

یک طبقه بندی کننده گروهی الهام گرفته از یادگیری عاطفی مغز (ELiEC)

چکیده:

در این مقاله ما یک معماری الهام گرفته از پردازش عاطفی مغز برای کاربردهای طبقه بندی شده را نشان می دهیم. این معماری از انواع طبقه بندی کننده گروهی موسوم به "طبقه بندی کننده گروهی الهام گرفته از یادگیری عاطفی مغز (ELiEC)" نامیده می شود. در این مقاله ما یک طبقه بندی کننده مشابه با وزن k را به عنوان طبقه بندی کننده ELiEC ارائه می دهیم. ما کارایی ELiEC را با طبقه بندی بعضی از مجموعه داده های آزمایشی مورد ارزیابی قرار خواهیم داد.

۱. مقدمه

روشهای طبقه بندی به صورت گسترده در علوم مهندسی، صنعت، تجارت و بهداشت مورد استفاده قرار می گیرند همچنین برای حل مشکلات طبقه بندی مانند تشخیص ناهنجاریها، تشخیص دست خط، تشخیص گفتار و تشخیص های پزشکی مورد استفاده قرار گیرند. در میان آنها، روشهای طبقه بندی براساس داده مانند مدلهایی برپایه شبکه عصبی و روشهای برپایه فاز عصبی به دلیل خود انطباقی و توانایی تعمیم بالا از محبوبترین روشها هستند. با این حال آنها دارای برخی مسائل قابل توجه مانند پیچیدگی مدل، مشکلات ابعاد، مناسب سازی و ... هستند. [5], [1] بنابراین توسعه مدلهای جدید طبقه بندی برای افزایش دقت طبقه بندی و در عین حال حل موارد فوق یک موضوع مهم تحقیقاتی در زمینه ی داده کاوی به شمار می آید. در این مقاله یک مدل طبقه بندی جدید پیشنهاد شده است که می تواند به عنوان یک طبقه بندی گروه با مکانیزم یکپارچه سازی و الگوریتم ترکیب مختلف در نظر گرفته شود. این مدل، یک مدل الهام گرفته از احساس است و "طبقه بندی گروهی الهام گرفته از آموزشهای عاطفی مغز (ELiEC)" نامیده می شود.

بقیه این مقاله به صورت زیر سازماندهی شده است: بخش II برخی کارها در زمینه ی طبقه بندی و مدلهای براساس آموزشهای عاطفی را مورد بازبینی قرار می دهد. بخش III ساختار ELiEC را توضیح می دهد. در بخش IV مجموعه داده های آزمایشی توسط ELiEC مورد بررسی قرار گرفته و نتایج بدست آمده با سایر روشها مقایسه می شوند. سرانجام در بخش V نتیجه گیری و برخی توصیه های ممکن برای بهبود ELiEC ارائه خواهد شد.

II. یک بررسی مختصر

A. کارهای مرتبط با روشهای طبقه بندی


برای مسائل طبقه بندی، روشهای زیادی توصیه شده اند که مبتنی بر هوش مصنوعی می باشند. آنها را می توان براساس استقرایی یا هدایتی، برپایه آماری یا فاقد پایه آماری، روشهای نظارت شده یا بدون ناظر. یکی از گروههای رایج روشهای طبقه بندی نظارت شده است که شامل روشهای آماری (مانند Naïve Bayes)، روشهای غیر آماری (مانند شبکه عصبی) و ماشین برداری یادگیری و پشتیبانی برپایه نمونه می باشد. با توجه به مجموعه ای از موارد، این الگوریتمها می توانند برچسب مناسب را به یک نمونه بدون برچسب نسبت دهند. در بین روشهای یادگیری نظارت شده، ماشین بردار پشتیبانی بهترین کارایی را از نظر دقت طبقه بندی دارا می باشد. با این حال دارای پیچیدگی زمانی بالایی است که این، برای برنامه های طبقه بندی آنلاین [2] و [5] موضوع مهمی می باشد.

