Shahid Rajaee Teacher Training  
University, Tehran, Iran<sup>2\*</sup>

### Abstract

The problem of classification can be divided into two categories: single-label and multi-label. Single-label classification consists of binary and multi-class classification. In binary classification, the task is to predict one in two possible classes, such as distinguishing between spam and non-spam emails. In multi-class classification, the goal is to classify instances into more than two classes, such as identifying different species of flowers based on petal measurements. In contrast to single-label classification, multi-label classification is more complex because each instance could belong to multiple categories simultaneously. In multi-label learning, instead of assigning a single label to each instance, a set of labels is assigned. This means that each sample may have zero, one, or more than one associated label. For example, in a text classification task, a news article about technology and business might be labeled as both "Technology" and "Business". To handle multi-label classification, several approaches have been developed. One of the simplest methods is Binary Relevance (BR), which transforms the multi-label

\* Corresponding author

\* نویسندهٔ عهده‌دار مکاتبات

• تاریخ ارسال مقاله: ۱۴۰۳/۴/۲۴ • تاریخ پذیرش: ۱۴۰۳/۱۲/۱۴ • تاریخ انتشار: ۱۴۰۴/۶/۲۲ • نوع مطالعه: پژوهشی

سال ۱۴۰۴ شماره ۲ پیاپی ۶۴

problem into multiple independent binary classification tasks—one for each label. Although this approach is easy to implement, it treats each label independently and ignores possible relationships among them. However, in real-world applications, labels are often correlated; for instance, in medical diagnosis, certain diseases frequently appear together. In another approach, Label Powerset (LP), considers label dependencies by treating each unique combination of labels as a separate class. While this method captures relationships between labels, it suffers from scalability issues while dealing with a large number of labels, as the number of possible label combinations increases exponentially. To address these challenges, the proposed method incorporates k-means constraint clustering to group both labels and features prior to applying classification. In the first step, clustering is performed to group similar labels together, ensuring that label correlations are preserved. This also helps to mitigate the issue of imbalanced classification, where certain labels may be underrepresented in the dataset. Once the labels are being clustered, a separate multi-layer neural network would be assigned to each cluster. Instead of using a single large neural network for all labels, multiple smaller networks would be trained for different label clusters. This approach enhances learning efficiency and improves accuracy by focusing on relevant label groups. However, using multiple classifiers increases computational costs and training time. To mitigate this issue, a scatter-add dimension reduction technique is applied. Using scatter-add, attributes are efficiently assigned to the input of each neural network, ensuring that each classifier receives only the relevant feature subset. Each neural network then predicts labels within its designated cluster. Eventually, the predictions from all classifiers are combined to generate the final multi-label output for each instance. To evaluate the effectiveness of the proposed method, experiments were conducted on various text datasets. The results were compared with traditional multi-label classification methods, including Binary Relevance and Label Powerset. The evaluation has been based on several performance metrics, such as accuracy, precision, and hamming-loss. The results demonstrated that the proposed approach achieved superior performance across multiple datasets, ranking first in several evaluation criteria. Notably, it outperformed existing methods by a margin of approximately 1% in accuracy. These findings suggest that clustering-based multi-label classification using k-means constraint clustering and multi-layer neural networks is a promising approach. By leveraging label correlations and reducing dimensionality, the proposed method effectively improves classification performance while addressing issues such as label imbalance and computational inefficiency. Future research may further explore optimization techniques to reduce training time while maintaining high accuracy.

**Keywords:** Classification, Multi-Label Classification, Clustering, Neural Networks.

محصولات<sup>۷</sup> [۴]، پیشنهاد برچسب (هشتگ)<sup>۸</sup> در شبکه‌های اجتماعی<sup>۹</sup>، طبقه‌بندی احساسات موسیقی<sup>۱۰</sup> [۶] و تفسیر تصویر<sup>۱۱</sup> [۷] اشاره کرد. در بسیاری از مقالات صفت‌های نمونه با متغیر  $x$  و برچسب‌هایی که قرار است برای نمونه‌ها پیش‌بینی شود، با متغیر  $y$  نشان داده شده‌است و درنهایت برای حل مسئله طبقه‌بندی چندبرچسبی باید زیرمجموعه‌ای از برچسب‌ها را به نمونه مورد نظر نسبت داد (برای مثال برچسبی را که با نمونه مرتبط است با یک، در غیر این صورت با صفر نمایش دهیم) که باید در فضای<sup>۱۲</sup> جست‌وجو شود<sup>۱۳</sup> [۸، ۹]. این مسئله نمایی است و زمانی که تعداد برچسب‌ها بسیار باشد، مشکل تشدید می‌شود.

بسیاری از مقالات برای حل این مشکل، به خوشبندی برچسب‌ها روی آوردنده<sup>۱۰</sup> [۱۱، ۱۰، ۹] که این امر موجب کاهش فضای مسئله می‌شود؛ زیرا به جای بررسی تمامی برچسب‌ها و مقایسه احتمال هر یک، خوشبندی‌های آن‌ها بررسی می‌شود.

<sup>7</sup> product categorization

<sup>8</sup> hashtag suggestion

<sup>9</sup> music emotion classification

<sup>10</sup> image annotation

## ۱- مقدمه

طبقه‌بندی<sup>۱</sup> فرایند یافتن مدلی<sup>۲</sup> (یا تابعی) است که طبقات<sup>۳</sup> یا مفاهیم داده را توصیف و جدا می‌کند. این مدل برای پیش‌بینی برچسب طبقه اشیایی که برچسب طبقه برای آن‌ها ناشناخته است، استفاده می‌شود[۱]. مسئله طبقه‌بندی را به دو دسته کلی طبقه‌بندی تکبرچسبی<sup>۴</sup> و طبقه‌بندی چندبرچسبی<sup>۵</sup> می‌توان تقسیم کرد. در طبقه‌بندی رایج هر نمونه به یک برچسب مرتبط می‌شود؛ در حالی که در دنیای واقعی هر نمونه ممکن است به چند برچسب به‌طور همزمان مربوط شود. از این جهت طبقه‌بندی چندبرچسبی به وجود آمده است[۲]. طبقه‌بندی چندبرچسبی طیف وسیعی از حوزه‌ها<sup>۶</sup> [۲۵-۲۶] را مانند «دسته‌بندی متن»<sup>۷</sup> که هر متن یا خبر ممکن است به بیش از یک دسته تعلق داشته باشد، شامل می‌شود[۳]. از جمله کاربردهای دیگر این نوع طبقه‌بندی می‌توان به دسته‌بندی

