

شناسایی حروف دستنویس فارسی با استفاده از ترکیب دسته بندهای

ماشین بردار پشتیبان مبتنی بر استخراج ویژگی

مازیار کاظمی¹، محمد یوسف نژاد²، صابر نوریان³

¹ دانشجوی ارشد، دانشکده علوم کامپیوتر و هوش مصنوعی، موسسه آموزش عالی روزبهان، ساری
maziar.kazemi@rouzbahan.ac.ir

² دانشجوی دکتری، دانشکده علوم و تکنولوژی کامپیوتر، دانشگاه هوا و فضای نانجینگ، چین
myousefnezhad@nuaa.edu.cn

³ دانشجوی دکتری، دانشکده برق، دانشگاه علم و صنعت ایران، تهران
snourian@elec.iust.ac.ir

چکیده

یکی از تحولات عمده یادگیری ماشین، ارائه روش های ترکیبی است که با استفاده از ترکیب نتایج چندین دسته بند جزء، یک دسته بند بسیار دقیق ایجاد می شود. در این مقاله روشی جدید برای ترکیب دسته بندی ها ارائه و بر روی مجموعه بزرگی از حروف دستنویس فارسی مورد آزمایش قرار گرفته است. این روش در هر مرحله تکرار، داده های ورودی را به صورت تصادفی به چند دسته تقسیم می کند سپس بر روی هر دسته روش آنالیز اجزای اصلی را اعمال کرده و ویژگی ها را استخراج می کند. بردار ویژگی نهایی از ادغام این ویژگی ها ایجاد و با دسته بند ماشین بردار پشتیبان، آموزش داده می شود. ویژگی این روش نسبت به سایر روش های ترکیبی افزایش همزمان درصد صحت دسته بند پایه و پراکندگی نمونه ها در هر مرحله است. با استفاده از این روش به طور متوسط درصد صحت ماشین بردار پشتیبان برای داده های حروف دستنویس فارسی از $78/06$ به $82/51$ افزایش یافته است.

کلمات کلیدی:

شناسایی حروف دستنویس فارسی، ترکیب دسته بندی کننده ها، درصد صحت، ماشین بردار پشتیبان، آنالیز اجزای اصلی

1) مقدمه

است اما در مورد زبان های فارسی و عربی به دلیل ویژگی های خاص (Addakiri K., 2012) این زبان ها، الگوریتم ها و نرم افزارهای طراحی شده از دقت کمتر و قدرت تشخیص پایین تری برخوردارند. در زمینه تشخیص حروف فارسی (مخصوصاً حروف دستنویس) نیز تحقیقات کمتری انجام شده و کمبودهایی در این زمینه وجود دارد. روش های داده کاوی به دو دسته یادگیری با ناظر و یادگیری بدون ناظر تقسیم می شوند. یکی از ناحیه های تحقیقی فعال در یادگیری با ناظر مطالعه بر روی ساختار روش های ترکیبی دسته بندی کننده ها است. این روش ها عملکرد دسته بندهای پایه را به صورت چشمگیری بهبود می بخشند. (M., 2013)

هدف از این مقاله، ارائه روشی جدید برای ترکیب دسته بندی کننده ها و به کارگیری آن برای شناسایی حروف دستنویس فارسی می باشد.

امروزه بازشناسی الگو در بسیاری از زمینه ها نقش کاربردی دارد. یکی از شاخه های بازشناسی الگو، بازخوانی نوری نویسه ها (OCR) است که به طور گسترده در ادبیات یادگیری ماشین مورد استفاده قرار می گیرد (Vivt Pham, 2012). شناسایی حروف دستنویس نیز، زیر مجموعه ای از OCR است (Ghods V., 2013). در دو دهه ی گذشته، فعالیت های وسیعی برای استفاده از کامپیوتر در خواندن متن های دستنویس انجام شده است (Kumar Garg N., 2011) که بعضی از این روش ها مانند روش تطبیق الگوها نسبت به اندازه و تغییر مکان حساس بوده و نیاز به نرمالسازی دارند بنابراین ما به دنبال الگوریتم هایی هستیم که نیاز به نرمالسازی نداشته باشند (Kazemi M., 2014). تحقیقات زیادی در زمینه OCR انجام شده است که اساساً برای شناسایی اعداد و حروف انگلیسی بوده و نتایج خوبی در این زمینه به دست آمده

مجموعه بزرگی از حروف دستنویس فارسی در این مقاله مورد آزمایش قرار گرفته است.