تلاشهای متعددی برای توسعه روشهای منظم جهت افزایش تعمیم الگوریتمهای طبقه بندی نظارت شده و کاهش پیچیدگی زمانی فرایند یادگیری صورت گرفته است. یک نمونه خوب از روشهای طبقه بندی بهبود یافته مدل NFI (روش استنتاج فازی عصبی برای استدلال [انتقالی](#) است که یک مدل محلی برای هر نمونه با استفاده از سیستم استدلال [انتقالی](#) ارائه می دهد. مدل NFI از مدل شبکه عصبی از نظر دقت و پیچیدگی زمانی بهتر است. با این حال این مدل برای کاربردهای طبقه بندی دارای ابعاد بالا [6] مناسب نیست. توسعه یک طبقه بندی گروه پایه فرایند اصلی در بررسی موارد طبقه بندی نشده و پیچیدگی زمانی می باشد. ایده ی طبقه بندی گروه پایه از الهام گرفته از فرایند تصمیم سازی انسان است. اجزای اصلی یک روش گروهی ایجاد تنوع و ترکیب است. اولی روش مناسب را انتخاب می کند در حالیکه دومی خروجی های طبقه بندی را ترکیب می کند. مکانیزم ترکیب توسعه یافته را می توان به دو زیر گروه تقسیم نمود: روشهای فراترکیبی و وزن دهی. انتخاب طبقه بندی متنوع و فرایندهای ترکیب مناسب، دقت طبقه بندی در طبقه بندی گروه پایه بهتر از دقت هر کدام از طبقه بندی هاست. با این حال هیچ روش تطبیقی برای انتخاب طبقه بندی و ترکیب با استفاده از اطلاعات مسائل طبقه بندی وجود ندارد.


اخیرا یک چارچوب طبقه بندی جدید توسعه یافته است که توانایی تنظیم تطبیق ساختار طبقه بندی را دارد. این مدل که شبکه عصبی فراشناختی (McNN) نامیده می شود شامل دو جزء است: یک جزء شناختی و یک جزء فراشناختی [1], [5]. در McNN، جزء اول یک شبکه عصبی پایه شعاعی است و برای تغییر و بهینه سازی ساختار مورد نیاز می باشد. جزء دوم نقش انتخاب نمونه ها و ساختار مناسب الگوریتم یادگیری و کسب دانش از داده های آموزشی را ایفا می کند.

مدل McNN و یک نسخه توسعه یافته از آن با نام PBL-McRBFN[5] کارآیی عالی برای مسائل طبقه بندی نشان می دهند.

مدل ELiEC یک روش طبقه بندی کلی است که به کاهش میزان اشتباه طبقه بندی و پیچیدگی زمانی در مسائل طبقه بندی کمک می کند. مدل ELiEC را می توان در رده ی طبقه بندیهای گروهی قرار داد که از طبقه بندی کننده ی Wk-NN استفاده می کند.



شکل ۱. اجزای amygdala و ارتباطات آنها.



شکل ۲. توضیح گرافیکی زیرسیستمهای amygdala-orbitofrontal

B. مدل‌های مبتنی بر یادگیری عاطفی مغز

مدلسازی فرایند عاطفی مغز و حافظه برای توسعه ابزارهای مبتنی بر هوش مصنوعی (AI) یک موضوع جالب در حوزه ی تحقیقات یادگیری ماشین است. از ابزارهای هوش مصنوعی الهام گرفته از احساس اغلب به عنوان مدل‌های محاسباتی یادگیری عاطفی یاد می شود. یک مدل محاسباتی شناخته شده سیستم پوسته مرکزی پوشش دهنده لوزه است که پردازش عاطفی را براساس سیستم حاشیه‌ای تعریف می کند. فرض این مدل این است که سیستم حاشیه‌ای که شامل تالاموس، قشر حسی، قشر لوزه و پوسته پوشاننده لوبهای لوزه به طور عمده مسئولیت اصلی یادگیری عاطفی در مغز پستانداران را برعهده دارد [8]. شکل ۱ اتصال بین لوزه ها و اجزای آن را نشان می دهد. شکل ۲ مدل زیرسیستم قشر لوزه و پوسته پوشاننده لوبهای لوزه را نشان می دهد که شامل چهار قسمت است که برای تقلید فرایند یادگیری عاطفی با هم تعامل می کنند. با توجه به ساختار ساده ی آن، چارچوب پایه برای توسعه ابزارهای هوش مصنوعی جهت برنامه های کنترلی و سیستم‌های پیش بینی خطی مورد استفاده قرار می گیرد.