<sup>1</sup> Classification

<sup>2</sup> Model

<sup>3</sup> Class

<sup>4</sup> Single label classification

<sup>5</sup> Multi-label classification

<sup>6</sup> Text categorization



مجموعه‌اند. تمام زیرمجموعه‌های این مجموعه  $k$  عضوی بررسی و برای هر یک از این زیرمجموعه‌ها نامی در نظر گرفته می‌شود. از دیگر الگوریتم‌های مطرح می‌توان به ترکیب طبقه‌بندها بر اساس الگوریتم تکاملی اشاره کرد. بسیاری از روش‌های ارائه‌شده گروهی طبق انتخاب، تصادفی بوده و به ساختار داده توجه ندارند؛ در حالی که مولانو روشی پیشنهاد می‌دهد که به ساختار داده یعنی رابطه بین برچسب‌ها و عدم تعادل در درجه برچسب‌ها اشاره دارد<sup>[۱۵]</sup>. در این مقاله هر طبقه‌بند مسئولیت زیرمجموعه‌ای از برچسب‌ها را بر عهده دارد. در این الگوریتم با استفاده از ابزارهای الگوریتم‌های تکاملی مانند تابع سازگاری<sup>۵</sup>، عملگر جهش<sup>۶</sup> و عملگر متقطع<sup>۷</sup> می‌توان دقیق را افزایش داد. روش دیگری که نتایج بسیار خوبی در این زمینه داشته است، درنظرگرفتن ارتباط نمونه‌ها و صفت‌ها با یکدیگر و استفاده از روش k-نزدیکترین همسایه<sup>۸</sup> است؛ همچنین در این مقاله به ارتباط بین برچسب‌ها با این فرض که برچسب‌های با ارتباط زیاد، خروجی مشابهی تولید می‌کند، توجه شده است. رویکرد دیگری که به تازگی منتشر شده، روش ترکیبی MLDE است<sup>[۱۶]</sup>. در این رویکرد، به صورت پویا طبقه‌بندهایی که بهترین دقیق را دارند، انتخاب می‌شوند. طبق ادعای مقاله، تنها از طبقه‌بندهای دودویی استفاده شده و ممکن است با تغییر طبقه‌بندها حتی بتوان به نتایج بهتری دست یافته. مشکل پیچیدگی زمان، حافظه و برچسب‌های دنباله<sup>۹</sup> در طبقه‌بندی چندبرچسبی با تعداد برچسب بالا بسیار شدیدتر است. برای حل این مشکل به طور معمول راه کارها قبل از اجرای الگوریتم اصلی، پیش‌پردازش انجام می‌دهند. در حالت کلی می‌توان به سه رویکرد اشاره کرد<sup>[۸]</sup>: روش یک در مقابل همه<sup>۱۰</sup>، حين فرایند آموزش برای هر برچسب یک طبقه‌بند، احتمال آن برچسب را در مقابل سایر برچسب‌ها محاسبه می‌کند. این روش از نظر دقیق از بهترین‌ها محاسبه می‌شود؛ اما چون زمان اجرای الگوریتم بسیار بالاست، در مواقعي که منابع محدود باشد، استفاده از این الگوریتم غیرممکن است. رویکرد دوم، روش‌های مبتنی بر درخت<sup>۱۱</sup> است. ابتدا برچسب‌ها را به مجموعه‌های مجزا تقسیم می‌کنند؛ سپس بر اساس درخت تصمیم ایجاد شده، برچسب‌گذاری نهایی را انجام می‌دهند. از مزایای این الگوریتم‌ها می‌توان به سرعت بالا در آموزش داده‌ها و پیش‌بینی برچسب‌ها در زمان اجرا اشاره کرد. از معایب آن مشکل انتشار در درخت و خطأ در پیش‌بینی برچسب‌های دنباله است. رویکرد سوم روش‌های مبتنی بر یادگیری روش‌ها نیز تا اندازه‌ای سرعت بالایی در آموزش دارند.

<sup>5</sup> Fitness function<sup>6</sup> Mutation operator<sup>7</sup> Crossover operator<sup>8</sup> k-nearest neighbor<sup>9</sup> tail labels<sup>10</sup> one vs rest<sup>11</sup> tree based method

در این مقاله نیز در ابتدا برچسب‌ها بر اساس داده و میزان ارتباط بین برچسب‌ها خوشبندی می‌شوند. برای درنظرگرفتن ارتباط بین برچسب‌ها از خوشبندی k-میانگین با محدودیت<sup>۱</sup> بر اساس تکرار برچسب‌ها با یکدیگر و ماتریس شباهت استفاده شده است؛ سپس راه کاری برای حل مشکل نمایی مد نظر قرار می‌گیرد؛ همچنین برای بهبود دقیق و سرعت در انتخاب برچسب‌ها ایده کاهش بعد بر اساس جمع پراکنده استفاده شده است. مواردی که در این مقاله انجام شده به اختصار در زیر آورده شده است:

- ❖ خوشبندی برچسب‌ها و صفت‌ها بر اساس ماتریس مشابهت

❖ کاهش بعد لایه ورودی شبکه عصبی  
❖ مناسب‌کردن داده‌ها برای استفاده از جمع پراکنده و درنهایت کاهش بعد لایه خروجی شبکه عصبی  
❖ در ادامه، بخش دوم این مقاله به تشریح کارهای انجام شده می‌پردازد. در بخش سوم، الگوریتم مورد نظر با جزئیات معرفی می‌شود. نتایج مقایسات و آزمایش‌های انجام گرفته الگوریتم پیشنهادی و سایر روش‌ها در بخش چهارم به تفصیل بیان شده و در انتهای و در بخش پنجم نیز به نتیجه‌گیری و پیشنهادهایی برای توسعه الگوریتم مقاله پرداخته شده است.

## ۲- پیشینهٔ پژوهش

روش‌ها و الگوریتم‌های طبقه‌بندی چندبرچسبی معمول را می‌توان از چندین دیدگاه متفاوت دسته‌بندی و با هم مقایسه کرد. یک دیدگاه این است که ارتباط بین برچسب‌ها را در نظر بگیریم یا خیر. از جمله الگوریتم‌هایی که این ارتباط را در نظر نمی‌گیرند، الگوریتم ارتباط دودویی<sup>۱۲</sup> است<sup>[۱۲]</sup>. این روش از یک گروه از طبقه‌بندهای جدا که هر کدام مسئولیت پیش‌بینی برچسب خود را دارند، تشکیل شده است. از مزایای این الگوریتم، ساده و شهودی بودن آن است؛ اما دسته دوم ارتباط بین برچسب‌ها را در نظر می‌گیرند. از جمله این الگوریتم‌ها، طبقه‌بند زنجیره‌ای است. در این رویکرد ترتیب قرارگیری برچسب‌ها بسیار مهم و دشوار است. جون و همکاران برای ترتیب قرارگیری، شرط آنتروپی<sup>۱۳</sup> را در نظر گرفتند<sup>[۱۳]</sup>. باید بین هر زوج برچسب با استفاده از قانون احتمال آنتروپی را حساب کرد. آن ترتیب که مقدار بیشتری داشت، ترتیب مناسب‌تری است. دسته دیگری از الگوریتم‌هایی که ارتباط بین برچسب‌ها را در نظر می‌گیرند، طبقه‌بندهای گروهی هستند؛ از جمله این الگوریتم‌ها می‌توان به k زیرمجموعه برچسب فعال اشاره کرد. وانگ و همکاران در مقاله خود<sup>[۱۴]</sup> برای حل مشکل نمایی با درنظرگرفتن مجموعه‌هایی مشکل از k برچسب راه کاری پیشنهاد دادند. در این روش هر k برچسب (برای مثال  $k=2$ ) به صورت یک

<sup>1</sup> k-means constraint<sup>2</sup> scatter\_add<sup>3</sup> Binary Relevance<sup>4</sup> Conditional entropy

(جدول-۱): دسته‌بندی روش‌های طبقه‌بندی  
(Table-1): classification methods in 2017 to 2023

الگوریتم	سال	رویکرد	مزایا
Br Binary relevance[12]	۲۰۱۷	برای هر برچسب یک طبقه‌بند جدا در نظر می‌گیرد و به ارتباط برچسب‌ها توجه ندارد.	ساده و شهودی بودن
Cc Classifier chain[13]	۲۰۱۹	بین هر زوج برچسب با استفاده از قانون احتمال، آنتروپی را حساب می‌کند.	ارتباط بین برچسب‌ها را در نظر می‌گیرد
Hierarchical Neural networks[16]	۲۰۱۴	بر اساس الگوریتم پرسپترون و انتشار مجدد در داده‌های آموزش	از نظر پیچیدگی محاسباتی برای مجموعه با تعداد زیاد برچسب داده کارآمد است
k-labelset ACKEL[14]	۲۰۲۰	در این رویکرد از طبقه‌بندهای متفاوت استفاده شده و هر طبقه‌بند مسئولیت زیرمجموعه‌ای از برچسب‌ها را بر عهده دارد.	-بهبودیافته روش $I_p$ است. - زمانی که تعداد برچسب‌ها و نمونه‌ها زیاد باشد مناسب است.
Bonsai[8]	۲۰۲۰	برچسب‌ها بر اساس ارتباطشان خوشه‌بندی می‌شوند و سپس درخت تصمیم ساخته می‌شود و درنهایت زیرمجموعه مطلوبی از برچسب‌ها برگزیده می‌شود.	-نیازی به متعادل بودن بین برچسب‌ها ندارد؛ بنابراین اعتبار در تمامی داده‌ها برقرار است. - در مجموعه‌های داده با برچسب بالا به ویژه آن دسته که میانگین برچسب کمی دارند خوب عمل می‌کند
Evolutionary algorithm Ensemble generation[15]	۲۰۲۰	الگوریتم از ابزارهای الگوریتم‌های تکاملی مانند تابع سازگاری عمل گر جهش و عمل گر متقطع استفاده کرده است.	داده‌های با تکرار کم را نیز پوشش می‌دهد و نادیده نمی‌گیرد.
CLML[17]	۲۰۲۲	انتخاب صفت‌های خاص با استفاده از ارتباط نمونه‌ها و صفت‌ها و استفاده از k-نزدیکترین همسایه	با توجه به انتخاب صفت‌ها و درنظرگرفتن ارتباط برچسب‌ها دقت نسبت به سایر روش‌ها بالاتر است.
MLDE[18]	۲۰۲۳	انتخاب بهترین طبقه‌بندها و ترکیب پیش‌بینی آنها برای بهدست آمدن برچسب نهایی	- بهدلیل اینکه یک رویکرد و نگرش کلی است می‌توان با تغییر طبقه‌بندها و جزئیات به نتایج بهتری دست یافت