در ادامه در بخش دوم کارهای انجام شده مورد بررسی قرار می‌گیرد سپس در بخش سوم مدل پیشنهادی ارائه می‌گردد. در بخش چهارم به ارزیابی و بررسی فواید و مشکلات مدل پیشنهاد شده پرداخته می‌شود و در نهایت در بخش پنجم نتایج حاصل از این مقاله و خط مشی کارهای آینده بیان می‌شود.

2) کارهای انجام شده

در این بخش به مروری بر کارهای انجام شده در زمینه تشخیص حروف دستنویس فارسی و عربی می‌پردازیم.

مسرووی (K., 2000) روشی برای بازشناسی حروف مجزای دستنویس فارسی ارائه نموده است. وی ۳۳ کلاس برای حروف فارسی در نظر گرفته است. بازشناسی حروف در دو مرحله انجام می‌گیرد. در مرحله اول به کمک یک طبقه بندی کننده فازی « قاعده - پایه » که قوانین آن به وسیله مجموعه نمونه های آموزشی یاد گرفته می‌شوند، حروف به ۸ گروه تقسیم می‌گردند. ویژگی های مورد استفاده در این مرحله با روش مکان های مشخصه در راستاهای ۹۰ و ۴۵ درجه از تصویر باینری حرف بدست می‌آید. در مرحله دوم، به وسیله طبقه بندی کننده های درخت تصمیم که برای هر گروه به طور خاص طراحی شده اند، بازشناسی نهایی حروف در هر گروه انجام می‌گیرد. در این مرحله، ویژگی های به کار رفته عموماً ساختاری هستند.

صالحیان و همکاران در (Salehian N., 2008) یک سیستم کامل برای شناسایی کلمات فارسی نستعلیق با استفاده از شبکه های عصبی ارائه کرده اند. آن ها در مرحله پیش پردازش، پس از یافتن بخش های متصل، سرکش ها و زیرکش های حروف را کشف و از تصویر حذف کردند و با استفاده از یک الگوریتم تقطیع که بر اساس کانتور بالایی و پایینی کلمه عمل می‌کند، تصویر کلمه را به دنباله ای از زیر کلمه ها تقسیم کردند. پس از انجام عمل تقطیع، هشت ویژگی شامل سه توصیفگر فوریه و تعدادی ویژگی ساختاری برای نمایش زیر کلمه ها در فضای ویژگی بکار برده شد. شناسایی با استفاده از یک شبکه عصبی پرسپترون انجام شده است.

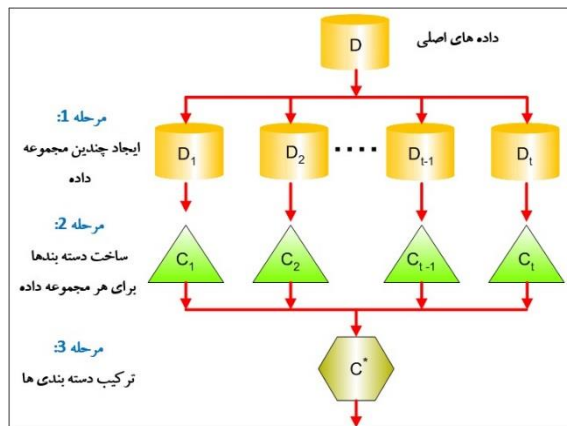
مولایی و همکاران (Mowlaei A., 2002) روشی به منظور بازشناسی کد های پستی و اسامی شهر های ایران که بر روی بسته های پستی به صورت دست نویس نوشته می‌شوند، پیشنهاد نموده اند. بردارهای ویژگی این روش، از طریق بکارگیری تبدیل موجک گسته (DWT) با موجک اساسی هار محاسبه می‌گردند. در مرحله استخراج ویژگی ها، تبدیل موجک سه سطحی بر روی تصویر نازک شده اعمال می‌شود. برای آموزش سیستم، یک شبکه عصبی پرسپترون چند لایه با قانون پس انتشار خطا مورد استفاده قرار می‌گیرد.