یک کنترل کننده ی معروف الهام گرفته از احساس BELBIC نام دارد که برای غلبه بر موارد غیر مطمئن و پیچیده سایر کنترل کننده های هوشمند ایجاد شده است. مطالعات نشان می دهند که BELBIC از بسیاری از کنترل کننده های دیگر مانند کنترل کننده PID و کنترل کننده های خطی از نظر سادگی، قابلیت اطمینان و ثبات بهتر است.

مدلهای پیش بینی برپایه احساس اغلب برای پیش بینی سری های زمانی پرهرج و مرج به کار می روند و اغلب نیز بهبود دقت پیش بینی را نشان داده اند.

III. طبقه بندی گروهی الهام گرفته از یادگیری عاطفی (ELIEC)

مدل طبقه بندی گروهی الهام گرفته از یادگیری عاطفی (ELIEC) دارای ساختاری مشابه با دو مدل قبلی یعنی BELRFS و BELFIS می باشد. مدل ELIEC دارای چهار قسمت اصلی است و از اتصالات داخلی سیستم عاطفی تقلید می کند. نامهای قسمت‌های ELIEC عبارتند از: TH، CX، AMYG و ORBI که به تالاموس، قشر حسی، لوزوی و قشر یا پوسته پوشاننده لوبهای لوزه اشاره می کنند. مدل ELIEC و اتصال بین این قسمت‌ها در شکل ۳ توضیح داده شده اند.

برای یک مساله طبقه بندی، ما مجموعه ای از داده های آموزشی را به صورت

$(\mathbf{x}_1, c^1), \dots, (\mathbf{x}_i, c^i), \dots, (\mathbf{x}_n, c^n)$ تعریف می کنیم که $\mathbf{x}_i$ نمونه ای

است با خصوصیات m و c^i کلاس برچسب x_i را مشخص می کند. در یک مساله طبقه بندی چند کلاسه، ما n کلاس و کلاس مربوطه ی x_i را داریم که می توانند به صورت $y^i = y_1^i, \dots, y_2^i, \dots, y_n^i$ کد گذاری شوند. اگر c^i با کلاس j^{th} مساوی باشد، مقدار y_j^i برابر با ۱ خواهد بود و سایر مقادیر صفر خواهند بود. با استفاده از مراحل زیر ما نشان می دهیم که ELIEC چگونه هر نمونه را برای به حداقل رساندن اشتباهات طبقه بندی، دسته بندی می کند. قسمت TH ویژگیهای x_i را ارزیابی نموده و چندین ویژگی جدید به x_i اضافه می کند. ویژگیهای اضافی براساس معادله (۱) محاسبه می شوند:

$$th_i = [\max(x_i), \text{mean}(x_i), \min(x_i)] \quad (1)$$

CX ویژگیهای x_i را ارزیابی نموده و خصوصیات زاید را حذف می کند. بنابراین CX، x_i با m ویژگی را دریافت نموده و s_i هایی با l ویژگی تولید می کند ($l \leq m$).



شکل ۳. معماری ELIEC

AMYG شامل یک طبقه بندی کننده و یک ترکیب کننده است. طبقه بندی کننده ای که در معادله (۴) ارائه شده است یک کلاس مرتبط برای $\mathbf{x}_i^a$ پیش بینی می کند که توسط معادله (۳) مشخص شده است. ترکیب کننده ی AMYG، خروجی های AMYG و ORBI را ترکیب نموده و کلاس نهایی را مطابق معادله ی (۵) ایجاد می کند.