### ۳- طرح پیشنهادی

همان‌طور که بیان شد، در طبقه‌بندی چندبرچسبی هدف آن است که زیرمجموعه‌ای (برحسب معمول کوچک) از تعداد زیادی برچسب به نمونه نسبت داده شود. در رویکرد پیشنهادی ابتدا برچسب‌ها خوشه‌بندی، سپس برای هر یک از خوشه‌های برچسب یک شبکه عصبی در نظر گرفته می‌شود؛ درنهایت با ترکیب برچسب‌های پیش‌بینی شده به‌وسیله شبکه‌های عصبی، برچسب‌های نهایی بهدست می‌آیند؛ همچنین راه کاری برای کاهش بعد شبکه‌های عصبی با استفاده از جمع پراکنده در نظر گرفته شده است. در ادامه به توضیح هر یک از موارد پرداخته شده است.

#### ۳-۱- پیش‌پردازش

این مرحله شامل یافتن ارتباط اولیه صفت‌ها با یکدیگر، برچسب‌ها با یکدیگر و خوشه‌بندی آن‌هاست. خوشه‌بندی k-میانگین با محدودیت بر اساس ماتریس شباهت بهدست می‌آید و به همین دلیل مناسب مجموعه داده‌هایی است که ارتباط بین برچسب‌ها به نسبت سایرین بالاتر است. در ادامه به توضیحات این موارد پرداخته شده است.

۳-۱-۱- ارتباط بین برچسب‌ها و خوشه‌بندی آن‌ها

می‌توان برچسب‌ها را در ماتریس دو بعدی دودویی نمایش داد. هر سطر ماتریس بیان کننده برچسب‌های هر نمونه است. در صورتی که آن نمونه آن برچسب را داشته باشد مقدار آن یک و در غیر این صورت صفر است.

برای مثال در ماتریس بالا سطر نخست بیان کننده نمونه نخست و ستون نخست و دوم آن یک است؛ پس این نمونه برچسب نخست ( $y_1$ ) و برچسب دوم ( $y_2$ ) را دارد و ستون سوم صفر است؛ پس این نمونه قادر برچسب سوم ( $y_3$ ) است؛ همچنین سطرهای دوم و سوم ماتریس بیان کننده برچسب‌های نمونه دوم و سوم هستند.

$$Y = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 1 & 0 \\ 0 & 1 & 1 \end{bmatrix}$$

۳-۱-۲- خوشه‌بندی k-میانگین با محدودیت

در این خوشه‌بندی ابتدا با پیش‌پردازش در قسمت ۳-۱-۱-۱- ارتباط بین برچسب‌ها (صفت‌ها) بهدست می‌آید؛ سپس برچسب‌های با ارتباط بیشتر در یک خوشه قرار می‌گیرند. تفاوت این خوشه‌بندی با k-میانگین متدائل در این است که می‌توان بیشینه<sup>۱</sup> و کمینه<sup>۲</sup> تعداد برچسبی را که در هر خوشه قرار می‌گیرد، تعیین کرد.

<sup>1</sup> maximum

<sup>2</sup> minimum

فصل پنجم



شده و در بین بازه صفر و یک قرار می گیرند. برای این کار از رابطه (۱) استفاده شده است:

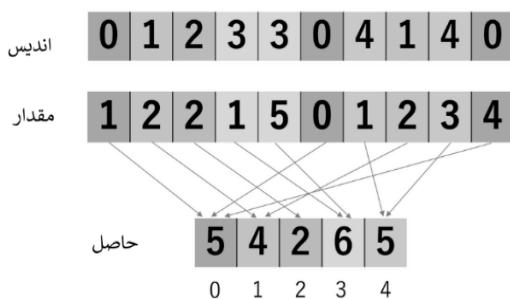
$$x'_i = \frac{xi - \min(x)}{\max(x) - \min(x)} \quad (1)$$

### ۳-۲-۳- کاهش بعد لایه های شبکه عصبی

در مرحله قبل، برچسبها و صفت ها خوشه بندی شدند. برای تبدیل شدن خوشه به عنوان گره شبکه، دو راه کار وجود دارد؛ راه نخست در نظر گرفتن مرکز هر خوشه به عنوان نماینده آن خوشه است. این رویکرد با اینکه در پیچیدگی زمانی مناسب تر است، اما دقیق کافی را ندارد؛ زیرا تأثیر تمام صفت ها در گره ها اعمال نمی شود؛ اما راه کار دوم رویکرد جمع پراکنده است که در قسمت ۳-۲-۱ توضیح داده شده است.

### ۳-۲-۱- رویکرد جمع کردن پراکنده

با توجه به این که در این مقاله برای کاهش بعد لایه ورودی و در لایه خروجی شبکه عصبی از رویکرد «جمع کردن پراکنده»<sup>۱</sup> استفاده شده، بهتر است در این بخش به توضیح این روش پرداخته شود. سه آرایه با نامهای اندیس، مقدار و حاصل را مطابق شکل (۱) در نظر بگیرید.



(شکل ۱): مثالی برای جمع پراکنده

(figure-1): example of scatter\_add

برای مثال در آرایه اندیس، سه درایه با مقدار صفر وجود دارد. درایه های متناظر در آرایه مقدار با هم جمع عددی شده و حاصل در درایه صفرم آرایه حاصل قرار می گیرد. به همین شکل تمام درایه های آرایه حاصل پر می شود.

در ادامه به ارتباط جمع پراکنده و روش این مقاله می پردازیم.

### ۳-۲-۲- کاهش بعد لایه ورودی شبکه

همان طور که در قسمت ۲-۳ گفته شد، ورودی شبکه شماره خوشه های صفت هاست (نه خود صفت ها)؛ پس باید تابعی طراحی شود که هر بار نمونه جدیدی دریافت کرده و شماره خوشه هایی که صفت های نمونه در آن قرار دارند را در اختیار شبکه عصبی قرار دهد. به شکل (۲) توجه فرمایید.

<sup>۱</sup> scatter\_add

ضرب ترانهاده ماتریس Y در ماتریس Z شبکه عصبی را به وجود می آورد که بیان کننده ارتباط جبری بین برچسب هاست:

$$Z = Y^t Y$$

برای مثال داریم:

$$Z = \begin{bmatrix} x & 2 & 0 \\ 2 & x & 1 \\ 0 & 1 & x \end{bmatrix}$$

در ماتریس شبکه Z قطر اصلی ارتباط هر برچسب با خودش است که در خوشه بندی تأثیری ندارد. در مورد سایر درایه ها  $Z_{ij}$  ارتباط برچسب i و برچسب j را بیان می کند؛ برای مثال در ماتریس بالا  $Z_{12}$  برابر دو است که بیان کننده آن است که برچسب های یک و دو، دو مرتبه در دو نمونه متفاوت هم زمان حضور داشته اند. پس این دو برچسب، ارتباط قوی تری نسبت به برچسب سوم دارند؛ زیرا  $Z_{13} = Z_{31} = 0$  که بیان کننده آن است که برچسب یک و سه در هیچ نمونه ای هم زمان رخ نداده اند و در خوشه های متفاوتی قرار خواهند گرفت.