کلاکسین و همکاران (Khorshed M.S., 2000) الگوریتمی برای بازشناسی کلمات عربی بدون تقطیع طراحی نموده اند که در آن ابتدا هر کلمه به یک تصویر قطبی نرمالیزه تبدیل می‌شوند و آنها سپس یک تبدیل فوریه دو بعدی به تصویر قطبی اعمال می‌گردند. مرحله بازشناسی با بکارگیری تابع فاصله اقلیدسی نرمالیزه شده انجام می‌گیرد. جهت آزمایش این الگوریتم، بیش از ۱۷۰۰ کلمه در ۴ فونت مختلف مورد استفاده قرار می‌گیرد.

3) مدل پیشنهادی

انتخاب نوع مدل دسته بندی، یکی از مراحل بازشناسی الگو است. دسته بند به عنوان هسته اصلی یک سامانه بازشناسی الگو مطرح است (Kuncheva, 2004).

معمولاً مدل های مختلف، پیشبینی های متفاوت با نتیجه های متفاوت ایجاد می‌کنند. بنابراین می‌توانیم برای دستیابی به نتایج بهتر، تعداد مدل ها را با استفاده از زیرمجموعه داده های متفاوت توسعه دهیم و یا از شرایط مختلف در روش مدل سازی انتخابی استفاده کنیم (Alizadeh H., 2015). ایده کلی در شکل (۱) نشان داده شده است:



شکل (۱): اندیشه کلی روش های ترکیبی

اگر تعدادی دسته بند پایه داشته باشیم می‌توان با ترکیب نتایج آن‌ها به دقت بالاتری رسید. ایده روش های ترکیبی به این صورت است که مجموعه‌ای از دسته بندی کننده‌ها را با داده‌های آموزشی ایجاد کرده و میزان صحت را با انجام عملیات رای گیری بر روی نتایج آن ها بدست می‌آوریم. نحوه محاسبه خطای این روش با فرض داشتن N دسته بند که خطای هر یک P است از رابطه زیر محاسبه می‌شود:

$$P(error) = \sum_{k=\frac{N}{2}+1}^N \binom{N}{k} p^k (1-p)^{N-k} \quad (1)$$

در واقع مفهوم ترکیب این است که خروجی چندین مدل با هم مخلوط شده تا به تصمیم گیری بهتر برسند (Alizadeh H., 2015). روش های ترکیبی در بیشتر حالت‌ها نتایج بهتری نسبت به دسته بندی کننده تنها دارند (Hassanzadeh M., 2013).

در ادامه ابتدا در مورد دسته بند پایه ماشین بردار پشتیبان (SVM) و روش کلاسیک ترکیبی یعنی روش خودراه انداز متراکم (Bagging)

توضیحات مختصری داده شده و سپس روش پیشنهادی را شرح می دهیم.

• ماشین بردار پشتیبان

ماشین بردار پشتیبان بیشترین حاشیه بین دو کلاس را در یک فضای ویژگی خاص پیدا می کند (Weston., 2010). تابع تصمیم گیری برای جدا کردن داده‌ها با استفاده از بردارهای پشتیبان که نزدیک ترین داده های آموزشی به ابرصفحه جداکننده هستند، تعیین می شود. در واقع ابرصفحه بهینه در ماشین بردار پشتیبان جداکننده ای بین بردارهای پشتیبان است. مرز تصمیم گیری معمولاً با استفاده از یک تابع خطی به دست می آید اما در بعضی از حالات این مرز به صورت خطی قابل تفکیک نیست، بنابراین داده ها را به فضای ویژگی با ابعاد بالاتر انتقال می دهند که در این فضا داده ها به صورت خطی قابل جداسازی هستند (Watt., 2007). برای انتقال، ابتدا تابع $\varphi(x)$ را برای نگاشت به فضای دیگر پیدا می کنیم. با استفاده از تابع کرنل $K(x, x_i) = \varphi(x_i)^T \varphi(x)$ ، تابع تصمیم گیری ماشین بردار پشتیبان به این صورت نمایش داده می شود:

$$f(x) = \sum_{i=1}^n \alpha_i y_i K(x, x_i) + b \quad (2)$$

در رابطه (2) $f(x)$ خروجی تصمیم، y_i برچسب داده های x و x_i داده ای است که قرار است دسته بندی شود. پارامترهای α_i و b در طول آموزش مقداردهی می شوند. کرنل های زیادی وجود دارد اما برای مسئله OCR، بهترین کرنل تابع شعاع مینا¹ (RBF) می باشد:

$$K(x, x_i) = \exp(-\gamma \|x - x_i\|^2) \quad (3)$$

در رابطه (3) پارامتر جریمه و در رابطه (3) γ پارامتر کرنل می باشد.