$$\mathbf{x}_i^a = [\mathbf{th}_i, \mathbf{s}_i] \quad (3)$$

$$C_a^i = \text{Class}(\mathbf{x}_i^a) \quad (4)$$

استراتژی ترکیب کننده به نوع روش طبقه بندی بستگی دارد. در این مقاله Wk-NN به عنوان طبقه بندی کننده ی AMYG و ORBI مورد استفاده قرار گرفته است. ترکیب کننده یک Wk-NN دیگر است و کلاس نهایی بردار ورودی $\mathbf{x}_i^c$ که یک بردار از $\mathbf{x}_i^c = [\mathbf{x}_i^a, \mathbf{x}_i^o, C_a^i, C_o^i]$ است را مشخص میکند.

$$C^i = \text{Class}(\mathbf{x}_i^c) \quad (5)$$

ORBI یک طبقه بندی کننده ی دیگر است که می تواند یک طبقه بندی کننده ی مستقل یا وابسته باشد.

برای یک طبقه بندی کننده ی وابسته، بردار ورودی $\mathbf{x}_i^o = [\mathbf{s}_i, \text{REW}_i]$ خواهد بود در حالیکه

برای طبقه بندی کننده ی مستقل، بردار ورودی $\mathbf{x}_i^o = \mathbf{s}_i$ خواهد بود. سرانجام نتیجه ی طبقه بندی

را به AMIG می فرستد. برای مثالهای این مطالعه، یک طبقه بندی کننده ی مستقل به ORBI نسبت داده می شود.

لازم به ذکر است که طبقه بندی های AMYG و ORBI می توانند براساس هر روش طبقه بندی نظارت شده ای تعریف شوند به عنوان مثال، درخت تصمیم، درک یک لایه یا چند لایه، ماشین بردار پشتیبانی و غیره. ما همچنین می توانیم با انتخاب یک طبقه بندی مبتنی بر گروه برای AMIG و ORBI، یک طبقه بندی فراگروهی شکل دهیم.

IV. نزدیکترین همسایه با وزن K: یک طبقه بندی اساسی از ELIEC

نزدیک ترین همسایه با وزن k یک الگوریتم براساس نمونه می باشد که به صورت گسترده به عنوان یک روش طبقه بندی و رگرسیون مورد استفاده قرار می گیرد. برای یک مجموعه آموزشی

به صورت: $(\mathbf{x}_1, c^1), \dots, (\mathbf{x}_i, c^i), \dots, (\mathbf{x}_{N_t}, c^{N_t})$ ، Wk-NN کلاس یک بردار آزمایشی $\mathbf{x}_{test}$ را با استفاده از مراحل زیر مشخص می کند:

۱- فاصله اقلیدسی بین $\mathbf{x}_{test}$ و $\mathbf{x}_i$ محاسبه می شود، $d_i = \|\mathbf{x}_{test} - \mathbf{x}_i\|_2$ که هر $\mathbf{x}_i$ عضوی از $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{N_t}$ می باشد که N_t نشان دهنده ی تعداد نمونه های مجموعه داده آموزشی می باشد.

۲- مقادیر حداقل $d = \{d_1, d_2, \dots, d_{N_t}\}$ به عنوان d_{min} انتخاب می شوند. $\mathbf{x}_i$ های مرتبط با d_{min} نزدیکترین همسایه های k به $\mathbf{x}_{test}$ هستند و همسایه های محلی بردار آزمایشی $\mathbf{x}_{test}$ را تعریف می کنند.

۳- کلاس برچسب $\mathbf{x}_{test}$ از کلاس برچسب های همسایه های محلی انتخاب می شوند. با استفاده از نزدیکترین همسایه با وزن k، (W-kNN)، به هر همسایه وزنی نسبت داده می شود. وزن نسبت داده شده با استفاده از تابع هسته $K(0)$ تعریف می شود. هر تابع دلخواه که دارای خواص زیر باشد را می توان به عنوان تابع هسته در نظر گرفت:

$$K(d) \geq 0 \quad 1- \text{ برای همه } d\text{ها:}$$

۲- اگر $d=0$ ، آنگاه $K(d)$ حداکثر مقدار را بدهد.

۳- اگر $d \rightarrow \pm\infty$ آنگاه $K(d)$ حداقل مقدار را بدهد.