اگر ماتریس Z به عنوان ورودی بهتابع خوشه بند ارسال شود، درنهایت یک آرایه برمی گردد که هر عنصر آن بیان کننده شماره خوشه آن برچسب است؛ برای مثال اگر ماتریس بالا به عنوان ورودیتابع باشد و k را برابر دو قرار دهیم، خروجی آن به صورت آرایه زیر است:

$$[1 \ 1 \ 0]_{1 \times 3}$$

درایه های نخست و دوم یک هستند و این یعنی شماره خوشه برچسب نخست و دوم یک است و هردو برچسب در خوشه یک قرار دارند؛ همچنین درایه سوم صفر، که نشان دهنده آن است که برچسب سوم در خوشه شماره صفر قرار دارد.

۳-۱-۲-۲- ارتباط بین صفت ها و خوشه بندی آن ها صفت ها (ویژگی ها) را نیز مانند برچسب ها می توان به صورت ماتریس دو بعدی نمایش داد. هر سطر ماتریس بیان کننده صفت های هر نمونه است؛ برای مثال ماتریس زیر بیان کننده صفت های سه نمونه است. (هر سطر صفت های یک نمونه را نشان می دهد)

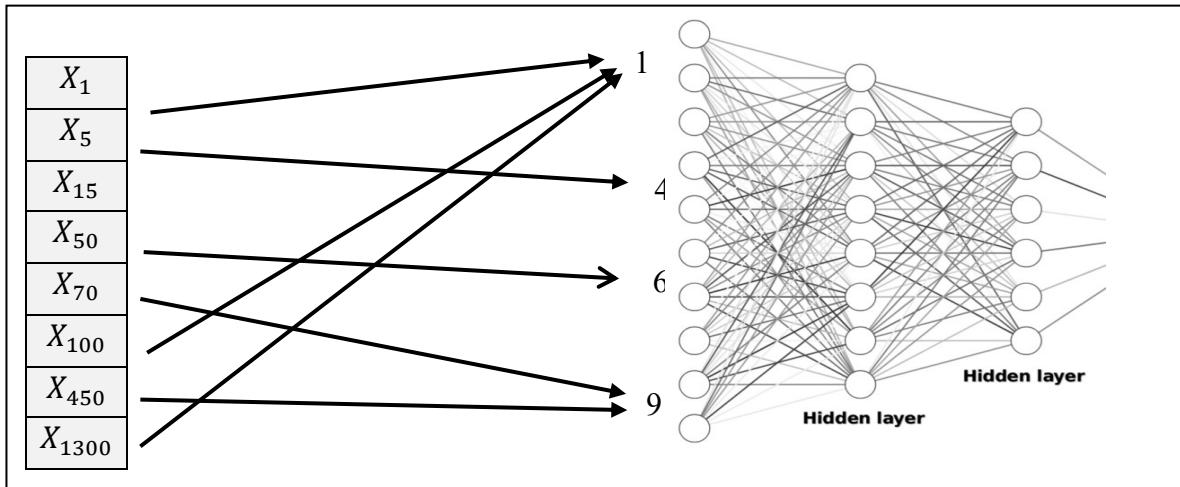
$$X = \begin{bmatrix} 0.5 & 0 & 1 & 10 \\ 1 & 6.2 & 3.1 & 0 \\ 0 & 0 & 4 & 6 \end{bmatrix}$$

درایه  $X_{ij}$  مقدار ز امین صفت از نمونه را بیان می کند؛ برای مثال در ماتریس بالا  $X_{22}$  بیان می کند که مقدار صفت سوم از نمونه دوم برابر ۳.۱ است.

همان طور که مشخص است، تنها تفاوت در این است که برچسب ها به صورت دودویی (صفر یا یک) بودند؛ در صورتی که صفت های مقادیر متفاوتی دارند؛ به همین علت قبل از ضرب ماتریس صفت در ترانهاده آن و به دست آوردن ماتریس Z که ارتباط بین صفت های با هم را بیان می کند، داده ها نرمال سازی

از خوشة نخست سه صفت، درصورتی که از خوشة شش تنها یک صفت موجود است؛ پس منطقی است که وزن اولیه خوشة یک، سه برابر وزن خوشة شش باشد. در این قسمت از جمع کردن پراکنده که در قسمت ۱-۳-۳ بیان شد، استفاده شده است.

همان طور که در شکل (۲) پیداست، نمونه جدید با صفت های خود وارد می شود. صفت هایی که در خوشة یک قرار دارند، در شبکه عصبی گره یک را فعال می کنند. صفت هایی که در خوشة نه قرار دارند، گره نه را در شبکه فعال کرده اند.



(شکل-۲): شماره خوشه ها به عنوان ورودی شبکه  
(figure-2): Number of clusters as network input

در عمل ماتریسی که به عنوان لایه آخر این شبکه ها قرار می گیرد، به تعداد کل برچسب ها درایه دارد؛ و برای هر درایه باید تابع فعال ساز جداگانه تعریف کرد؛ به همین جهت در عمل، کاهش هزینه ای که مدنظر بود، محقق نمی شود. برای رفع این مشکل از کاهش ابعاد به روش جمع پراکنده استفاده شده است و آرایه های که به عنوان لایه خروجی شبکه های ثانویه قرار می گیرد، به تعداد عناصر همان خوشة (V) است و دیگر به تعداد عناصر کل برچسب ها (N) نیست.

**۴-۲-۳-مراحل ساخت لایه خروجی شبکه های ثانویه**  
همان طور که در قسمت قبل بیان شد، آرایه هایی که به عنوان لایه خروجی شبکه ها قرار می گیرند، به تعداد کل برچسب ها درایه دارند. در این بخش روش کاهش تعداد درایه های آرایه ها بیان می شود.  
بعد از این که برچسب ها خوش بندی شدند، در خروجی آرایه های خواهیم داشت که نشان می دهد هر برچسب متعلق به کدام خوشة است؛ برای مثال اگر تعداد کل برچسب ها ده و تعداد خوشه ها سه باشد، آرایه زیر را در نظر بگیرید:

$$[1 \quad 1 \quad 3 \quad 2 \quad 2 \quad 3 \quad 3 \quad 3 \quad 1 \quad 2]_{1 \times 10}$$

درایه های نخست، دوم و نهم مقدار یک دارند و این یعنی برچسب های نخست و دوم و نهم در خوشة یک هستند. درایه های سوم، ششم، هفتم و هشتم مقدار صفر

**۳-۲-۳- مرحله نهایی برچسب زنی**  
بعد از مشخص شدن وزن خوشه های برچسب، وزن برچسب های نهایی تعیین می شود. باید برای هر یک از خوشه های برچسب، یک شبکه عصبی جداگانه طراحی شود، به گونه ای که ورودی این شبکه ها همان ورودی شبکه نخست شکل (۱) یعنی همان خوشه های صفت ها باشد. خروجی این شبکه ها نیز برچسب های خوشة مورد نظر است؛ برای مثال اگر تعداد خوشه های برچسب ده باشد، باید ده شبکه عصبی جداگانه طراحی شود که هر کدام از شبکه های برچسب های نهایی را پیش بینی می کنند. لایه ورودی این ده شبکه، یکسان بوده و همان لایه ورودی شبکه اصلی یعنی خوشه های صفت است.

در لایه آخر شبکه باید برای هر گره یک تابع فعال ساز در نظر گرفت. در شکل (۱) خوشه های برچسب مشخص شده اند و همان طور که پیدا است تعداد برچسب ها در هر خوشه کمتر از تعداد کل برچسب هاست. به طور دقیق تر اگر تعداد کل برچسب ها N و تعداد خوشه ها L باشد، تعداد عناصر هر خوشه به طور متوسط برابر  $V = \frac{N}{L}$  خواهد بود و رابطه (۲) برقرار است:

$$(2) \quad V = \frac{N}{L}$$

این، نوید بخش آن است که شبکه های ثانویه که قرار است برچسب های نهایی را تعیین کنند، دارای گره های کمتری خواهند بود؛ و این باعث کمتر شدن هزینه زمانی و حافظه می شود.



