

مقایسه بین روش های کاهش بعد آنالیز مولفه های اصلی (PCA) و آنالیز مولفه های اصلی مبتنی بر هسته (KPCA) با روش تقسیم داده (M-SVM) به کمک روش دسته بندی ماشین بردار پشتیبان (KCV)

در تشخیص چهره

آتنا عباس زاده، سعید طوسی زاده، حسین اثباتی

کارشناس ارشد مهندسی برق کنترل، دانشگاه آزاد اسلامی، واحد مشهد، atena.abbaszadeh@gmail.com

استادیار دانشگاه آزاد اسلامی، واحد مشهد، saeedtoosizadeh@yahoo.com

کارشناس ارشد مهندسی برق کنترل، شرکت صنایع سیمان زابل، Hosseinesbati1@gmail.com

مسئول مکاتبات: آتنا عباس زاده

چکیده - در این مقاله به منظور دسته بندی تصاویر چهره بانک اطلاعاتی ORL، از روش هایی کاهش بعد آنالیز مولفه های اصلی (PCA) و آنالیز مولفه های اصلی مبتنی بر هسته (KPCA) با روش دسته بندی شبکه عصبی mun (ELMAN) استفاده شده است. ماشین بردار پشتیبان کارایی بالایی برای تعیین پردازش نمونه های کوچک به اطلاعات در ابعادی بزرگ را فراهم می کند. به منظور بررسی اثر استفاده از تعداد مولفه های PCA و KPCA در میزان دقت دسته بندی سیستم و زمان دسته بندی چهره های بانک اطلاعاتی بکار رفته، مراحل دسته بندی با تعداد مولفه های مختلف انجام شد و با هم مقایسه گردید که در حالت بهینه دقت تشخیص ۹۷.۴۱۶۷٪ بدست آمد.

کلید واژه- آنالیز مولفه های اصلی، آنالیز مولفه های اصلی مبتنی بر هسته ، ماشین بردار پشتیبان چند کاناله، تشخیص چهره. نرم افزار سازی داده

#### ۱- مقدمه

در حال حاضر با پیشرفت سریع ارتباطات، محدوده فعالیتهای مردم نیز در حال رشد است و اهمیت تشخیص هویت به صورت صعودی افزایش می‌یابد. تشخیص چهره تحقیقات بسیار مهمی را در زمینه‌های مختلف تصاویر سه بعدی، بازتاب هوش انسان بر ماشین، سیستمهای ویدئو کنفرانس و سیستمهای مانیتورینگ را در بر می‌گیرد. بنابراین تشخیص چهره به یکی از داغترین موضوعات در زمینه تشخیص الگو و هوش مصنوعی تبدیل شده است. تکنیکهای مختلف بررسی شناسائی چهره در [۱] و [۲]<sup>۱</sup> معرفی شده اند که از جدیدترین آنها می‌توان به روش SVM<sup>۲</sup> اشاره نمود که در سالهای اخیر به شکل وسیعی در کاربردهای مختلف بازناسایی الگو مورد استفاده قرار گرفته است. کلیات روش SVM در بخش ۳ آمده است. این روش در مراجع [۳],[۴],[۵],[۶]<sup>۳</sup> برای بررسی شناسائی چهره بکار برده شده است. در این مقاله از روش PCA<sup>۴</sup> و KPCA<sup>۵</sup> برای کاهش بعد و از روش KCV<sup>۶</sup> برای تقسیم داده‌ها به دسته‌های آموزش و آزمون از SVM<sup>۷</sup> برای دسته بندی استفاده شده است و به عنوان یک کار پژوهشی جدید اثر تعداد مولفه‌های PCA و KPCA در دقت تشخیص و زمان تشخیص بررسی شده است. این مقاله بدین صورت سازمان یافته است: بخش ۲ معرفی روش‌های کاهش بعد مورد استفاده در مقاله، بخش ۳ بیان روش KCV، بخش ۴ معرفی روش دسته بندی ماشین بردار پشتیبان، بخش ۵ آزمایشات تجربی نشان داده شده و مورد بحث قرار می‌گیرد و بخش ۶ به نتیجه‌گیری اختصاص یافته است.

#### ۲- اساس نظریه PCA

ایده اصلی PCA کاهش ابعاد داده‌های موجود در یک مجموعه داده می‌باشد بگونه‌ای که تغییرات موجود در این داده‌ها تا حد امکان حفظ گردد. در حقیقت بردارهای ویژه یا همان بردارهای عمود بر هم به صورتی است که اولین مولفه PCA بیشترین اطلاعات را در خود دارد و این روند تا آخرین مولفه دنبال می‌شود و مولفه آخرین کمترین اطلاعات را در خود جای داده است. در این روش محورهای مختصات جدیدی برای داده‌ها تعریف شده و داده‌ها بر اساس این محورهای مختصات جدید بیان می‌شوند.