در این مقاله تابع هسته به صورت (۶) تعریف شده است. بنابراین نزدیکترین همسایه به $\mathbf{x}_{test}$ دارای بالاترین وزن در محاسبه برچسب کلاس $\mathbf{x}_{test}$ را دارد.

$$K(d) = \frac{\max(d) - (d_j - \min(d))}{\max(d)} \quad (6)$$

۷. مجموعه داده های آزمایشی

در این بخش مدل ELIEC را برای طبقه بندی چندین مجموعه داده ای که از دانشگاه کالیفرنیا مخزن یادگیری ماشین اروین (UCI) مورد آزمایش قرار می دهیم. لازم به ذکر است که هر نمونه داده ای نرمال سازی شده اند و مقادیر صفات در محدوده ی [0,1] قرار داده شده اند. برای هر محک زدنی، مجموعه اعتبارسنجی متقاطع با مجموعه داده های آموزشی هم اندازه هستند. ما ۱۰۰ بار مدل طبقه بندی را آزمایش کردیم با این حال ما بهترین نتایج را گرفتیم. برای انجام یک مقایسه موثر، ما مدل ELIEC را هم در مورد مجموعه داده های آزمایشی دودویی و هم مجموعه داده های آزمایشی چند کلاسی مورد آزمایش قرار دادیم. ما همچنین هر دو مجموعه داده های آزمایشی معیار متعادل و نا متعادل را در نظر گرفته ایم. عملکرد مدل های طبقه بندی با استفاده از دقت میانگین کلاس طبقه بندی (۷) که با η_a نشان داده می شود. پارامتر n تعداد کلاسها را مشخص می کند و η_j دقت طبقه بندی کلاس j را نشان می دهد. خطای آزمایش تعداد نمونه های طبقه بندی نشده از مجموعه آزمایش را نشان می دهد. نمونه های مجموعه داده ی آزمایشی توسط N_{test} مشخص می شود.

$$\eta_a = \frac{1}{N_{test}} \sum_{j=1}^n \eta_j \quad (7)$$

A. مجموعه داده های آزمایشی چند کلاسی با تعادل عالی

مجموعه داده های Iris و تعیین wine دو معیار طبقه بندی شناخته شده هستند که در زیرمجموعه داده های متعادل و چندکلاسی طبقه بندی شده اند. مجموعه داده های Iris از دانشگاه کالیفرنیا بدست آمده اند، مخزن یادگیری ماشین (UCI) Irvine، و توسط چندین روش طبقه بندی مانند NFI, PBL-McRBFN مورد آزمایش قرار گرفته است. این مجموعه داده دارای ۵۰ نمونه است که هر نمونه دارای چهار صفت به نامهای طول کاسبرگ، عرض کاسبرگ، طول گلبرگ و عرض گلبرگ می باشد. مجموعه داده های Iris، مجموعه ای با چندکلاسی است و شامل سه کلاس با نامهای iris setosa، iris versicolor و iris virginica می باشد.

به عنوان اولین مطالعه، ۵۰ درصد از مجموعه داده های Iris به صورت تصادفی به عنوان مجموعه داده های آزمایشی انتخاب می شوند. درحالیکه بقیه نمونه ها به عنوان مجموعه داده آزمایشی در نظر گرفته می شوند. جدول ۱ تعداد طبقه بندی های نادرست با استفاده از NFI، ELiEC و MLP را با هم مقایسه می کند. نتایج نشان می دهد که استفاده از ELiEC منجر به میانگین تعداد خطای ۲,۲ می شود که از دو روش دیگر کمتر می باشد.

مدل طبقه بندی	مشخصات نتایج		
	ساختار	خطای آزمایش	تعداد داده های آموزشی
BELBEC	۱۵ همسایه	۲,۲	۷۵
NFI	۶,۳ همسایه	۳,۳	۷۵
MLP	۱۲ سلول عصبی	۴,۶	۷۵

جدول ۱: مقایسه کارایی طبقه بندی BELBEC و سایر روشها برای مجموعه داده های Iris با ۵۰ درصد به عنوان داده های آموزشی و ۵۰ درصد به عنوان داده های آزمایشی