پس از اضافه شدن مقدار متواالی یک، آرایه به شکل زیر تغییر می‌کند:

$$[1 \ 2 \ 0 \ 0 \ 0 \ 0 \ 0 \ 3 \ 0]_{1 \times 10}$$

#### مرحله پنجم:

ماتریس به دست آمده از مرحله سوم با آرایه به دست آمده از مرحله چهارم جمع پراکنده (در قسمت ۱-۲) می‌شوند و ماتریس حاصل به عنوان لایه خروجی شبکه‌ها قرار می‌گیرد و بدین شکل کاهش ابعاد انجام خواهد گرفت.

شبکه کد روش این مقاله در شکل (۳) ملاحظه می‌شود.

همان طور که در الگوریتم (۱) مشخص است، ورودی الگوریتم نمونه‌ها که با ویژگی‌های خود بیان می‌شوند هستند و خروجی الگوریتم مجموعه برچسب پیش‌بینی شده است.

در خط نخست، ویژگی‌ها خوش‌بندی می‌شوند. ورودی این خوش‌بند عبارت است از:

- تعداد خوشة (k)

- بیشینه برچسبی که در یک خوشه قرار می‌گیرد (max)
- کمینه برچسبی که در یک خوشه قرار می‌گیرد (min)
- سه ورودی بالا را برنامه‌نویس تعیین می‌کند.

(الگوریتم-۱): روش پیشنهادی خوش‌بندی  
(Algorithm-1): Proposed Algorithm

Algorithm1

```

Input: samples with their features
Output: set of possible labels
1.  $S_1, \dots, S_k \leftarrow$  K-means-constraint(K ,max, min)
2. new-features  $\leftarrow$  scatter-add(features, clusters)
3.  $S_1, \dots, S_k, \leftarrow$  K-means-constraint(K' ,max, min)
4. new-labels  $\leftarrow$  scatter-add(labels, clusters)
5.  $V_1, \dots, V_k, \leftarrow$  separating(clusters)
6. new-out  $\leftarrow$  multiplication(new-labels , labels)
7. training K' neural networks
8. concatenate possible of each neural networks
9. return final set of labels.

```

در خط دوم به وسیله جمع پراکنده ویژگی‌های جدید ساخته می‌شود. در خط سوم و چهارم، الگوریتم مراحلی را که برای ویژگی‌ها انجام شد، برای برچسب‌ها تکرار می‌کند. خط پنجم و ششم جداسازی خوش‌های و ضرب نقطه به نقطه در برچسب‌های اولیه برای آماده شدن در آموزش شبکه‌های عصبی است. در خط هفتم، شبکه‌های عصبی که به تعداد خوش‌ها هستند، آموزش می‌بینند. در خط هشتم و نهم، برچسب‌های پیش‌بینی شده با هم ادغام و در نهایت برچسب‌های نهایی برگردانده می‌شود.

## ۴- آزمایش‌ها و نتایج

برای پیاده‌سازی الگوریتم‌ها از زبان برنامه‌نویسی Python 3.8.8 در سیستم عامل Windows 10 استفاده شد.

دارند و در خوشة سه قرار دارند؛ به همین ترتیب درایه‌های چهارم، پنجم و دهم در خوشة دو قرار گرفته‌اند.

#### مرحله نخست:

در ابتدا خوشه‌ها جداسازی می‌شوند؛ برای مثال آرایه بالا به سه آرایه زیر تبدیل می‌شود:

$$\begin{bmatrix} 1 & 1 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 2 & 2 & 0 & 0 & 0 & 2 \\ 0 & 0 & 3 & 0 & 0 & 3 & 3 & 0 \end{bmatrix}_{1 \times 10}$$

آرایه نخست بیان کننده خوشة یک، آرایه دوم بیان کننده خوشة دو و آرایه سوم بیان کننده خوشة سه است. همان طور که پیداست برای مثال در آرایه نخست عناصر غیر از یک همگی به صفر تبدیل شده‌اند و همین روند برای خوشه‌های دیگر نیز برقرار است.

#### مرحله دوم:

در مرحله بعد ماتریس دو بعدی برچسب‌ها در هر یک از خوشه‌های جداسازی شده ضرب می‌شود؛ برای مثال اگر سه نمونه وجود داشته باشد، ضرب ماتریس برچسب آن سه نمونه در خوشة نخست به صورت زیر است:

$$\begin{aligned} & \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \\ & * \quad \begin{bmatrix} 1 & 1 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}_{1 \times 10} \\ & = \quad \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \end{aligned}$$

ضرب صورت گرفته، یک ضرب متناول ماتریسی متفاوت است. ماتریس حاصل ضرب بیان کننده آن است که در هر نمونه کدام برچسب در خوشة نخست قرار دارد.

#### مرحله سوم:

ماتریس خروجی مرحله دوم تعداد زیادی سطر دارد که تمام درایه‌های آن صفر است. در این مرحله تمام سطرهای صفر در ماتریس و همچنین سطرهای نظیر آن در ماتریس ورودی شبکه پاک می‌شوند.

#### مرحله چهارم:

در این مرحله باید آرایه جداسازی شده در مرحله نخست که بیان کننده خوشة مورد نظر است، آمده جمع کردن پراکنده (که در قسمت ۱-۲ بیان شد) بشود. اگر به درایه‌های غیر صفر آرایه، به ترتیب مقدار یک اضافه شود، این امکان صورت خواهد گرفت؛ برای مثال خوشة نخست به صورت زیر است:

$$\begin{bmatrix} 1 & 1 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}_{1 \times 10}$$

نشان دهنده بهترین کارایی است؛ همچنین از معیار hamming loss نیز بهره برده شد. برخلاف سه معیار دیگر در این معیارها هر چه عدد به دست آمده پایین تر باشد، به معنای کارایی بهتر روش طبقه بندی است.

معیار Accuracy (در جداول به اختصار Acc است) در رابطه (۳) بیان شده است. برای به دست آوردن Accuracy، ابتدا نسبت برچسب های پیش بینی شده درست را به کل برچسب های فعال برای هر یک از نمونه ها حساب می کنیم. میانگین این نسبت ها برابر Accuracy است.  $Z_i$  برچسبی است که مدل پیش بینی کرده است و  $Y_i$  برچسب درست است.

$$\text{Accuracy} = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i \cap Z_i|}{|Y_i \cup Z_i|} \quad (3)$$

برای معیار Precision (در جداول به اختصار prec) رابطه (۴) برقرار است. برای به دست آوردن این معیار ابتدا برای هر نمونه نسبت برچسب های درست پیش بینی شده به کل برچسب های پیش بینی شده حساب می شود؛ سپس میانگین این اعداد بیان کننده Precision است.

$$\text{Precision} = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i \cap Z_i|}{Z_i} \quad (4)$$

معیار دیگری که در این مقاله استفاده شده است، F-measure (در جداول به اختصار F1) است. برای به دست آوردن این معیار ابتدا لازم است معیاری به نام recall را معرفی کنیم. برای به دست آوردن این معیار ابتدا برای هر نمونه نسبت برچسب های درست پیش بینی شده به کل برچسب های درست حساب می شود؛ سپس میانگین این اعداد بیان کننده recall است که در رابطه (۵) آمده است:

$$\text{recall} = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i \cap Z_i|}{Y_i} \quad (5)$$

حال معیار F-measure از رابطه (۶) به دست می آید:

$$F - \text{measure} = 2 * \frac{\text{Precision} * \text{recall}}{\text{Precision} + \text{recall}} \quad (6)$$

از Hamming loss (در جداول به اختصار H-Loss) نیز از معیارهای دیگر است که از رابطه (۷) به دست می آید. این معیار، تفاوت برچسب های درست و برچسب های پیش بینی شده را حساب می کند و در نهایت نسبت به تعداد برچسب (k) و تعداد نمونه (n) نرمال سازی می شود.

$$\text{Hamming loss} = \frac{1}{n} \frac{1}{k} \sum |Y_i \Delta Z_i| \quad (7)$$

برای ارزیابی الگوریتم در آزمایش های از مجموعه داده های delicious و Stackex\_cs، Stackex\_cooking مجموعه داده های سایت دانشگاه کوردو با<sup>۱</sup> است، استفاده شده است؛ همچنین نتایج این مقاله با بهترین الگوریتم های موجود (از این جهت بهترین آند؛ زیرا مقالاتی که در سال اخیر در مجلات معتبر چاپ شده اند، نتایج را با این الگوریتم ها مقایسه کرده اند) که در [19] LLSF، [18] LIFT، [20] LLSF-DL، [21] JLCLS، [23] MLCIB، [24] CLML، LFCMILL و LSF-CI هستند، مقایسه شده است. مجموعه داده های استفاده شده در مقالات از دو بخش ویژگی ها و برچسب های استخراج شده است.

