

## بهبود روش‌های طبقه‌بندی چهره مبتنی بر ماشین بردار پشتیبان فازی

لیلا یارمحمدی<sup>۱</sup>، امیر هوشنگ مزینان<sup>\*۲</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد مهندسی برق کنترل، دانشگاه آزاد اسلامی واحد تهران جنوب

<sup>\*۲</sup> دانشیار دانشکده مهندسی برق، گروه مهندسی برق کنترل، دانشگاه آزاد اسلامی واحد تهران جنوب

**چکیده:** در این پژوهش به الگوریتم‌های تشخیص چهره‌ی خودکار پرداخته می‌شود. بدین منظور از ترکیبی از الگوریتم‌های یادگیری با نظارت استفاده می‌شود؛ به این ترتیب که ابتدا طبقه‌بندی با استفاده از ماشین بردار پشتیبان فازی طراحی شده و سپس برای دقت بیشتر و کنترل بیش‌برازش، متا الگوریتم آدابوست بر طبقه‌بند طراحی شده اعمال می‌شود. در اینجا برای رفع اثر کلاس‌های نامتقارن از ضرایبی تطبیقی بهره گرفته می‌شود، ضمن آنکه برای کاهش ابعاد داده‌ها، تحلیل مولفه‌های اصلی بر روی داده‌های خام اعمال می‌شود. روش معرفی شده بر روی مجموعه‌ای از تصاویر استخراج شده از پایگاه داده‌ی دانشگاه ییل اعمال می‌شود و درستی و دقت روش پیشنهادی صحت‌سنجی می‌گردد.

**کلمات کلیدی:** تشخیص چهره، طبقه‌بند، ماشین بردار پشتیبان فازی، آدابوست.

## Improvement of Face Recognition Approach through Fuzzy-based SVM

L. Yar Mohammady, A. H. Mazinan

**Abstract:** In this investigation, automatic face recognition algorithms are discussed. For this purpose, a combination of learning algorithms with supervision are realized; in this way, the classification is first designed by the fuzzy-based support vector machine and then the AdaBoost meta-algorithm is applied to the designed classification to reach more accuracy and overfitting control. In the research proposed here, in order to address the effects of asymmetric classes, the adaptive coefficients are employed. In addition, to reduce the data size, the principal components analysis is also applied to the raw data. It is to note that the proposed approach is carried out in a set of images extracted from Yale University data set and its accuracy of the proposed one is verified.

**Keywords:** Face recognition, classification, fuzzy-based support vector machine, AdaBoost.

## مقدمه

تشخیص چهره عملی است که انسان‌ها معمولاً بدون هیچ تلاشی و به صورت ناخودآگاه انجام می‌دهند، اما در حوزه‌ی بینایی رایانه‌ای حتی پس از ۳۰ سال تحقیق و پژوهش نیز هنوز مسأله‌ای مشکل بوده و در ابتدای مسیر دستیابی به راه-حلی تکنولوژیکی و موثر است. تشخیص چهره‌ی خودکار به عنوان یک فناوری بیومتریک، ویژگی‌های مطلوبی دارد که تحقیقات را به سمت تکنیک‌های عملی سوق می‌دهد.

شناسایی و تشخیص چهره در طول یک دهه‌ی گذشته، به یکی از محبوب‌ترین حوزه‌های تحقیقاتی و کاربردی در علوم تشخیص و تحلیل سیستم تبدیل شده است. یکی از اهداف چنین تحقیقاتی توسعه سیستم‌های امنیتی کاربر دوست است. اگر چه روش‌های بیومتریک قابل اطمینانی همچون آنالیز اثر انگشت و اسکن شبکیه یا عنبیه موفق ظاهر شده‌اند، اما این روش‌ها به همکاری شرکت‌کنندگان احتیاج دارند. در حالی که سیستم‌های مبتنی بر تصاویر معمولاً بدون نیاز به همکاری یا آگاهی شرکت‌کننده نیز موثرند.

کاهش قیمت دوربین‌ها و افزایش توان عملیاتی موجود، موجب توسعه و تولید الگوریتم‌های جدیدی شده است که سیستم‌های تشخیص چهره را کاربردی‌تر کرده است. این سیستم‌ها به طور فزاینده‌ای در بازه‌ی وسیعی از کاربردهای عملی به کار گرفته شده‌اند و پیشرفت‌های آتی نویدبخش استفاده‌ی بیشتر از تشخیص چهره خواهد بود.

تشخیص خودکار چهره‌ی انسان طیف وسیعی از فناوری‌ها را در برمی‌گیرد. در بالاترین سطح، فناوری‌ها با نوع رسانه‌ی ورودی اعم از نور مرئی، فروسرخ یا داده‌های سه بعدی از هم متمایز می‌شوند. با این وجود، تمرکز بیشتر بر تصاویر عکس-برداری شده‌ی ثابت و در نور مرئی و معمولاً سیاه و سفید است، هرچند تشخیص چهره در تصاویر ویدیویی رنگی نیز اخیراً مورد توجه قرار گرفته است [۱]. هر رسانه‌ی ورودی مورد استفاده، تشخیص چهره را در برابر شرایط خاصی مقاوم می‌کند، مثلاً تصویربرداری فروسرخ از صورت عملاً در برابر تغییر نور مقاوم است [۲] یا داده‌های سه بعدی در تئوری در برابر نحوه‌ی

قرارگیری سر تغییرناپذیر است [۳]. با این وجود تصویربرداری در طیف نور مرئی به دلیل حجم وسیع داده‌های میراثی، حضور آسان و همیشگی و تجهیزات تصویربرداری ارزان قیمت، همچنان در حوزه‌های تحقیقاتی و کاربردی برجسته است.

پژوهش‌هایی که تاکنون در حوزه‌ی تشخیص چهره صورت پذیرفته است کمتر به تشخیص چهره در حالت‌ها، ظاهر، شدت نور و حالت‌های چهره به طور همزمان پرداخته است. همین امر سبب شد تا به دنبال رویکردی جامع در تشخیص چهره پرداخته شود. از این رو روش ماشین بردار پشتیبان فازی با ضرایب تطبیقی در ترکیب با الگوریتم آدابوست اتخاذ شد. این روش یکی از روش‌های یادگیری با نظارت است که در آن داده به دو بخش داده‌های آموزش و داده‌های آزمایش تقسیم شده و با استفاده از داده‌های آموزش طبقه‌بند طراحی می‌شود، سپس با داده‌های آزمایش درستی و دقت عملکرد طبقه‌بند مورد بررسی قرار می‌گیرد. ضمن آنکه برای کاهش ابعاد داده‌ها، استفاده از روش‌های کاهش بعد ضروری می‌نمود. در ادامه در قسمت ۲ نگاهی بر ادبیات تحقیق خواهیم کرد. در قسمت ۳ روش‌های مورد استفاده معرفی می‌شوند. نتایج عددی در قسمت ۴ گنجانده شده و در نهایت در قسمت ۵ نتیجه‌گیری کلی صورت می‌پذیرد.