مدل طبقه بندی	مشخصات نتایج		
	ساختار	میانگین دقت کلاس	تعداد داده های آموزشی
BELBEC بدون نرمال سازی	۱۶ همسایه	٪۹۹,۰۲	۴۵
McNN	۵ سلول عصبی	٪۹۷,۱۴	۲۲
PBL-	۶ سلول عصبی	٪۹۸,۱۰	۲۰

McRBFN			
BELBEC	۱۸ همسایه	٪۹۶,۲۴	۶۰
McNN	۹ سلول عصبی	٪۹۸,۴۹	۲۷
PBL-McRBFN	۱۱ سلول عصبی	٪۹۸,۶۹	۲۹
گروه (OC-SVM)	---	٪۹۲,۰۰	---

جدول II. دقت طبقه بندی BELBEC برای مجموعه داده های Iris با ۴۵ نمونه به عنوان داده ی آموزشی و ۱۰۵ نمونه به عنوان داده ی آزمایشی

به عنوان نمونه دوم، ELIEC، مجموعه iris را با استفاده از ۴۵ نمونه به عنوان مجموعه داده ی آموزشی طبقه بندی نمود.

مجموعه داده ی wine دومین مجموعه داده ای است که برای ارزیابی ELIEC مورد استفاده قرار گرفته است. این مجموعه داده چند کلاسی بوده و به خوبی متعادل می باشد. این داده ها از تحلیل شیمیایی برخی نوشیدنی ها که از ارقام مختلف در مناطق مشابه ایتالیا تولید شده اند بدست آمده است. مثال مجموعه داده شامل ۱۳ ویژگی است و می تواند به سه کلاس دسته بندی شود. جدول I نتایج ELIEC و سه روش: McNN, PBL-McRBFN و یک روش دیگر از نوع طبقه بندی گروهی را مقایسه می کند. نام این مدل OC-SVM است که از آن به عنوان ماشینهای برداری پشتیبانی یک کلاسی یاد می شود. در این آزمایش ما از ۶۰ نمونه به عنوان نمونه های آموزشی و ۱۱۸ نمونه به عنوان نمونه های آزمایشی استفاده می کنیم. قابل مشاهده است که ELIEC دارای نتایج خوبی در طبقه بندی مجموعه داده هایی است که به خوبی متعادل شده اند.

همانطور که گفته شد، ELIEC بر پایه W-kNN است بنابراین ما نتایج ELIEC و W-kNN را برای طبقه بندی مجموعه داده های wine مقایسه می کنیم (جدول II را مشاهده نمایید). ما همچنین ELIEC و W-kNN را برای طبقه بندی مجموعه داده های Wine با دو ساختار متفاوت مقایسه می کنیم. همانطور که جدول III نشان می دهد، دقت طبقه بندی ELIEC هنگامیکه تعداد کل همسایه های طبقه بندی ELIEC فقط هشت همسایه است اختلاف قابل

ملاحظه ای ندارد. به هر حال، هنگامیکه ما تعداد کمتری همسایه برای W-kNN تعریف می کنیم، دقت آن به میزان قابل توجهی کاهش می یابد.

مدل طبقه بندی	مشخصات نتایج		
	ساختار	میانگین دقت کلاس	تعداد داده های آموزشی
BELBEC	۱۸ همسایه	٪۹۶،۲۴	۶۰
BELBEC	۸ همسایه	٪۹۵،۲۷	۶۰
KNN	۳ همسایه	٪۹۵،۴۰	۶۰
KNN	۱۸ همسایه	٪۹۱،۶۰	۶۰