• روش خودراه انداز متراکم (Bagging)

این روش با دستکاری مجموعه داده های آموزشی ایجاد می گردد. در این روش مجموعه داده های آموزشی به صورت مضاعف ساخته می شوند. داده ها در این مرحله با روش نمونه برداری تصادفی با جایگزینی انتخاب می شوند در نتیجه با این که دسته بندها یکسان هستند ولی به دلیل انتخاب تصادفی نمونه ها، نتایج متفاوت خواهد بود. در نهایت با انجام عملیات رای گیری روی خروجی های بدست آمده از دسته بندها، نتیجه نهایی حاصل می گردد. این روش برای الگوریتم های ناپایدار، که تغییر کوچکی در ورودی، دچار تغییر در نتیجه آن ها می شود مناسب است.

• روش پیشنهادی

رودریگز و همکاران روشی جدید برای ترکیب دسته بندی کننده ها ارائه کرده اند که این روش امروزه به روش جنگل تصادفی

(Rotation Forest) معروف است. این الگوریتم بر پایه استخراج ویژگی می باشد. برخلاف روش های دسته بندی معمول، داده های آموزشی فقط یک نسبت از کل مجموعه داده ها نیست بلکه به طور تصادفی به K زیرمجموعه تقسیم می شود و سپس تبدیل آنالیز اجزای اصلی (PCA) بر هر دسته اعمال می گردد. زیرمجموعه های انتخاب شده می توانند به صورت جدا از هم آ و یا مشترک³ انتخاب شوند ولی برای رسیدن به پراکندگی مناسب از زیر مجموعه های جدا از هم استفاده شده است (Rodriguez, 2006).

روش پیشنهادی با تغییراتی در روش جنگل تصادفی (Rotation Forest) ایجاد شده است که الگوریتم آن به شرح زیر است.

Algorithm

Training Phase

Given

- X : the object in the training data set (an $N \times n$ matrix)
- Y : the labels of the training data set (an $N \times 1$ matrix)
- L : the number of classifiers in the ensemble
- K : the number of subsets
- $\{w_1, w_2, \dots, w_c\}$: the set of class labels

For $i = 1 \dots L$

- Prepare the Feature Vector
 - Split F (the feature set) into K subsets
 - For $j = 1 \dots K$
 - * Let $X_{i,j}$ be the data set X for the features in $F_{i,j}$
 - * Eliminate from $X_{i,j}$ a random subset of classes
 - * Apply PCA on $X_{i,j}$ to obtain the feature vector $C_{i,j}$
 - Construct final feature vector R by merge the $C_{i,j}$
- Build classifier D_i using (R, Y) as the training set

Classification Phase

- Calculate maximum voting

$$\sum_{j=1}^L d_{j,k} = \max_{m=1}^c \sum_{j=1}^L d_{j,m}$$


ما روشی برای ترکیب دسته بندی کننده ها بر اساس استخراج ویژگی پیشنهاد کرده ایم. به منظور ایجاد داده های آموزشی برای دسته بندی پایه، مجموعه ویژگی ها را به صورت تصادفی به K