## مروری بر ادبیات تحقیق

از آنجا که داده‌های مورد استفاده در روند تشخیص چهره، تصاویر صورت هستند، طبیعی است که ابعاد داده‌های خام عددی بسیار بزرگ شود. از این رو در روش‌های تشخیص چهره‌ی ویژگی محور، بهره‌گیری از روش‌های استخراج ویژگی امری معمول به حساب می‌آید.

روش‌های کاهش ابعاد زیادی اعم از روش‌های مبتنی بر فضاهای ویژه [۴] - [۶] روش‌های مبتنی بر تابع هسته [۷] - [۹] و روش‌های مبتنی بر هسته‌ی فیشر [۱۰] معرفی شده‌اند؛ اما به دلیل سرعت کم پردازش و سختی تنظیم پارامترهای هسته در روش‌های غیرخطی، در این پژوهش از روش خطی PCA بهره گرفته شده است.

[۱۶]. در FSVM به هر داده‌ی آموزش درجه عضویتی نسبت داده می‌شود. درجه عضویت‌های متفاوت منجر به رویکردهای متفاوت در یادگیری ابرصفحه می‌شود. به این ترتیب هنگام یافتن ابرصفحه‌ی جداکننده اثر داده‌های پرت و نویزی کاهش می‌یابد. ونگ [۱۹] با معرفی دو تابع عضویت برای هر نمونه، یک FSVM با وزن دو جانبه را ارائه داد که بعدها در [۲۰] به مجموعه‌های مبهم نیز تعمیم داده شد. ایب و آینو FSVM را برای مسائل چند کلاسه پیشنهاد کردند [۲۱] که تعمیمی از مساله‌ی طبقه‌بندی باینری بود و سپس آن را به طبقه‌بندی چند کلاسه‌ی متن اعمال نمودند [۲۲]. رگرسیون بردار پشتیبان فازی نیز در [۲۳] معرفی شد.

چگونگی انتخاب درجه عضویت فازی مناسب در حال حاضر مساله‌ای باز است و کارهای زیادی در این زمینه صورت گرفته است. [۱۶] تابع عضویت فازی را بر مبنای فاصله‌ی اقلیدسی بین نمونه‌ها و مرکز کلاس‌ها در فضای اصلی تعریف می‌کند؛ در حالی که [۲۴] این فواصل را در فضای ویژگی با بعد بالا تعریف می‌کند. هرچند هر دو این توابع عضویت فازی بر مبنای فاصله‌ی بین هر نمونه و مرکز کلاسشان می‌باشند. در [۲۵]، [۲۶] توابع عضویت فازی بر مبنای فاصله‌ی نمونه‌ها و مراکز دسته‌هایشان و وابستگی بین نمونه‌ها محاسبه می‌شود. توابع عضویت دیگری نیز با استفاده از مقادیر تصمیم تولید شده با SVM بدست می‌آیند [۲۷]، [۲۸]. در [۲۹] با استفاده از ساختار (وردایی) درون کلاسی نمونه‌ها، دانش اولیه‌ی نسبت به اهمیت داده‌ها بدست می‌آید که در تعیین درجه عضویت نمونه‌ها به کار می‌رود. در رویکردی دیگر [۳۰] با استفاده از روش‌های خوشه‌یابی مراکز مناسب هر کلاس انتخاب می‌شود. سپس با اصلاح حاشیه‌ی خوشه‌ها، درجه عضویت فازی مناسبی به نمونه‌ها داده می‌شود [۳۱].

در سناریوی داده‌های نامتوازن، معمولاً طبقه‌بندی‌های سنتی بسیاری در طبقه‌بندی شکست می‌خورند، بنابراین لازم است از یک تکنیک تصحیح بایاس پیش یا پس از ساختن طبقه بند بهره برد. یکی از این تکنیک‌ها نمونه‌برداری مجدد از مجموعه داده‌های آموزش اصلی است تا کلاس‌ها تقریباً برابر شوند. نمونه برداری می‌

اگر چه روش‌های استخراج ویژگی مساله‌ی تشخیص را تا حد زیادی تسهیل می‌کند، اما در هنگام مواجهه با ورودی‌های جدیدی که در فرآیند آموزش در نظر گرفته نشده‌اند، افت عملکرد شدیدی دارد؛ برای مثال چهره‌ی تستی که زاویه دید آن روبه‌روی دوربین نیست، در حالی که چهره‌های آموزش از روبه‌رو بوده‌اند. استخراج ویژگی با PCA و FLDA در برابر این تغییرات بزرگ تغییرپذیر است چرا که این روش‌ها اساساً روش‌هایی مبتنی بر ظاهر هستند. در [۱۱] نویسندگان پیشنهاد می‌کنند که همچنان طبقه‌بندی پیچیده‌تر از نزدیک‌ترین همسایگی نیاز است چرا که توزیع الگوی چهره در زیرفضای مبتنی بر FLDA و PCA تفکیک‌ناپذیر است. به عبارت دیگر طبقه‌بندی با قدرت تعمیم‌دهی مناسب و ریسک تجربی کمینه نیاز است تا نقطه‌ضعف روش استخراج ویژگی ظاهر محور را برطرف کند. بر این اساس ماشین بردار پشتیبان<sup>۱</sup> می‌تواند کاندید مناسبی برای طبقه‌بند باشد.