#### ۱-۲- الگوریتم PCA در تشخیص چهره

ابتدا تصاویر را به بردارهای یک بعدی تبدیل می‌کنیم و سپس مراحل زیر را انجام می‌دهیم:

فرض کنیم  $M$  بردار  $N \times 1$  داریم که در اصل همان  $M$  تصویر پایگاه داده ما هستند:

$$x_1, x_2, \dots, x_M \quad (1-1-2)$$

مرحله ۱: میانگین هر یک از این  $M$  بردار را محاسبه می‌کنیم

$$\bar{x} = \frac{1}{M} \sum_{i=1}^M x_i \quad (2-1-2)$$

مرحله ۲: هر یک از بردارها را از مقدار میانگین آنها کم می‌کنیم

$$\varphi_i = x_i - \bar{x} \quad (3-1-2)$$

مرحله ۳: محاسبه ماتریس کوواریانس  $C$  که مشخص کننده پراکندگی داده‌ها است

<sup>1</sup> Support vector machine

<sup>2</sup> Principal Component Analysis

<sup>3</sup> Kernel Principal Component Analysis

<sup>4</sup> K-Fold Cross-Validation

# اولین همایش ملی پیشرفت های تکنولوژی در مهندسی برق، الکترونیک و کامپیوتر

First National Conference of Technology Developments on Electronical, Electronics and Computer Engineering

. . . W W W . T D E C O N F . I R . . .

$$c = \frac{1}{M} \sum_{n=1}^M \varphi_n \varphi_n^T = AA^T \quad (4-1-2)$$

$$A = [\varphi_1 \varphi_2 \dots \varphi_M] \quad (5-1-2)$$

مرحله ۴: محاسبه مقادیر ویژه ماتریس کوواریانس

$$\lambda_1 > \lambda_2 > \dots > \lambda_N \quad (6-1-2)$$

مرحله ۵: محاسبه بردار ویژه ماتریس کوواریانس

$$X - \bar{X} = b_1 u_1 + b_2 u_2 + \dots + b_N U_N = \sum_{i=1}^N b_i u_i \quad (7-1-2)$$

مرحله ۶: (مرحله کاهش بعد) فقط  $k$  تا بردار ویژه ای را که دارای مقادیر ویژه بالاتری هستند نگه میداریم

$$X - \bar{X} = \sum_{i=1}^k b_i u_i \text{ where } k \ll n \quad (8-1-2)$$

## ۲-۲- الگوریتم KPCA در تشخیص چهره

تکنیک اصلی KPCA در فضای نگاشت یافته توسط یک تابع نگاشت غیر خطی است که از ایده هسته برای تخمین این نگاشت استفاده می شود. داده های نگاشت یافته  $\emptyset(X_k), \emptyset(X_1), \dots, \emptyset(X_N)$  را در نظر بگیرید که میانگین آنها صفر نباشد. ابتدا با رابطه زیر میانگین داده های نگاشت یافته صفر می شود:

$$\emptyset(X_k) = \emptyset(X_k) - \frac{1}{N} \sum_{j=1}^N \emptyset(X_j) \quad (1-2-2)$$

ماتریس کوواریانس از رابطه زیر محاسبه می شود

$$\hat{\Sigma} = \frac{1}{N} \sum_{j=1}^N \emptyset(X_j) \emptyset(X_j)^T \quad (2-2-2)$$

معادله مقادیر ویژه برای ماتریس کوواریانس فوق بفرم  $\hat{\Sigma} \hat{V} = \hat{\Sigma} \hat{V}$  می باشد. که  $\hat{\lambda}_1 \geq \dots \geq \hat{\lambda}_N$  مقادیر ویژه و  $\hat{V} \in F \setminus \{0\}$  به معنی  $F$  به استثنای  $\{0\}$  بردارهای ویژه می باشند. معادل معادله مقادیر ویژه را می توان به صورت رابطه زیر نوشت:

$$\hat{\lambda}_k (\emptyset(X_k) \cdot \hat{V}) = (\emptyset(X_k) \cdot \hat{\Sigma} \hat{V}), k = 1, \dots, N \quad (3-2-2)$$

که  $\hat{\lambda}_k$  ها ضرایبی هستند که مقادیر آنها به گونه ای انتخاب می شوند که رابطه (۳-۲-۲) برقرار باشد

$$\hat{V} = \sum_{k=1}^N \hat{\lambda}_k \emptyset(X_k) \quad (4-2-2)$$

که با جایگذاری رابطه (۳-۲-۲) در رابطه (۴-۲-۲) خواهیم داشت:

$$\hat{\lambda} \alpha = K \alpha, \quad (\alpha = (\alpha_1, \dots, \alpha_N)^T) \quad (5-2-2)$$