¹ Radial basis function

² disjoint

³ Intersecting

روش پیشنهادی در محیط متلب (ver8.1) پیاده سازی و مورد آزمایش قرار گرفته و نتایج آزمایش بر روی میانگین ۱۰ بار اجرای مستقل برنامه برای هر تکنیک گزارش شده است. نتایج حاصل از این آزمایش در جدول (۱) آمده است. در این مقاله ما از روشی جدید برای ترکیب دسته بندها استفاده کردیم که در این روش از ماشین بردار پشتیبان (SVM) به عنوان دسته بند پایه استفاده شده است. در جدول (۱) بهترین نتیجه ها به صورت پررنگ نشان داده شده است. نتایج حاصل از این روش به مراتب بهتر از سایر روش های دسته بندی است. روش خودراه انداز متراکم (Bagging)، روش دیگری برای ترکیب می باشد که نتایج خوبی از آن حاصل نشده است چون روش خودراه انداز متراکم (Bagging) برای دسته بندهای ناپایدار با اغتشاش کوچک عملکرد خوبی از خود نشان می دهد. به دسته بندهایی که با تغییری کوچک در ورودی، خروجی آن ها نیز دچار تغییر می شود ناپایدار می گویند و چون ماشین بردار پشتیبان (SVM) پایدار است در نتیجه این روش در خروجی تغییرات خوبی ایجاد نمی کند. مهمترین پارامتر در روش ارائه شده پارامتر K (تعداد باری که داده ها به صورت تصادفی تقسیم می شوند) می باشد. در شکل (۳) تاثیر این پارامتر بر عملکرد این روش نشان داده شده است.



شکل (۳) : تاثیر پارامتر K

همانطور که در شکل مشاهده می شود با افزایش مقدار K نتیجه حاصل بهبود پیدا می کند اما از یک مقداری به بعد نتایج حاصل کاهش می یابد. پس افزایش مقدار K تا یک حدی شاهد بهبود نتایج هستیم اما از این حد به بعد شاهد کاهش درستی نتایج هستیم. افزایش مقدار K باعث افزایش پراکندگی در انتخاب داده ها شده و سبب می شود تا ویژگی های متمایزتری برای آموزش انتخاب شود البته افزایش بیش از حد این پارامتر امکان انتخاب ویژگی های مشابه را افزایش می دهد و این امر سبب کاهش درصد صحت می شود. با توجه به شکل (۳) مقدار پارامتر $K=5$ انتخاب شده است.

مجموعه (k پارامتر الگوریتم است) تقسیم کرده و سپس به هر مجموعه تبدیل آنالیز اجزای اصلی (PCA) اعمال می کنیم. حال برای هر مجموعه m ضریب آنالیز اجزای اصلی (PCA) (m) به صورت تجربی تعیین می شود) را انتخاب می کنیم و سپس در انتها با ادغام این m ضریب، بردار ویژگی نهایی ایجاد می گردد. بردار ویژگی نهایی $k \times m$ مولفه دارد. بردار ویژگی ایجاد شده را با استفاده از دسته بند ماشین بردار پشتیبان (SVM) آموزش داده و پس از L بار تکرار الگوریتم (L به صورت تجربی تعیین می شود)، داده های آزمایشی را با L دسته بند ایجاد شده آزمایش می کنیم سپس با استفاده از روش رای گیری ماکزیمم خروجی نهایی را تعیین می کنیم.

(4) ارزیابی

در این بخش نتایج به کارگیری روش پیشنهادی روی مجموعه داده های مختلف و پارامترهای مورد استفاده گزارش می شود. ابتدا به توضیحاتی در مورد مجموعه داده ها می پردازیم و سپس به ارائه نتایج حاصل از روش پیشنهادی می پردازیم.

• مجموعه داده ها

روش پیشنهادی بر روی ۱۰ مجموعه داده مورد آزمایش قرار گرفته است. هر مجموعه شامل ۳۲۰۰ نمونه از حروف دستنویس فارسی می باشد که هر مجموعه دربردارنده ۱۰۰ نمونه برای هر حرف فارسی است. از هر مجموعه ۲۲۴۰ نمونه مربوط به فاز آموزش (۷۰ نمونه از هر حرف) و ۹۶۰ نمونه مربوط به فاز آزمون (۳۰ نمونه برای هر حرف) است. هر تصویر شامل یک پس زمینه سفید می باشد که حروف در وسط آن قرار دارد. ابتدا برای افزایش کیفیت تصاویر را به دودویی تبدیل کردیم و به منظور کاهش حجم محاسبات، حروف را از این پس زمینه جدا کرده و سپس آن را به یک اندازه استاندارد تبدیل می کنیم. در شکل ۲ چند نمونه از این داده ها نشان داده شده است:




شکل (۲) : چند نمونه از داده های استفاده شده

• نتایج آزمایش

افزایش مقدار C باعث بزرگتر شدن بردار ویژگی شده و اطلاعات بیشتری از تصویر حفظ می شود پس با افزایش آن، درصد صحت افزایش می یابد ما با زیاد شدن بیش از حد، باعث همپوشانی بردارهای ویژگی شده و درصد صحت کاهش می یابد. مقدار K با توجه به شکل (3) 5 انتخاب شده است پس اندازه بردار ویژگی نهایی ما برابر است با $C \times 5$ ، یعنی برای مقدار $C=4$ اندازه بردار ویژگی نهایی ما 20 می باشد.

در شکل (5) میانگین درصد صحت برای هر تکنیک آورده شده است. با توجه به این شکل می توان بهبود نتایج در روش پیشنهادی را به وضوح مشاهده کرد.

پارامتر دیگری که در این روش موثر است، C (تعداد ضرایب PCA که برای هر قسمت در نظر گرفته شده است) می باشد. در شکل (4) تاثیر این پارامتر نشان داده شده است.

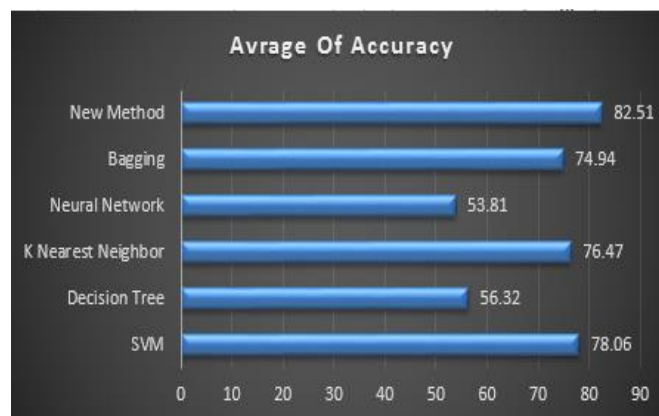


شکل (4) : تاثیر پارامتر C

با توجه به شکل (4)، با افزایش تعداد ضرایب تا 4 شاهد افزایش درصد صحت و پس از آن شاهد کاهش درصد صحت هستیم.

جدول (1) : نتایج حاصل از ارزیابی \pm خطای استاندارد 10 بار اجرای مستقل (Standard Error)

	SVM	DT	KNN	NN	Bagging	New Method
Random 1	77.01±0.415	52.27±0.639	72.92±0.481	54.06±0.633	72.71±0.434	83.06 ± 0.185
Random 2	78.42±0.419	56.94±0.155	78.65±0.454	55.94±0.569	75.68±0.227	81.74±0.068
Random 3	79±0.285	59.11±0.562	76.15±0.351	53.13±0.618	76.55±0.236	83.02±0.172
Random 4	79.38±0.425	60.12±0.581	79.17±0.294	60.63±0.414	79.47±0.243	83.41±0.168
Random 5	76.51±0.371	56.34±0.609	71.77±0.677	54.38±0.449	69.89±0.208	82.07 ±0.179
Random 6	77.26±0.328	52.87±0.483	77.19±0.319	51.88±0.456	75.68±0.224	79.86 ±0.184
Random 7	79.31±0.435	55.67±0.576	78.54±0.483	51.25±0.601	78.92±0.153	83.31±0.229
Random 8	79.06±0.449	56.50±0.658	76.56±0.553	51.25±0.395	75.72±0.186	83.8±0.189
Random 9	79.14±0.346	58.67±0.702	77.29±0.344	59.38±0.634	73.22±0.273	82.73±0.166
Random 10	75.56±0.351	54.74±0.558	76.46±0.341	46.25±0.508	71.59±0.335	82.15±0.155



شکل (5) : میانگین درصد صحت برای هر تکنیک

5 نتیجه گیری

Kazemi M., Yousefnezhad M., Nourian S. (2014) "Persian Handwritten Letters Recognition With Using Ensemble Methods", 2nd Conference on Computer and Information Technology (CSCIT2014), Iran, Tabriz.

Khorsheed M.S., Clocksin W.F. (2000) "Multi-font Arabic word recognition using spectral features", 15th International Conference on Pattern Recognition, vol. 6, 3574 - 3577.