ماشین بردار پشتیبان نخستین بار از سوی وپنیک<sup>۲</sup> ارائه شد [۱۲] و به طور موفقیت‌آمیزی در کاربردهای متعددی به کار گرفته شده است. در یک دهه‌ی گذشته کارهای بسیاری در زمینه‌ی تشخیص چهره با استفاده از SVM صورت گرفته و نتایج مطلوبی نیز به همراه داشته است [۱۳]، [۱۴]. اولین مشکل SVM حساسیت به داده‌های نامناسب است چرا که وزن جریمه برای تمامی داده‌ها یکسان می‌باشد [۱۵]، [۱۶]. دومین مشکل آن، هنگامی که SVM به مساله‌ای با مجموعه دادگان نامتوازن اعمال می‌شود است که چولگی حاشیه‌ی کلاس پیش می‌آید [۱۷]، [۱۸]. به عبارت دیگر هنگامی که تعداد داده‌های کلاس منفی بسیار بیشتر از کلاس مثبت است، مرز کلاس‌ها یا همان ابر صفحه‌ی جداکننده‌ی بهینه که با استفاده از SVM به دست آمده است، دچار چولگی به سمت کلاس مثبت می‌شود.

در اینجا برای حل مشکل داده‌های پرت از نسخه‌ی فازی ماشین بردار پشتیبان و برای حل مشکل چولگی حاشیه‌ی کلاس از فاکتور جریمه‌ی تطبیقی بهره می‌بریم. ماشین بردار فازی نخستین بار در سال ۲۰۰۲ توسط لین و ونگ معرفی شد

$$[U, S, V] = \text{svd}(G) \quad (2)$$

(۳)

$$Z_r = Z_t \times V(:, 1:r)$$

که در آن  $Z_{tr} = [z^{(1)}, z^{(2)}, \dots, z^{(r)}]^T$  شامل ویژگی‌های  $m$  تصویر مختلف است.  $S$  ماتریسی قطری با عناصر نامنفی است که به صورت نزولی مرتب شده‌اند. ماتریس‌های  $U$  و  $V$  ماتریس‌های یکانی هستند که در رابطه-ی  $G = USV^T$  صدق می‌کنند.  $\text{svd}$  تابعی است که تجزیه به مقادیر تکین را انجام می‌دهد. اگر  $S_{ii}$  مقدار تکین ویژگی  $i$  ام باشد، هرچه  $S_{ii}$  بزرگتر باشد، ویژگی  $i$  ام اطلاعات بیشتری دارد. در بسیاری از سیستم‌ها از جمله اطلاعات تصویری، بسیاری از عناصر اطلاعات ناچیزی دارند. معمولاً برای انتخاب مناسب  $r$ ، کوچکترین  $r$  می که در نامعادله‌ی زیر صدق کند را برمی‌گزینند:

(۴)

$$\frac{\sum_{i=1}^r S_{ii}}{\sum_{i=1}^m S_{ii}} \times 100 \geq \varepsilon$$

به این ترتیب  $\varepsilon\%$  از واریانس باقی می‌ماند. پس از نگاشت ویژگی‌ها به فضایی با ابعاد پایین‌تر در (۳)، می‌توان از تکنیک-های یادگیری ماشین برای طبقه‌بندی افراد (شناسایی افراد از پایگاه داده) استفاده نمود.

بدین منظور می‌توان مشاهده کرد که تحلیل مولفه‌های ویژه مولفه‌هایی را انتخاب می‌کند که واریانس را بیشینه می‌کنند. همین ویژگی بسیار مهم است که چگونگی عملکرد خوب روش پیشنهادی را حتی با اطلاعات کمتر (ابعاد پایین‌تر) توجیه می‌کند. در واقع PCA نه تنها تمام اطلاعات را استخراج می‌کند، بلکه جدایی‌پذیری میان کلاس‌های مختلف را بیشینه می‌کند. به همین علت در این مقاله از PCA استفاده شده است.

تواند شامل افزودن نمونه [۳۱]-[۳۳] کاهش نمونه [۳۴]، [۳۵] و یا نمونه‌برداری مرکب [۳۶] باشد. که در این مقاله نمونه‌ها افزایش شده‌اند.

مقالات متعددی به منظور مقایسه‌ی تکنیک‌های یادگیری با نظارت منتشر شده‌اند. از جمله مهم‌ترین تکنیک‌های یادگیری آداپوست می‌باشد که برای نخستین بار در ۱۹۹۷ از سوی فراند و شپیر معرفی شد، اما پس از اصلاحات پیشنهاد شده از سوی وایولا و جونز و ترکیب سری آن با طبقه‌بندها در سال ۲۰۰۴ به محبوبیت رسید. این الگوریتم با ترکیب چند تابع طبقه‌بندی ضعیف و ایجاد یک طبقه‌بند قویتر، عملکرد طبقه‌بندی را بهبود می‌بخشد. به منظور کاهش چشم‌گیر پیچیدگی-های محاسباتی، طبقه‌بندهای پیچیده در ساختاری سری با یکدیگر ترکیب می‌شوند. به این ترتیب تنها برای نمونه‌های جالب‌تر پردازش پیچیده انجام می‌گیرد [۳۷].

## معرفی روش‌های پیشنهادی

### پیش‌پردازش تحلیل مولفه‌های اصلی (PCA)

تحلیل مولفه‌های اصلی در تعریف ریاضی، یک تبدیل خطی متعامد است که داده‌ها را به دستگاه مختصات جدید می‌برد، طوری که بزرگترین واریانس داده بر روی اولین مختصات، دومین واریانس بر روی دومین مختصات و به همین ترتیب برای سایرین قرار گیرد. در اینجا از تحلیل مولفه‌های اصلی برای کاهش ابعاد داده‌ها استفاده می‌کنیم، به این ترتیب که مولفه‌هایی از داده‌ها را که بیشترین تاثیر را در واریانس دارند حفظ کرده و باقی حذف می‌شوند.