جدول III. مقایسه بین ELIEC و W-kNN برای مجموعه داده های wine

B. ابعاد پایین و دودویی

پایگاه داده اختلالات کبدی (LD) و بیماران دیابتی هند PIMA دو مجموعه داده ی پزشکی هستند که با روشهای مختلف طبقه بندی مورد آزمایش قرار گرفته اند. ناراحتی های کبدی (LD) به آزمایش خون مربوط می شوند و به ترتیب دارای ۳۴۵ نمونه و ۶ ویژگی می باشد. مجموعه بیماران دیابتی هند PIMA دیگر مجموعه داده ی پزشکی است و توسط موسسه ملی دیابت و بیماریهای هاضمه و کلیه ارائه می شود. از این داده ها برای تشخیص دیابت استفاده می شود. تعداد نمونه ها و تعداد ویژگیها به ترتیب ۷۶۸ و ۸ می باشند. جدول IV نتایج ELIEC را برای مجموعه داده ها نشان می دهد و نتایج را با سه روش دیگر مقایسه می کند: McNN, PBL- و McRBFN و یک تغییر در تطبیق تقسیم و انتخاب (AdaSS). جدول نشان می دهد که نتایج McNN, PBL-McRBFN و یک تغییر در تطبیق تقسیم و انتخاب (AdaSS) بهتر از نتایج ELIEC است. به هر حال ELIEC دارای ساختار ساده تری نسبت به دو روش دیگر می باشد.

مدل طبقه بندی	مشخصات نتایج		
	ساختار	میانگین دقت کلاس	داده ها
BELBEC	۴۸ سلول عصبی	۶۸,۴	LD
McNN	۶۸ سلول عصبی	۷۱,۶۰	LD
PBL-McRBFN	۸۷ سلول عصبی	۷۲,۶۳	LD
BELBEC	۱۰۰ همسایه	۷۰,۳۷	PIMA
McNN	۱۹۳ سلول عصبی	۷۷,۳۱	PIMA
PBL-McRBFN	۱۶۲ سلول عصبی	۷۶,۶۷	PIMA
MAD	۷ خوشه و ۵ طبقه بندی کننده	۷۲,۰۱۰	PIMA

جدول IV. مقایسه بین روشهای مختلف برای دسته بندی LD و PIMA. تعداد نمونه های آموزشی برابر با ۵ می باشد.

VI. نتیجه گیری

این مقاله یک طبقه بندی گروه پایه جدید معرفی نموده است که از شبکه عاطفی مغز الهام گرفته است. معماری به ELiEC مراجعه نموده و از W-kNN به عنوان روش طبقه بندی اصلی استفاده نموده است. به هر حال ELiEC با سایر روشهای گروهی از نظر روش تزریق داده ها متفاوت می باشد. (شکل ۲ را ملاحظه نمایید).

کارایی ELiEC با استفاده از چند مجموعه داده معیار مورد ارزیابی قرار گرفته است. نتایج نشان دهنده ی عملکرد نسبتا خوب ELiEC در طبقه بندی می باشد.

به عنوان کاری برای آینده، ما W -kNN را با سایر روشهای طبقه بندی یادگیری مثلا ماشین بردار پشتیبانی برای حل پیچیدگی زمانی و مسائل مربوط به ابعاد جایگزین می کنیم. علاوه بر این، روش جنگل تصادفی می تواند از یک طبقه بندی فراگروهی مورد استفاده قرار گیرد.