مشخصات مجموعه داده ها در جدول (۲) آورده شده است:

(جدول-۲): مشخصات مجموعه داده های استفاده شده

(Table-2): Multi-label datasets used in the experiment

C_VIR <sup>۳</sup>	کاردینالیتی <sup>۲</sup>	تعداد ویژگی	تعداد برچسب	تعداد نمونه	مجموعه داده
۰.۷۴	۱۹۰.۲	۵۰۰	۹۸۳	۱۶۱۰۵	delicious
۰.۷۶	۲.۵۶	۶۳۵	۲۷۴	۹۲۷۰	Stackex_cs
۰.۶۵	۲.۲۳	۵۷۷	۴۰۰	۱۰۴۹۱	Stackex_cooking

در جدول (۲) کاردینالیتی بیان کننده میانگین برچسب برای هر نمونه است؛ همچنین CVIR ضریب تغییرات نسبت عدم تعادل برای تمام برچسب های طبقه است.

یک مجموعه داده وب محور است که از تارنمای delicious (یک سامانه نشانه گذاری اجتماعی) استخراج شده است؛ هر نمونه مربوط به یک صفحه وب است و برچسب های آن عبارت اند از برچسب هایی که کاربران به آن صفحه داده اند. Stackex\_cs زیر مجموعه ای از داده های StackExchange است و بهطور خاص شامل پست های مربوط به Computer Science می شود. مشابه Stackex\_cs است، اما حوزه آن مرتبط با آشپزی و غذا است. هر نمونه یک پست درباره آشپزی بوده و برچسب های موضوعات آشپزی مانند مواد غذایی، تکنیک های آشپزی و ابزارهای آشپزی هستند.

برای ارزیابی میزان کارایی نتایج طبقه بندی، در آزمایش های از معیارهای precision، Accuracy و F-measure استفاده شده است. در این معیارها هر چه عدد به دست آمده بالاتر باشد، به معنای کارایی بهتر روش طبقه بندی است. بیشینه مقدار این معیارها برابر با یک و

<sup>1</sup> www.uco.es/kdis/mllresources/

<sup>2</sup> Cardinality

<sup>3</sup> coefficient variation of the imbalance ratio



۰.۳۷۶	۰.۰۰۵	۰.۳۰۰	۰.۴۸۰	LSFCI
۰.۰۹۹	۰.۰۰۵	۰.۰۷۹	۰.۱۴۴	LSFMLL
۰.۰۱۱	۰.۰۰۶	۰.۰۰۹	۰.۰۱۷	JLCLS
۰.۴۲۲	۰.۰۰۶	۰.۳۲۷	۰.۴۶۰	CLML-L
۰.۴۱۸	۰.۰۰۶	۰.۳۲۶	۰.۴۶۹	CLML-C
۰.۴۱۹	۰.۰۰۶	۰.۳۲۶	۰.۴۶۸	CLML
۰.۵۷۳	۰.۰۰۵	۰.۴۳۶	۰.۷۴۶	الگوریتم پیشنهادی

تعداد و مشخصات شبکه‌های عصبی در جدول (۶) آورده شده است:

(جدول-۶): مشخصات شبکه عصبی استفاده شده برای stackex\_cooking

(Table-6): Description of neural network used for stackex\_cooking dataset

Time(h)	Learning rate	epoch	تعداد لایه میانی	تعداد شبکه
۲.۵	۰.۰۱	۱۲۰۰	۱	۴

با توجه به نتایج جدول (۷) Precision, accuracy f1 و  
الگوریتم پیشنهادی از تمامی الگوریتم‌های برگزیده با اختلاف زیاد بالاتر است. فاصله hamming در فاصله بسیار کمی از بهترین الگوریتم قرار دارد.

(جدول-۷): نتایج مقایسه الگوریتم‌ها بر اساس چهار معیار روی مجموعه داده stackex\_cs

(Table-7): Experimental Results of All Comparing Data Set in Terms of Four Algorithms on stackex\_cs Evaluation Metrics

F1	H- Loss	Acc	Prec	الگوریتم
۰.۳۸۱	۰.۰۱۳	۰.۲۷۷	۰.۳۷۰	LLSF
۰.۳۶۲	۰.۰۱۶	۰.۲۵۵	۰.۳۲۴	LLSF-DL
۰.۲۱۱	۰.۰۰۸	۰.۱۶۲	۰.۳۱۵	LIFT
۰.۳۵۵	۰.۰۱۴	۰.۲۵۹	۰.۳۵۴	MLCIB
۰.۳۸۳	۰.۰۱۱	۰.۲۸۵	۰.۴۰۱	LSFCI
۰.۰۸۷	۰.۰۰۹	۰.۰۶۶	۰.۱۲۴	LSFMLL
۰.۰۲۳	۰.۰۰۹	۰.۰۱۷	۰.۰۴۲	JLCLS
۰.۴۲۰	۰.۰۱۱	۰.۳۱۲	۰.۴۲۶	CLML-L
۰.۴۲۳	۰.۰۱۱	۰.۳۱۵	۰.۴۲۲	CLML-C
۰.۴۲۶	۰.۰۱۱	۰.۳۱۷	۰.۴۲۶	CLML
۰.۵۵	۰.۰۰۹	۰.۴۱	۰.۶۹	الگوریتم پیشنهادی

تعداد و مشخصات شبکه‌های عصبی در جدول (۸) آورده شده است:

(جدول-۸): مشخصات شبکه عصبی استفاده شده برای stackex\_cs

(Table-8): Description of neural network used for stackex\_cs dataset

Time(h)	Learning rate	epoch	تعداد لایه میانی	تعداد شبکه
۲.۴	۰.۰۱	۱۵۰۰	۱	۳

(جدول-۳): نتایج مقایسه الگوریتم‌ها بر اساس چهار معیار روی مجموعه داده delicious

(Table-3): Experimental Results of All Comparing Algorithms on delicious Data Set in Terms of Four Evaluation Metrics

F1	H- Loss	Acc	Prec	الگوریتم
۰.۲۹۹	۰.۰۲۲	۰.۱۹۶	۰.۳۸۳	LLSF
۰.۲۸۱	۰.۰۱۹	۰.۱۸۳	۰.۴۹۹	LLSF-DL
۰.۱۹۳	۰.۰۱۸	۰.۱۲۵	۰.۴۹۷	LIFT
۰.۲۸۱	۰.۰۲۸	۰.۱۸۰	۰.۳۱۷	MLCIB
۰.۳۰۰	۰.۰۲۲	۰.۱۹۶	۰.۳۸۲	LSFCI
۰.۰۳۴	۰.۰۱۹	۰.۰۲۳	۰.۰۹۲	LSFMLL
۰.۰۸۸	۰.۰۱۹	۰.۰۵۲	۰.۳۱۶	JLCLS
۰.۳۱۴	۰.۰۲۶	۰.۲۰۴	۰.۳۲۴	CLML-L
۰.۳۱۱	۰.۰۲۷	۰.۲۰۱	۰.۳۱۷	CLML-C
۰.۳۱۱	۰.۰۲۷	۰.۲۰۱	۰.۳۱۷	CLML
۰.۳۱۰	۰.۰۲۶	۰.۲۰۶	۰.۴۰۱	الگوریتم پیشنهادی

جدول (۴ و ۸) مناسب‌ترین حالت مدل (از نظر تعداد شبکه عصبی و لایه‌های میانی) برای مجموعه داده‌های مختلف‌اند که بهترین نتایج را به دست آورده‌اند.