داده‌ها در مختصات جدید دو ویژگی اصلی دارند: (۱) ابعاد مختلف داده‌های جدید هیچ هم‌بستگی با یکدیگر ندارند، و (۲) ابعاد بر اساس اهمیت اطلاعاتشان مرتب شده‌اند. معادلات زیر یک ماتریس داده با ابعاد  $m \times n$ ،  $Z_t$  را به ماتریسی با ابعاد  $Z_{tr}, m \times r$  نگاشت می‌کند:

(۱)

$$G = \frac{1}{m} \times Z_t^T \times Z_t$$

### ماشین بردار پشتیبان فازی

ماشین بردار پشتیبان عموماً ابرصفحه یا مجموعه‌ای از ابرصفحه‌ها را برای طبقه‌بندی یا رگرسیون طراحی می‌کند. با فرض آنکه مجموعه‌ی داده‌های برچسب‌دار آموزش به صورت  $S = (x_l, y_l), l = 1, \dots, L$  باشند و  $y_l = \{-1, 1\}$  ماشین بردار پشتیبان با حل مسأله‌ی بهینه‌سازی زیر حل می‌شود:

$$(۵)$$

$$\min_{\omega, \xi, b} \frac{1}{2} \omega^T \omega + C \sum_{i=1}^L \xi_i, \quad (۶)$$

$$\text{Subject to } y_i (\omega^T \phi(x_i) + b) \geq 1 - \xi_i, \quad (۷)$$

$$\xi_i \geq 0, l = 1, \dots, L.$$

که در آن  $\phi(x_l)$  تبدیلی غیرخطی است که  $x_l$  را به فضایی بالاتر نگاشت می‌کند. متغیر  $\xi_l$  برای مجموعه‌های آموزش جدایی‌پذیر غیرخطی است و  $C$  پارامتر مثبت رگولاسیون قابل تنظیم است.

ماشین بردار پشتیبان فازی برای مجموعه‌هایی کاربرد دارد که درجه‌ی اهمیت کلیه‌ی داده‌ها یکسان نیست. به این ترتیب اهمیت و تاثیر داده‌هایی با درجه عضویت بالاتر، بیشتر خواهد بود. از طرفی به دلیل بهره‌گیری از حالت یکی در مقابل همه برای تعمیم روش به حالت چند کلاسه، با مشکل کلاس‌های نامتقارن نیز رو به رو خواهیم بود. از این رو ضرایب تطبیقی نیز برای فائق آمدن بر این مشکل نیز بر معادلات افزوده می‌شود. به این ترتیب معادلات (۵)–(۷) به شکل زیر بازنویسی می‌شود:

$$(۸)$$

$$\min_{\omega, \xi^+, \xi^-, b} \frac{1}{2} \omega^T \omega + C^+ \sum_{i=1}^{L_p} s_i^+ \xi_i^+ + C^- \sum_{i=1}^{L_n} s_i^- \xi_i^-, \quad (۹)$$

$$\text{Subject to } y_i (\omega^T \phi(x_i) + b) \geq 1 - \xi_i^+, \quad \forall x_i \in S_f^+ \quad (۱۰)$$

$$y_i (\omega^T \phi(x_i) + b) \geq 1 - \xi_i^-, \quad \forall x_i \in S_f^-$$

$$(۱۱)$$

$$\xi_i^+ \geq 0, l = 1, \dots, L_p, \forall x_i \in S_f^+.$$

$$(۱۲)$$

$$\xi_i^- \geq 0, l = 1, \dots, L_n, \forall x_i \in S_f^-.$$

که در آن  $L_p$  و  $L_n$  به ترتیب تعداد اعضای کلاس مثبت و منفی،  $C^+$  و  $C^-$  پارامتر رگولاسیون برای کلاس مثبت و منفی و  $\xi_i^\pm$  ضریب فراموشی برای کلاس‌های مثبت و منفی،  $S_f^\pm$  مجموعه‌ی داده‌های متعلق به کلاس‌های مثبت و منفی و  $s_i^\pm$  نیز درجه عضویت فازی عنصر  $i$  ام کلاس مثبت یا منفی است. درجات عضویت فازی در اینجا بر اساس فاصله‌ی داده‌ی مورد نظر تا میانگین کلاس محاسبه می‌شود:

$$(۱۳)$$

$$\text{Subject to } y_i (\omega^T \phi(x_i) + b) \geq 1 - \xi_i^+, \quad \forall x_i \in S_f^+$$

ضرایب تطبیقی نیز با توجه به اندازه‌ی کلاس‌ها تعیین می‌شوند. از آنجا که رویکرد یکی در مقابل همه مورد استفاده قرار گرفته است، از این رو برای طراحی هر ابرصفحه، ضرایب تغییر می‌کنند، چرا که اندازه‌ی کلاس‌ها تغییر می‌کنند. به این ترتیب برای طراحی ابرصفحه‌ی  $i$  ام، اگر ضریب جریمه‌ی کلاس مثبت  $C^+$  باشد، ضریب جریمه‌ی کلاس منفی  $C^- = C^+ (n-i)$  خواهد بود که در آن  $n$  تعداد کل کلاس‌هاست.

### آدابوست

ایده‌ی اصلی آدابوست ترکیب ساده‌ی قواعد برای بدست آوردن طبقه‌بندی جمعی است که از تک‌تک اعضای طبقه‌بندی کلی بهتر عمل کند یا به عبارتی عملکرد آن‌ها را ارتقا بخشد. اگر فرض کنیم  $h_1, h_2, \dots, h_T$  مجموعه‌ای از فرضیه‌ها (طبقه‌بندها) باشند، فرض کلی به صورت زیر خواهد بود:

$$(۱۴)$$

$$f(x) = \sum_{i=1}^T \alpha_i h_i(x).$$

(۱۵)

$$\epsilon_t(h_t, d^t) = \sum_{i=1}^N d_i^{(t)} I(y_i \neq h_t(x_i)).$$

که در آن  $I(\cdot)$  برداری است که در صورت برقراری شرط، آرگومان آن مقدار یک و در غیراین صورت مقدار صفر را اختیار می کند. پس از انتخاب طبقه بند  $h_t$ ، وزن آن  $\alpha_t$  طوری محاسبه می شود تا تابع هزینه ی زیر را کمینه کند:

(۱۶)

$$G(\alpha) = \sum_{i=1}^N \exp\{-y_i(\alpha h_t(x_i) + f_{t-1}(x_i))\},$$

که در آن  $f_{t-1}$  ترکیب طبقه بندهای مراحل قبلی به صورت  $f_{t-1}(x_i) = \sum_{r=1}^{t-1} \alpha_r h_r(x_i)$  است. به این ترتیب ضرایب طبقه بند در هر مرحله به صورت زیر محاسبه می شوند:

(۱۷)

$$\alpha_t = \frac{1}{2} \log \frac{1 - \epsilon_t}{\epsilon_t}$$

در ادامه الگوریتم آدابوست به طور خلاصه توضیح داده می شود:

که در آن  $\alpha_t$  ضرایبی هستند که فرضیه های  $h_t$  را ترکیب می کنند.  $\alpha_t$  و طبقه بندها یا فرضیه های  $h_t$  در روند آدابوست یاد گرفته می شوند. روش های بسیاری برای انتخاب ضرایب  $\alpha_t$  و فرضیه های پایه  $h_t$  وجود دارد. ایده ی اصلی آن است که نمونه هایی که اشتباه طبقه بندی شده اند، در مرحله ی بعدی وزن بیشتری بگیرند. برای مثال نمونه هایی که نزدیک مرزها قرار دارند، معمولاً سخت تر طبقه بندی می شوند و در نتیجه پس از چند مرحله وزن بالاتری دارند. ایده ی وزن دهی مجدد نمونه های آموزش در هر مرحله برای بهبود عملکرد طبقه بندی نهایی ضروری است. به طور کلی، در مرحله ی  $t$  ام وزن های نامنفی  $d^{(t)} = (d_1^{(t)}, d_2^{(t)}, \dots, d_N^{(t)})$  به داده ها نسبت داده می شوند و طبقه بند ضعیف  $h_t$  بر اساس  $d^{(t)}$  ساخته می شود. این وزن ها در هر مرحله  $t$  بر اساس خطای وزن دار طبقه بند مرحله ی قبل به روز می شوند. در هر مرحله  $t$ ، طبقه بند ضعیف تلاش دارد خطای وزن دار تجربی تعریف شده در (۱۵) را کمینه کند:

### جدول ۱

نتایج حاصل از استفاده از ضرایب جریمه تطبیقی

		Train time	Test time	CCR	شماره سطر
$C^+ = C^- = 1$	SVM	۸,۸۷۱	۳,۶۲۳	۰,۸۸۹۵	۱
	FSVM	۸,۶۲۸	۳,۳۱۳	۰,۷۳۸۲	۲
$C^- = 1$ $C^+ = C^- \frac{L_n}{L_p}$	SVM	۸,۰۰۸	۴,۳۱۶	۰,۸۸۹۵	۳
	FSVM	۸,۳۹۸	۳,۶۵۹	۰,۹۰۰۰	۴
$C^- = 10$ $C^+ = C^- \frac{L_n}{L_p}$	SVM	۷,۹۹۱	۳,۲۸۴	۰,۸۲۹۱	۵
	FSVM	۸,۱۷۴	۳,۳۲۹	۰,۸۶۹۷	۶

### الگوریتم آدابوست

۱. ورودی ها:  $\mathcal{S} = \{(x_1, y_1), \dots, (x_N, y_N)\}$

تعداد مراحل  $T$ .

۲. مقداردهی اولیه:  $d_i^{(1)} = 1/N$  برای

$i = 1, \dots, N$

۳. برای  $t = 1, \dots, T$

a. آموزش طبقه بند با نمونه های وزن دار

$\{\mathcal{S}, d^{(t)}\}$  و بدست آوردن فرضیه

$h_t: \mathbf{x} \rightarrow$  (طبقه بند ضعیف)

$\{-1, +1\}$

طبقه‌بند آماده می‌باشند.

در این پژوهش ابتدا طبقه‌بند ماشین بردار پشتیبان با نسخه‌ی فازی آن مقایسه می‌شود. نرخ طبقه‌بندی صحیح<sup>۱</sup> (CCR) مقیاسی است که برای بررسی عملکرد طبقه‌بند مورد استفاده قرار می‌گیرد. به این صورت که جدولی به ابعاد تعداد کلاس‌ها تشکیل می‌شود؛ که در آن سطرها بیانگر کلاس واقعی داده‌هاست و ستون‌ها بیانگر کلاسی است که طبقه‌بند به داده می‌دهد. به این ترتیب هر داده با توجه به کلاس واقعی و نسبت داده شده‌اش در یکی از خانه‌های جدول فوق‌الذکر (ماتریس درهم‌ریختگی<sup>۲</sup>) قرار می‌گیرند. مطلوب آن است که کلاسی که طبقه‌بند تشخیص می‌دهد با کلاس واقعی داده‌ها یکسان باشد. یعنی داده‌ها بر روی قطر اصلی ماتریس قرار گیرند. به این ترتیب می‌توان CCR را به صورت زیر تعریف کرد:

(۱۸)

$$CCR = \frac{\text{tr}(\text{Confusion Matrix})}{N}$$

که در آن  $\text{tr}(\cdot)$  تابع اثر<sup>۳</sup> و  $N$  تعداد کل داده‌هاست. مطلوب آن است که CCR به یک و یا نزدیک به یک باشد. از آنجا که رویکرد یکی در مقابل همه اتخاذ شده، از این رو در طراحی هر طبقه‌بند اندازه‌ی کلاس منفی تغییر می‌کند. از این رو ضریب تطبیقی کلاس مثبت براساس بزرگای کلاس منفی تعیین می‌شود. در اینجا به طور مثال ضریب کلاس منفی را ۱ یا ۱۰ اتخاذ کرده و ضریب کلاس مثبت به صورت ضریبی از اندازه کلاس منفی در ضریب کلاس منفی اتخاذ می‌شود. به این ترتیب مساله کلاس‌های نامتقارن تا حد مطلوبی مرتفع می‌شود و تعمیم‌پذیری طبقه‌بند بهبود می‌یابد. (جدول ۱) تاثیر بهره‌گیری از ضرایب تطبیقی را در بهبود عملکرد ماشین بردار پشتیبان فازی نشان می‌دهد.

مشاهده می‌شود که بدون ضرایب تطبیقی FSVM نتیجه‌ی چندان مطلوبی ندارد و حتی SVM خود عملکرد بهتری دارد، اما به محض بهره‌گیری از این ضرایب نه تنها عملکرد FSVM بهبود می‌یابد بلکه عملکردی به مراتب بهتر

b. محاسبه‌ی خطای وزن دار  $\varepsilon_t$  از رابطه‌ی (۱۵).

c. محاسبه‌ی ضریب طبقه‌بند از رابطه‌ی (۱۷).

d. به‌روزرسانی وزن‌ها با رابطه‌ی

$$d_i^{(t+1)} = d_i^{(t)} \exp(-\alpha_t y_i h_i(\mathbf{x}_i)) / Z_t$$

که در آن  $Z_t$  ثابت نرمالیزه می‌باشد طوری

$$\text{که } \sum_{i=1}^N d_i^{(t+1)} = 1 \text{ شود.}$$

۴. توقف الگوریتم اگر  $\varepsilon_t = 0$  یا  $\varepsilon_t \geq \frac{1}{2}$  باشد و