VII. منابع

- [1] G. S. Babu and S. Suresh, "Meta-cognitive neural network for classification problems in a sequential learning framework," *Neurocomputing*, vol. 81, pp. 86–96, Apr. 2012.
- [2] S.B. Kotsiantis, I.D. Zaharakis, and P.E. Pintelas, "Machine Learning: A Review of Classification and Combining Techniques," *Artificial Intelligence Review*, vol.26, pp. 159- 190, 2006.
- [3] T.Phyu, "Survey of Classification Techniques in Data Mining", in.Proc. International Multi Conference of Engineers and Computer Scientists, vol, I IMECS 2009, 2009.
- [4] L. Rokach, "Ensemble-based classifiers," *Artificial Intelligence Review*, vol. 33, no. 1, pp. 1–39, 2010.S.B. Kotsiantis, *Supervised Machine Learning: A Review of Classification Techniques*, J. Informatica(31),pp. 249-26, 2007.
- [5] G. S. Babu and S. Suresh, "Sequential Projection-Based Metacognitive Learning in a Radial Basis Function Network for Classification Problems," *Neural Networks and Learning Systems*, IEEE Transactions on , vol.24, no.2, pp.194,206, Feb. 2013
- [6] Q.Song; N.K.Kasabov, "NFI: a neuro-fuzzy inference method for transductive reasoning," *Fuzzy Systems*, IEEE Transactions on , vol.13, no.6, pp.799,808, Dec. 2005
- [7] J.Moren, C.Balkenius, "A computational model of emotional learning in the amygdala," in *From Animals to Animats*, MIT, Cambridge, 2000.
- [8] C. Lucas, D. Shahmirzadi, N. Sheikholeslami, " Introducing BELBIC: brain emotional learning based intelligent controller," *J. INTELL. AUTOM. SOFT. COMPUT.*, vol. 10, no. 1, pp. 11-22, 2004.
- [9] R. M. Milasi, C. Lucas, B. N. Araabi, "Intelligent Modeling and Control of Washing Machines Using LLNF Modeling and Modified BELBIC," in *Proc. Int. Conf. Control and Automation.*, pp.812-817, 2005,
- [10] N. Sheikholeslami, D. Shahmirzadi, E. Semsar, C. Lucas., "Applying Brain Emotional Learning Algorithm for Multivariable Control of HVAC Systems," *J. INTELL. FUZZY. SYST.*vol.16, pp. 1–12, 2005.
- [11] M. Parsapoor, C. Lucas and S. Setayeshi, "Reinforcement _recurrent fuzzy rule based system based on brain emotional learning structure to predict the complexity dynamic system," in *Proc. IEEE Int. Conf. ICDIM*,pp.25-32, 2008.
- [12] M. Parsapoor, U. Bilstrup, "Brain Emotional Learning Based Fuzzy Inference System (BELFIS) for Solar Activity Forecasting," in *Proc. IEEE Int. Conf. ICTAI 2012*, 2012.
- [13] M. Parsapoor, Lucas.C, Setayeshi.S, "Modifying Brain Emotional Learning Model for Adaptive Prediction of Chaotic Systems with Few Data Training Samples, " in *Proc. Int. Conf. ICAOR*. pp. 328-341,2008.
- [14] M. Parsapoor, M, U. Bilstrup, "Neuro-fuzzy models, BELRFS and LoLiMoT, for prediction of chaotic time series," in *Proc. IEEE Int. Conf. INISTA.*, pp.1-5, 2012.
- [15] C. Lucas, A. Abbaspour, A. Gholipour, B. Nadjar Araabi, M. Fatourehchi, "Enhancing the performance of neurofuzzy predictors by emotional learning algorithm," *J. Informatica* , vol. 27, no. 2 pp.165–174, 2003.
- [16] T. Babaie, R. Karimizandi ,C. Lucas, "Learning based brain emotional intelligence as a new aspect for development of an alarm system," *J. Soft Computing.*, vol. 9, issue 9 ,pp.857- 873, 2008.
- [17] G. Shakhnarovich, T. Darrell,and P.Indyk, *Nearest-Neighbor Methods in Learning and Vision:Theory and Practice*, MIT Press, March 2006.
- [18] C. Blake and C. Merz. (1998). *UCI Repository of Machine Learning Databases*. Dept. Information & Computer Sciences, Univ. California, Irvine [Online]. Available: <http://archive.ics.uci.edu/ml/>.
- [19] M. Fatourehchi, C. Lucas, and A.K. Sedigh, "Emotional Learning as a New Tool for Development of Agent-based System," *J. Informatica (Slovenia)*, vol. 27, no. 2, pp.137- 144., 2004.
- [20] C. Blake and C. Merz. (1998). *UCI Repository of Machine Learning Databases*. Dept. Information & Computer Sciences, Univ. California, Irvine [Online]. Available: <http://archive.ics.uci.edu/ml/>.

- [21] M. Wozniak and B. Krawczyk, "Combined classifier based on feature space partitioning, " J.Applied Mathematics and Computer Science vol. 22, no4, pp. 855-866., 2012.
- [22] B. Cyganek, "One-Class Support Vector Ensembles for Image Segmentation and Classification, ", J. Mathematical Imaging and Vision, vol. 42, no 2-3, pp.103-117 2012.
- [23] R.Burduk, "New AdaBoost Algorithm Based on Interval- Valued Fuzzy Sets, " J. IDEAL pp. 794-801, 2012.