همان‌طور که در جدول (۳) مشاهده می‌شود، accuracy الگوریتم پیشنهادی از تمامی الگوریتم‌های برگزیده بالاتر است. F1 با فاصله خیلی کمی از بهترین الگوریتم قرار دارد. Precision نیز مقام سوم را دارد. تعداد و مشخصات مناسب‌ترین مدل و شبکه‌های عصبی در جدول (۴) آورده شده است:

(جدول-۴): مشخصات شبکه عصبی استفاده شده برای delicious

(Table-4): Description of neural network used for delicious dataset

Time(h)	Learning rate	epoch	تعداد لایه میانی	تعداد شبکه
۰.۳	۰.۰۱	۱۵	۲	۱۰

بر اساس داده‌های جدول (۵) Precision, accuracy (۵) الگوریتم پیشنهادی از تمامی الگوریتم‌های برگزیده با اختلاف زیاد بالاتر است. فاصله hamming در فاصله بسیار کمی از بهترین الگوریتم قرار دارد.

(جدول-۵): نتایج مقایسه الگوریتم‌ها بر اساس چهار معیار روی مجموعه داده stackex\_cooking

(Table-5): Experimental Results of All Comparing Data Set in Terms of Four Algorithms on stackex\_cooking Evaluation Metrics

F1	H- Loss	Acc	Prec	الگوریتم
۰.۳۸۹	۰.۰۰۵	۰.۳۰۹	۰.۴۸۰	LLSF
۰.۳۵۰	۰.۰۱۰	۰.۲۴۵	۰.۳۰۱	LLSF-DL
۰.۲۴۷	۰.۰۰۴	۰.۱۹۷	۰.۳۶۱	LIFT
۰.۳۷۱	۰.۰۰۷	۰.۲۸۲	۰.۴۰۱	MLCIB

روند کلی نمودار، بیان‌کننده آن است که با کاهش cvir اختلاف از میانگین بیشتر شده و الگوریتم پیشنهادی عملکرد بهتری دارد.

## ۵-نتایج

این مقاله روش جدیدی را با هدف بهبود دقت وظایف طبقه‌بندی چندبرچسبی معرفی می‌کند. رویکرد پیشنهادی دو نوآوری کلیدی را به‌ویژه در زمینه‌های خوشه‌بندی برچسب و کاهش ابعاد لایه شبکه عصبی، ادغام می‌کند؛ این نوآوری‌ها برای رفع چالش‌های رایج در طبقه‌بندی چندبرچسبی طراحی شده‌اند که منجر به افزایش عملکرد و کاهش پیچیدگی محاسباتی می‌شود. نخستین نوآوری شامل طراحی یک سازوکار خوشه‌بندی برابر برای مدیریت مسئله چندبرچسبی (برچسب‌های کمیاب)، نوآوری دوم حول محور کاهش ابعاد در لایه‌های شبکه عصبی است. با توجه به پیچیدگی آموزش طبقه‌بندی کننده‌های متعدد در یک تنظیمات چندبرچسبی، کاهش ابعاد لایه‌ها برای بهینه‌سازی زمان آموزش بسیار مهم است. این روش از scatter\_add برای این منظور استفاده می‌کند که به طور مؤثر تعداد پارامترها را بدون کاهش دقت، کاهش می‌دهد و روند آموزش را سرعت قابل توجهی می‌بخشد؛ علاوه‌بر این، راه حل ارائه شده در این مقاله می‌تواند به عنوان یک رویکرد جدید در نظر گرفته شود که فضا را برای بهینه‌سازی بیشتر فراهم می‌کند. به‌طور خاص، نوع و تعداد طبقه‌بندی کننده‌ها را می‌توان برای به دست آوردن نتایج بهتر تنظیم کرد. در این مطالعه، یک طبقه‌بندی کننده پرسپترون چندلایه (MLP) به کار گرفته شد، اما در حال حاضر از چندین الگوریتم پیشرفت‌های در انواع مجموعه‌داده‌ها و معیارهای عملکرد بهتر عمل کرده است. این نشان می‌دهد که با طبقه‌بندی کننده‌های پیشرفته‌تر، روش پیشنهادی می‌تواند به دقت بالاتر و کاهش بیشتر در زمان آموزش دست یابد، که آن را از جهتی امیدوارکننده برای پژوهش‌های آینده در طبقه‌بندی چندبرچسبی تبدیل می‌کند. این مقاله از دو روش خوشه‌بندی استفاده می‌کند؛ با این حال، هیچ معیار دقیق یا علمی برای تعیین زمان استفاده از هر نوع خوشه‌بندی ارائه نشده است. این موضوع حتی می‌تواند به عنوان یک مشکل پژوهشی جدید در نظر گرفته شود؛ علاوه‌بر این، پارامترهای دیگری مانند تعداد خوشه‌ها و نوع طبقه‌بندی کننده نیز مشابه این موضوع است و می‌تواند هم به عنوان محدودیت‌های این مقاله و هم به عنوان فرصت‌های جدید برای سایر پژوهش‌گران در نظر گرفته شود.

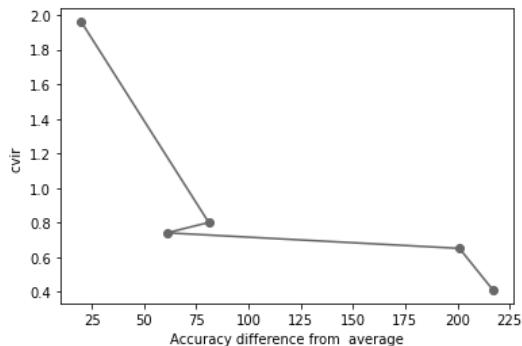
## ۶-جمع‌بندی

در این مقاله سه نوآوری جدید در بخش‌های خوشه‌بندی برچسب‌ها و کاهش بعد لایه‌های شبکه عصبی ارائه شد. با توجه به این که از چندین طبقه‌بندی برای پیش‌بینی برچسب‌ها

## ۴-مشخصات طبقه‌بند شبکه عصبی

در این مقاله از شبکه عصبی چندلایه پرسپترون استفاده شده است. از دلایل استفاده این نوع شبکه عصبی به عنوان طبقه‌بند پایه این است که به صورت بومی، مسئله چندبرچسبی را پشتیبانی می‌کند و نیاز به تغییر ساختار آن نیست؛ همچنین مقالات متعددی با استفاده از این نوع شبکه به نتایج بسیار خوبی از نظر دقت و سرعت رسیده‌اند. شبکه عصبی چندلایه پرسپترون دست کم از سه لایه ورودی، خروجی و میانی<sup>۱</sup> (مخفي) تشکیل شده است. لایه‌های میانی را می‌توان افزایش داد. در بیشتر موارد وجود یک لایه میانی بهترین نتایج را دربرداشت. انواع توابع فعال ساز<sup>۲</sup> برای مجموعه‌داده‌های متفاوت در نظر گرفته و بهترین نتایج با تابع فعال ساز relu در لایه‌های میانی و فعال ساز sigmoid در لایه پایانی حاصل شد. تابع sigmoid احتمال عضویت در طبقه را برای برچسب پیش‌بینی می‌کند و چون این مقدار احتمال بین صفر و یک است، برای مقدار نهایی که یا صفر یا یک است (یک بیان‌کننده پیش‌بینی برچسب و صفر عدم پیش‌بینی آن برچسب به وسیله مدل را بیان می‌کند) نیاز به حد آستانه است؛ همان‌طور که بیان شد، با نتایج به دست آمده، در مجموع حد آستانه<sup>۳</sup> ۰.۳ نتایج بهتری را حاصل می‌کند.

در این مقاله با استفاده از خوشه‌بندی مطرح شده، مشکل برچسب‌هایی که نسبت پراکندگی بالایی داشتند، تا حدودی رفع شد. نتایج نشان می‌دهد، به‌طور کلی در مجموعه‌داده‌هایی که واریانس کمتر بود، نتایج بهتر است. در نمودار (۱) می‌توان این نسبت را مشاهده کرد.