قرار دادن  $T = t - 1$

۵. خروجی:  $f_T(\mathbf{x}) = \sum_{t=1}^T \frac{\alpha_t}{\sum_{r=1}^T \alpha_r} h_t(\mathbf{x})$

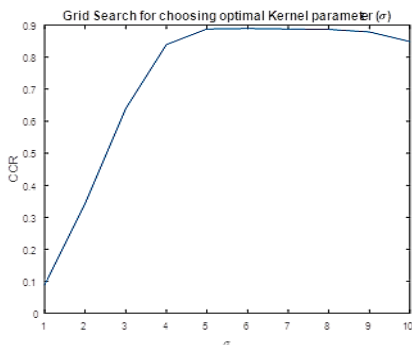
## نتایج عددی

داده‌های مورد استفاده در این پژوهش تصاویر افراد مختلف باحالت‌های متفاوت است که از پایگاه داده‌ی دانشگاه ییل به دست آمده است [۳۸]. اما آنچه که در اینجا چالش اساسی محسوب می‌شود آماده‌سازی و استخراج ویژگی از تصاویر است. در ابتدا باید تصویر چهره‌ی افراد از تصویر کلی جدا شود که البته در تصاویر مورد استفاده این جداسازی از پیش صورت گرفته بود. سپس کلیه‌ی تصاویر هم‌اندازه (از لحاظ تعداد پیکسل) می‌شوند. آنگاه شدت نور هر پیکسل از تصویر (که به صورت سیاه و سفید می‌باشند) به عنوان ویژگی در نظر گرفته می‌شود. به این ترتیب به ازای هر تصویر یک بردار ویژگی شامل شدت نور در کلیه‌ی پیکسل‌های تصویر بدست می‌آید. این بردار مبنای طبقه‌بندی قرار خواهد گرفت. مشکل اصلی ابعاد بالای بردار ویژگی (به اندازه‌ی تعداد پیکسل‌های تصویر) است که با بهره‌گیری از تحلیل مولفه‌های اصلی، این مشکل مرتفع می‌شود. در این پژوهش با بازیابی ۹۵٪ از داده‌های اولیه، ابعاد از ۳۲۲۵۶ به ۵۹ ویژگی کاهش می‌یابد که نشانگر آن است که بخش زیادی از ویژگی‌های اولیه تاثیر چندانی در شکل‌دهی با داده‌ها نداشته‌اند. حال داده‌های ورودی به

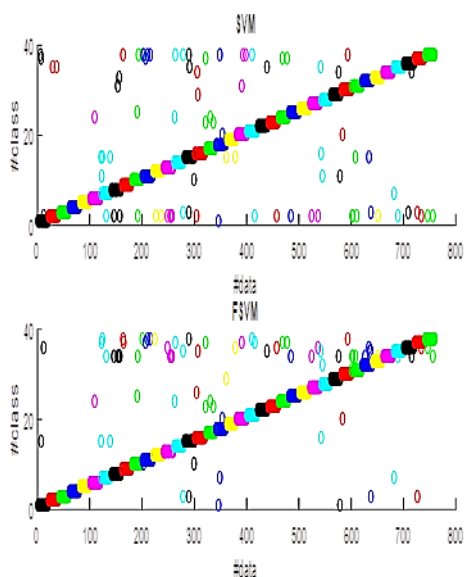
1. Correct Classification Rate (CCR)

2. Confusion Matrix

3. Trace



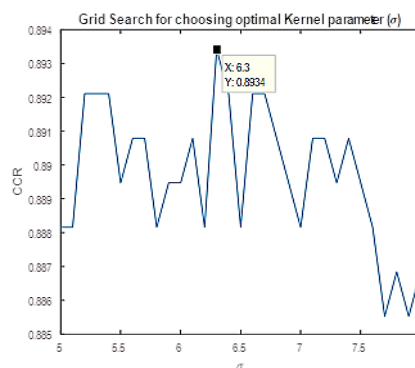
شکل ۱- نمودار تغییرات CCR با تغییر مقدار پارامتر تابع هسته با بزرگنمایی کمتر (راست) و بیشتر (چپ)



شکل ۲- مقایسه‌ی چگونگی طبقه‌بندی داده‌های آزمایش به روش‌های SVM و FSVM (راست) و FSVM و آدابوست (چپ)

از SVM از خود نشان می‌دهد. دیده می‌شود که مدت زمان اجرای برنامه برای داده‌های آموزش و تست در هر دو روش مشابه است. از این رو هیچ‌یک بر دیگری برتری از لحاظ سرعت محاسبات ندارند. لازم به ذکر است که در تمامی مسائل فوق از تابع هسته<sup>۱</sup>ی RBF<sup>۲</sup> با پارامتر 6.3 استفاده شده است. این پارامتر با استفاده از روش جست‌وجوی شبکه‌ای<sup>۳</sup> به دست آمده است و بهینه‌ترین جواب ممکن را در اختیار ما قرار می‌دهد. شکل (۱) تغییر میزان CCR با تغییر میزان پارامتر تابع هسته را نشان می‌دهند. در این رابطه شکل (۲) چگونگی طبقه‌بندی داده‌های آزمایش را به شکلی ملموس‌تر نمایش می‌دهد. در این شکل محور افقی شماره‌ی داده‌ها و محور عمودی کلاس واقعی داده‌هاست. هر ۲۰ داده‌ی آزمایش به ترتیب متعلق به یک کلاس است و هر رنگ نشانگر کلاس نسبت داده شده به هر داده می‌باشد.

البته لازم به ذکر است که به دلیل محدودیت در رنگ‌ها، در هر هفت کلاس مجدداً رنگ‌ها تکرار می‌شوند. مشاهده می‌شود طبقه‌بندی تا حد زیادی به درستی صورت گرفته و در هر کلاس تعداد انگشت‌شماری از داده‌ها به اشتباه طبقه‌بندی شده‌اند. با این‌حال برای بهبود عملکرد طبقه‌بند از روش آدابوست بهره می‌بریم. در ادامه نتایج حاصل از بهبود عملکرد طبقه‌بند در الگوریتم آدابوست مورد بررسی قرار می‌گیرد.