Kumar Garg N., Kaur L., Jindal M. K. (2011) "The Hazards in Segmentation of Handwritten Hindi Text", International Journal of Computer Applications (IJCA).

L.I. Kuncheva (2004) "combining Pattern Classifier: Methods and algorithm", Published by John Wiley & Sons, Inc.

Govindarajan M. (2013) "Evaluation of Ensemble Classifiers for Handwriting Recognition", I.J. Modern Education and Computer Science.

Mowlaei A., Faez K., Haghghat A.T. (2002) "Feature extraction with wavelet transform for recognition of isolated handwritten Farsi/Arabic characters and numerals", 14th International Conference on Digital Signal Processing, Vol. 2, 923-926.

Salehian N., Yazdchi M., Karimian A. R. (2008) "Identification of Persian words nstaliq using artificial neural network", Scientific research of electrical engineering Majlesi.

Vivt Pham, Dung. (2012), "Online handwriting recognition using multi convolution neural networks", The Ninth International Conference on Simulated Evolution And Learning .

A. Ben-Hur and J. Weston. (2010) "A users guide to support vector machines. Technical report", Department of Computer Science. Colorado State University.

Masroori k., (2000) "The Persian handwritten letters recognition with Fuzzy Method", Ph.D. Thesis, University Of Tarbiat Modarres.

B. Keshari and S.M. Watt. (2007) "Hybrid mathematical symbol recognition using support vector machines", In Proceedings of the Ninth International Conference on Document Analysis and Recognition.

در این مقاله از روش جدید ترکیبی به منظور شناسایی حروف دست نویس فارسی استفاده شده است. از آنجایی که هیچ دسته بندی وجود ندارد که برای تمام مسائل جواب بهینه را تولید کند پس ما می توانیم با ترکیب نتایج آن ها به جواب مطلوب برسیم. نتایج تجربی این روش برای مسئله بازشناسی حروف دست نویس بر روی ۱۰ مجموعه داده مختلف و مقایسه آن با روش هایی مثل شبکه های عصبی، K نزدیکترین همسایه، خودراه انداز متراکم (Bagging) و ماشین بردار پشتیبان (SVM) نشان می دهد که این روش نسبت به روش های متداول دسته بندی برتری دارد در این روش با تغییراتی در مرحله استخراج ویژگی به روش جدیدی برای ترکیب دسته بندی کننده ها دست یافتیم. هدف این روش این است که با تقسیم بندی ویژگی های ورودی در هر مرحله، داده های متمایزتری برای آموزش ایجاد کرده تا در نهایت به دسته بندی متفاوتی برسیم و با ترکیب نتایج این دسته بندیها به نتیجه مورد نظر برسیم. از مزیت های این روش می توان دستیابی به درصد صحت بالاتر نسبت به سایر الگوریتم در زمینه شناسایی حروف دستنویس و عیب این روش زمان اجرایی بالاتر نسبت بقیه روش های پایه دسته بندی دانست.

برای کارهای آینده پیشنهاد می شود از دسته بندیهای متفاوت به عنوان دسته بندی پایه به جای ماشین بردار پشتیبان (SVM) استفاده شود همچنین با ترکیب این روش و سایر روش های ترکیبی می توان به نتایج بهتری دست پیدا کرد.

مراجع

Addakiri K., Bahaj M. (2012) "On-line Handwritten Arabic Character Recognition using Artificial Neural Network", International Journal of Computer Applications (IJCA), Volume 55.

Alizadeh H., Yousefnezhad M., Minaei-Bidgoli B. (2015) "Wisdom of Crowds Cluster Ensemble", Intelligent Data Analysis, IOS Press, Vol. 19(3).

Ghods V., Kabir E. (2013) "A Study on Farsi Handwriting Styles for Online Recognition", Malaysian Journal of Computer Science. Vol. 26(1).

Hassanzadeh M., Ardeshir G. (2013) "A New Classifiers Ensemble Method For Handwritten Pen Digits Classification", International Research Journal of Applied and Basic Sciences, Vol 5, pp. 1092-1096.

J. J. Rodriguez, L. I. Kuncheva, and C. J. Alonso, (2006) "Rotation forest: A new classifier ensemble method",