شکل-۳: ارتباط دقت و cvir  
(figure-3): relation between accuracy and cvir

محور افقی در نمودار بیان‌کننده اختلاف دقت الگوریتم پیشنهادی از میانگین دقت سایر الگوریتم‌های است و محور عمودی cvir واریانس طبقه‌های موجود را در مجموعه‌داده بیان می‌کند. ضریب تغییر نسبت عدم تعادل (CVIR) یک معیار آماری است که برای سنجش میزان عدم تعادل در یک مجموعه‌داده طبقه‌بندی استفاده می‌شود.

<sup>1</sup> Hidden layer

<sup>2</sup> Activation function

- [12]Zhang, Min-Ling, et al. "Binary relevance for multi-label learning: an overview", *Frontiers of Computer Science*, 12(2), 191-202, (2018).
- [13]Jun, Xie, et al. "Conditional entropy based classifier chains for multi-label classification", *Neurocomputing*, 335, 185-194, 2019.
- [14]Wang, Ran, et al. "Active k-labelsets ensemble for multi-label classification", *Pattern Recognition*, 109, 107583, (2021).
- [15]Moyano, Jose M., et al. "Combining multi-label classifiers based on projections of the output space using Evolutionary algorithms", *Knowledge-Based Systems*, 196, 105770, 2020.
- [16]Cerri, Ricardo, Rodrigo C. Barros, and André CPLF De Carvalho, "Hierarchical multi-label classification using local neural networks", *Journal of Computer and System Sciences*, 80.1, 39-56, 2014.
- [17]Li, Junlong, et al. "Learning common and label-specific features for multi-label classification with correlation information", *Pattern Recognition*, 121, 108259, 2022.
- [18]Zhu, Xiaoyan, et al. "Dynamic ensemble learning for multi-label classification", *Information Sciences*, 623, 94-111, 2023.
- [19]J. Huang, G. Li, Q. Huang, X. Wu, "Learning label specific features for multi-label classification", *IEEE ICDM 2015*, pp. 181-190, 2015.
- [20]J. Huang, G. Li, Q. Huang, X. Wu, "Learning label-specific features and class dependent labels for multi-label classification", *IEEE Trans. Knowl. Data Eng.*, 28 (12), 3309-3323, 2016.
- [21]A. Braytee, W. Liu, A. Anaissi, P.J. Kennedy, "Correlated multi-label classification with incomplete label space and class imbalance", *ACM Trans. Intell. Syst. Technol.* 10 (5), 56:1-56:26, 2019.
- [22]Y. Wang, W. Zheng, Y. Cheng, D. Zhao, "Joint label completion and label-specific features for multi-label learning algorithm", *Soft Comput.*, 24 (11), 6553-6569, 2020.
- [23]H. Han, M. Huang, Y. Zhang, X. Yang, W. Feng, "Multi-label learning with label specific features using correlation information", *IEEE Access* 7, 11474-11484, 2017.
- [24]X. Jia, S. Zhu, W. Li, "Joint label-specific features and correlation information for multi-label learning", *J. Comput. Sci. Technol.* 35 (2) (2020) 247-258
- [۲۵] صامت عمرانی، مسلم، صنیعی آباده، محمد، مقدم چرکری، نصرالله، «تشخیص شایعه در شبکه اجتماعی توییتر با استفاده از ویژگی‌های توییت و کاربر», *فصلنامه پردیش علوم و داده‌ها*، دوره ۲۱، شماره ۲، صص ۱۵-۲۸ .۱۴۰۳.۲۸
- [25] Moslem Samet Omrani, Mohammad Saniee Abadeh, Nasrollah Moghaddam Charkari, "Rumor Detection on Twitter using tweet and user features", *Signal and Data Processing*, 21(2), 15-28. 2024.

استفاده شده است، کاهش بُعد به سبک جمع پراکنده برای کاهش زمان آموزش در نظر گرفته شد. راهکار این مقاله را می‌توان یک رویکرد جدید در نظر گرفت و با تغییر نوع و تعداد طبقه‌بندها به نتایج بهتری دست یافته؛ چراکه در این مقاله از طبقه‌بند ساده mlp استفاده شده است؛ با این حال در مجموعه‌داده‌های مختلف در بسیاری از پارامترها از بهترین الگوریتم‌های موجود، بهتر عمل کرده است.

## 7-References

## ۷-مراجع

- [1]Han, Jiawei, Jian Pei, and Micheline Kamber, *Data mining: concepts and techniques*, Elsevier, 2011.
- [2]Zhang, Min-Ling, and Zhi-Hua Zhou. "A review on multi-label learning algorithms", *IEEE transactions on knowledge and data engineering*, 26.8, 1819-1837, 2013.
- [3]Chalkidis, Ilias, et al. "Large-scale multi-label text classification on EU legislation", *arXiv preprint arXiv*, 1906.02192, 2019.
- [4]Spyromitros-Xioufis, Eleftherios, et al. "Multi-target regression via input space expansion: treating targets as inputs", *Machine Learning*, 104, 55-98, 2016.
- [5]Yang, Qi, et al. "Amnn: Attention-based multimodal neural network model for hashtag recommendation", *IEEE Transactions on Computational Social Systems*, 7.3, 768-779, 2020.
- [6]Lee, Jaesung, et al. "Compact feature subset-based multi-label music categorization for mobile devices", *Multimedia Tools and Applications*, 78, 4869-4883, 2019.
- [7]Wang, Jiang, et al. "Cnn-rnn: A unified framework for multi-label image classification", *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016.
- [8]Khandagale, Sujay, Han Xiao, and Rohit Babbar, "Bonsai: diverse and shallow trees for extreme multi-label classification", *Machine Learning* 109 (11), 2099-2119, 2020.
- [9]Tanaka, Erica Akemi, et al. "A multi-label approach using binary relevance and decision trees applied to functional genomics", *Journal of biomedical informatics*, 54, 85-95, 2015.
- [10]Prajapati, Purvi, Thakkar, Amit, "Performance improvement of extreme multi-label classification using K-way tree construction with parallel clustering algorithm", *Journal of King Saud University-Computer and Information Sciences*, 34(8), 6354-6364, 2021.
- [11]Prabhu, Yashoteja, et al. "Parabel: Partitioned label trees for extreme classification with application to dynamic search advertising", *Proceedings of the 2018 World Wide Web Conference*, 2018, 993-1002.

[۲۶] پروین نیا، الهام، صفری، محمد، خیامی، سید علیرضا، «تشخیص حالت غیر نرمال ماشین های دوار با داده کاوی در پارامترهای حفاظتی»، فصلنامه پردازش عالم و داده ها، دوره ۲۱، شماره ۱، صص ۳۸-۲۷. ۱۴۰۳.

- [26] Elham Parvinnia, Mohammad Safari, Seyed Alireza Khayami, “Exploring on rotating machines abnormal state with data mining in protective parameters”, *Signal and Data Processing*, 21(1), 27-38, 2024.



نگین دانشپور مدرک کارشناسی خود را در سال ۱۳۷۷ از دانشگاه شهید بهشتی و درجه کارشناسی ارشد و دکترای خود را در رشته مهندسی کامپیوتر - نرم افزار از دانشگاه صنعتی امیرکبیر در سال های ۱۳۸۰ و ۱۳۸۹ دریافت کرد.

در حال حاضر دانشیار دانشکده مهندسی کامپیوتر دانشگاه تربیت دبیر شهید رجایی است. زمینه های پژوهشی مورد علاقه ایشان عبارت اند از: داده کاوی و پیش پردازش، مدیریت داده ها، پایگاه داده تحلیلی و سیستم های تصمیم یار.

نشانی رایانمۀ ایشان عبارت است از:  
ndaneshpour@sru.ac.ir



محسن نصیری کارشناسی را در دانشگاه شهید رجایی در رشته مهندسی نرم افزار گذرانده است. در حال حاضر دانشجوی مقطع کارشناسی ارشد رشته مهندسی نرم افزار دانشگاه شهید رجایی است. زمینه مطالعاتی ایشان داده کاوی و پایگاه داده است.

نشانی رایانمۀ ایشان عبارت است از:  
Program.nasiri97@gmail.com