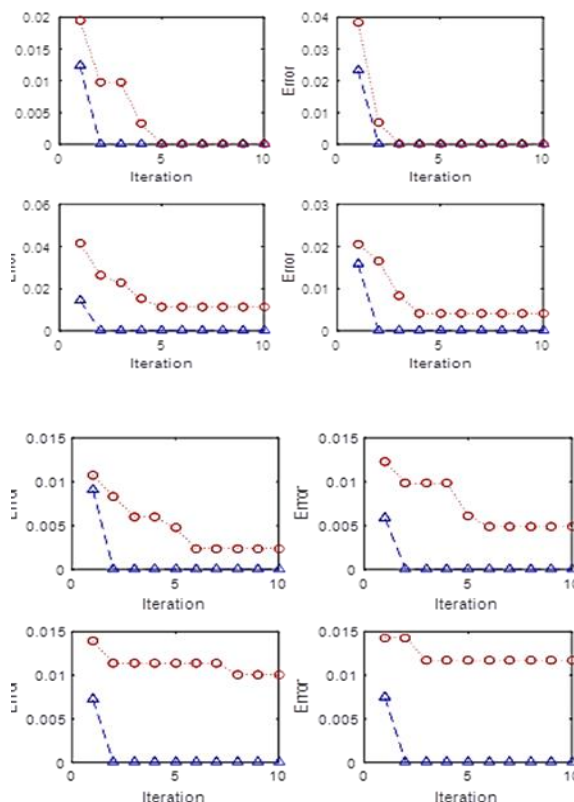
1. Kernel Function
2. Radial Basis Function
3. Grid Search



نمایش می‌دهد. مشاهده می‌شود که مقدار خطا به نحو بسیار مطلوبی در الگوریتم آدابوست کاهش یافته است. این برتری روش پیشنهادی را نشان می‌دهد. در واقع آدابوست در هر مرحله سعی در کاهش میزان خطای داده‌های تست دارد. این امر در شکل‌های (۳) نشان داده شده است. این شکل‌ها نمونه‌ای از کاهش میزان خطا برای طبقه‌بندی طراحی شده برای هر کلاس است، اما از آنجا که تعداد کلاس‌ها بسیار زیاد (۳۸ کلاس) است، در اینجا به نمایش چند نمونه اکتفا می‌گردد. مشاهده می‌شود که خطای حاصل از داده‌های آموزش در طول مراحل تکرار کاهش می‌یابد که با افزایش تعداد مراحل الگوریتم این کاهش بیشتر نیز می‌شود. جدول (۴-۲) نیز برتری روش پیشنهادی را بر FSVM نشان می‌دهد. البته این برتری به بهای افزایش زمان آموزش و آزمایش است اما این افزایش زمان برای داده‌های آزمایش چندان چشمگیر نیست. به این ترتیب اگر چه زمان آموزش بیشتری صرف می‌شود، ولی افزایش زمان آزمایش چندان نیست که ما را از این روش منصرف کند. به علاوه بهبود چشمگیر عملکرد در روش پیشنهادی محرک خوبی برای استفاده از این روش می‌باشد.

### نتیجه‌گیری

در این پژوهش نشان داده شده که روش پیشنهادی با بهره‌گیری از ماشین بردار پشتیبان فازی، ضرایب تطبیقی و الگوریتم آدابوست به طور چشم‌گیری دقت تشخیص چهره افراد را بالا می‌برد. در این روش اگر چه سرعت در آموزش طبقه‌بند فدای سرعت شده، اما زمان آزمایش و دقت در اندازه‌گیری محرک‌های خوبی برای تشویق افراد در استفاده از این روش است. ضمن آنکه در این روش نیازی به عکس‌های با کیفیت یا رنگی نیست و با هر عکس تمام‌رخ می‌توان شناسایی را انجام داد. همچنین روش پیشنهادی در برابر تغییر چهره‌ی افراد نیز مقاوم است، چرا که داده‌های مورد استفاده از تمامی حالات چهره‌ی افراد (مثل خشم، اندوه، شادی) گرفته شده است.



شکل ۳- نمودار کاهش خطای داده‌های آموزش (آبی) و آزمایش (قرمز) در مراحل تکرار الگوریتم آدابوست برای طبقه‌بند ۱ تا ۴ (راست) و طبقه‌بند ۲۵ تا ۲۸ (چپ)

جدول ۲

نتایج حاصل از روش پیشنهادی و FSVM

شماره سطر	Train time	Test time	CCR	شماره سطر
۱	۱۲,۶۲۷	۵,۷۰۵	۰,۹۷۲۴	روش پیشنهادی
۲	۸,۳۹۸	۳,۶۵۹	۰,۹۰۰۰	FSVM

در ادامه طبقه‌بند FSVM طراحی شده در مرحله‌ی قبل، وارد الگوریتم آدابوست با ۱۰ مرحله تکرار می‌شود. در واقع آدابوست طبقه‌بند طراحی شده را با ضرایب مختلف و برای داده‌های متفاوت در نظر گرفته و در نهایت طبقه‌بندی حاصل از مجموع طبقه‌بندی‌های پیشین با ضرایب مشخص عرضه می‌کند که خطا را به نحو چشمگیری کاهش می‌دهد. شکل (۲) توصیفی گرافیکی از نتایج حاصل از آدابوست و FSVM را

## مراجع

- Neural Network, *IEEE Transaction on*, vol. 14, no. 1, pp. 117-126, 2003.
- [12] C. Cortes and V. Vapnik, "Support Vector Networks," *Machine Learning*, vol. 20, no. 3, pp. 273-297, 1995.
- [13] Y. Wen, "An improved discriminative common vectors and support vector machine based face recognition approach," *Expert Systems with Applications*, vol. 39, no. 4, pp. 4628-4632, 2011.
- [14] L. H. Thai, T. S. Hai and N. T. Thuy, "Image Classification using Support Vector Machine and Artificial Neural Network," *International Journal of Information Technology and Computer Science*, vol. 4, no. 5, pp. 32-38, 2012.
- [15] I. Guyon, N. Matic and V. Vapnik, "Discovering informative patterns and data cleaning," *Advanced in knowledge discovery and data mining*, pp. 181-203, 1996.
- [16] C. F. Lin and S. D. Wang, "Fuzzy Support Vector Machines," *Neural Network, IEEE Transaction on*, vol. 13, no. 2, pp. 464-471, 2002.
- [17] Y. Zhang, P. Fu, W. Liu and L. Zou, "SVM classification for imbalanced data using conformal kernel transformation," in *Neural Networks (IJCNN), 2014 International Joint Conference on*, Beijing, 2014.
- [18] S. Maldonado, R. Weber and F. Famili, "Feature selection for high-dimensional class-imbalanced data sets using Support Vector Machines," *Information Sciences*, vol. 286, pp. 228-246, 2014.
- [19] Y. Wang, S. Wang and K. Lai, "A new fuzzy vector machine to evaluate credit risk," *Fuzzy systems, IEEE Transactions on*, vol. 13, no. 6, pp. 820-831, 2005.
- [20] Y. Hao, Z. Chi and D. Yan, "Fuzzy support vector machine based on vague sets for credit assessment," in *Proceeding of the Forth International Conference on fuzzy Systems and Knowledge Discovery*, Changsha, China, 2007.
- [21] S. Abe and T. Inoue, "Fuzzy support vector machines for multiclass problems," in *Proceedings of the Tenth European*
- [1] E. G. P. V. R. R. S. D. O. G. Miguel De-la-Torre, "Partially-supervised learning from facial trajectories for face recognition in video surveillance," *Information Fusion*, vol. 24, p. 31-53, 2015.
- [2] R. C. S. L. L. Z. Stan Z. Li, "Illumination Invariant Face Recognition Using Near-Infrared Images," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 29, no. 4, pp. 627 - 639, 2007.
- [3] T. V. V. Blanz, "Face recognition based on fitting a 3D morphable model," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 25, no. 9, pp. 1063 - 1074, 2003.
- [4] R. O. Duda, P. E. Hart and D. G. Stork, *Pattern Classification*, John Wiley & Sons, 2012.
- [5] A. P. B. Moghaddam, "Probabilistic visual learning for object representation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 19, no. 7, pp. 696 - 710, 2002.
- [6] P. N. J Ruiz-del-Solar, "Toward a generalized eigenspace-based face Recognition System," *Lecture Note in Computer Science*, 2002.
- [7] V. V. Corinna Cortes, "Support Vector Networks," *Machine Learning*, vol. 20, no. 3, pp. 273-297, 1995.
- [8] A. S. K.-R. M. Bernhard Schölkopf, "Nonlinear component analysis as a kernel eigenvalue problem," *Neural Computation*, vol. 10, no. 5, pp. 1299-1319, 1998.
- [9] K. J. H. J. K. Kwang In Kim, "Face recognition using kernel principal component analysis," *IEEE Signal Processing Letters*, vol. 9, no. 2, pp. 40-42, 2002.
- [10] H. L. S. M. Qingshan Liu, "Improving kernel fisher discriminant analysis for face Recognition," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 14, no. 1, pp. 1051-8215, 2004.
- [11] J. Lu, N. Plataniotis and A. N. Venetsanopoulos, "Face recognition using kernel discriminant analysis algorithm,"

- Unconstrained Background Clutter Using Color Based Segmentation," *Advances in Intelligent Systems and Computing*, vol. 425, pp. 51-62, 2016.
- [32] H. Zhang and M. Li, "RWO-Sampling: A random walk over-sampling approach to imbalanced data classification," *Information Fusion*, vol. 20, p. 99-116, 2014.
- [33] N. Chawla, K. Bowyer and L. Hall, "SMOTE: synthetic minority over-sampling technique," *Journal of Artificial Intelligence*, vol. 16, pp. 321-357, 2002.
- [34] R. Akbani, S. Kwek and N. Japkowicz, "Applying support vector machine to imbalanced datasets," in *Proceedings of the 15th European Conference on Machine Learning*, Pisa, Italy, 2004.
- [35] S. Yen and Y. Lee, "Cluster-based under-sampling approaches for imbalanced data distributions," *Expert Systems with Applications*, vol. 36, no. 3, pp. 5718-5727, 2009.
- [36] H. Yu, J. Ni and J. Zhao, "ACOSampling: an ant colony optimization-based undersampling method for classifying imbalanced DNA microarray data," *Neurocomputing*, vol. 101, pp. 309-318, 2013.
- [37] S. R. a. L. N. S. Aruna, "An empirical comparison of supervised learning algorithms in disease detection," *International Journal of Information Technology Convergence and Services*, vol. 1, no. 4, pp. 81-92, 2011.
- [38] P. B. D. K. Athinodoros Georghiades, "From Few to Many: Illumination Cone Models for Face Recognition under Variable Lighting and Pose," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 23, no. 6, pp. 643 - 660, May 2001.
- Symposium on Artificial Neural Networks, Burges, Belgium, 2002.
- [22] T. Wang and H. Chiang, "fuzzy support vector machine for multi-class text categorization," *Information Processing & Management*, vol. 43, no. 4, pp. 914-929, 2007.
- [23] Z. Sun and Y. Sun, "Fuzzy support vector machine for regression estimation," in *IEEE International Conference on Systems, Man and Cybernetics*, 2003.
- [24] X. Jiang, Y. Zhang and J. Lv, "Fuzzy SVM with a new fuzzy membership function," *Neural Computation & Application*, vol. 15, no. 4, pp. 268-276, 2006.
- [25] X. Zhang, X. Xiao and G. Xu, "Fuzzy support vector machine based on affinity among samples," *Journal of Software*, vol. 17, no. 5, pp. 951-958, 2006.
- [26] H. Tang and L.-s. Qu, "Fuzzy support vector machines with a new fuzzy membership function for pattern classification," in *Machine Learning and Cybernetics*, 2008 International Conference on, Kunming, 2008.
- [27] Z. Xie, Q. Hu and D. Yu, "Fuzzy output support vector machine for classification," in *Proceedings of the International Conference on Advances in Neural Computation*, Changsha, China, 2005.
- [28] T. Inoue and S. Abe, "Fuzzy support vector machine for pattern classification," in *Proceedings of the International Conference on Neural Networks*, Washington, DC, 2001.
- [29] W. An and M. Liang, "Fuzzy support vector machine based on within-class scatter for classification problems with outliers or noise," *Neurocomputing*, vol. 110, pp. 101-110, 2013.
- [30] Z. Wu, H. Zhang and J. Liu, "A fuzzy support vector machine algorithm for classification based on a novel PIM fuzzy clustering method," *Neurocomputing*, vol. 125, pp. 119-124, 2014.
- [31] A. Chatterjee, D. Mishra and S. S. Gorthi, "Enhancing Face Recognition Under