که  $K$  ماتریس هسته بوده و به فرم ماتریس مربعی  $N \times N$  با عناصر  $K_{i,j} = (\varphi(X_i), \varphi(X_j)) = k(X_i, X_j)$  می‌باشد. برای نرمال‌سازی راه حل‌های  $(\lambda_k, \alpha^k)$ ، بایستی رابطه  $\lambda_k(\alpha^k \cdot \alpha^k) = 1$  در فضای نگاشت یافته اعمال شود. همانند هر الگوریتم PCA دیگری، دادگان در فضای نگاشت یافته باید متمرکز<sup>۵</sup> شوند. برای این کار ماتریس هسته با رابطه زیر جایگزین می‌شود،

$$\hat{K} = K - \mathbf{1}_N K - K \mathbf{1}_N + \mathbf{1}_N K \mathbf{1}_N \quad (6-2-2)$$

که  $(\mathbf{1}_N)_{i,j} = 1/N$  می‌باشد. [۸]

### -۳- روش تقسیم داده $KCV$

در این روش مجموعه کل داده‌ها به طور تصادفی به  $K$  گروه تقسیم می‌شوند، که با هم همپوشانی ندارند. سپس برای هر ترکیب دلخواه از این  $K$  گروه ترکیب‌های آموزش و آزمون ساخته می‌شود. سپس طی  $K$  مرحله هر بار یکی از دسته‌ها به عنوان آزمون و  $K-1$  دسته دیگر به عنوان آموزش استفاده می‌شود و میزان اعتبار روش روی دسته آزمون سنجیده می‌شود. در نهایت  $K$  مقدار برای میزان صحت روش بدست می‌آید که می‌توان میانگین آن را به عنوان میزان صحت روش در نظر گرفت. هر چه پراش مقادیر بدست آمده از  $K$  مرحله کمتر باشد، اعتبار نتیجه بیشتر است. در بیشتر مقالات در مورد تقسیم به گروه‌های آزمون و آزمایش بیشتر از  $K=5$  و  $K=10$  استفاده می‌کنند.

### -۴- ماشین بردار پشتیبان ( $SVM$ )

یکی از روش‌های طبقه‌بندی با معلم<sup>۶</sup> روش ماشین بردار پشتیبان می‌باشد [۹]. ایده اولیه این روش برای اولین بار در سال ۱۹۷۹ توسط محقق روسی به نام ولادیمیر و اپنیک<sup>۷</sup> مطرح شد و بعدها در سال ۱۹۹۵ توسط همین شخص به عنوان یک طبقه‌بندی کننده از آن استفاده شد [۱۰]. اساس این دیدگاه بر مبنای تئوری یادگیری آماری ( $SLT$ )<sup>۸</sup> بوده، ولی روش پیاده‌سازی آن شبیه شبکه عصبی می‌باشد [۱۱]. این روش برای جدا کردن داده‌ها در دو دسته طراحی شده بود. البته در صورت استفاده از چند  $SVM$  به صورت موازی و با روش‌های متفاوت می‌توان از این روش برای طبقه‌بندی داده‌ها به بیش از دو دسته نیز استفاده نمود. از ماشین‌های بردار پشتیبان می‌توان برای جداسازی داده‌های تفکیک پذیر خطی و غیرخطی استفاده نمود.  $SVM$  ادعا کرده است: مشکل عدمه شبکه‌های عصبی، یعنی Over fitting را حل می‌کند. ایده اصلی در  $SVM$  کاوش ریسک<sup>۹</sup> می‌باشد. فرض کنید که نمونه‌های آموزشی به صورت یک بردار  $\{y_i, x_i\}$  نمایش داده شوند و دو دسته  $\{+1, -1\}$  وجود دارد. در  $SVM$  خطی، مرز بین دسته‌ها با خط ایجاد می‌شود. یک مرز تصمیم‌گیری خطی را می‌توان در حالت کلی به صورت (۴-۱) نوشت:

$$H: x_i \cdot w + b = 0 \quad (4-1)$$

$X$  یک نقطه روی مرز تصمیم‌گیری و  $w$  یک بردار  $n$  بعدی عمودبر مرز تصمیم‌گیری است.  $b / \|w\|$  فاصله مبدأ تا مرز تصمیم‌گیری و  $w \cdot X$  بیانگر ضرب داخلی دو بردار  $X$  و  $w$  است.

آنگاه باید همه داده‌ها در شرایط (۲-۴) صدق کنند:

$$(x_i \cdot w + b) \geq +1 \text{ for } y_i = +1 \text{ (class 1)}$$

$$(x_i \cdot w + b) \leq -1 \text{ for } y_i = -1 \text{ (class 2)}$$

<sup>5</sup> To be centered

<sup>5</sup> Supervised

<sup>7</sup> Vladimir Vapnik

<sup>8</sup> Statistical Learning Theory

<sup>9</sup> Structural Risk Minimization

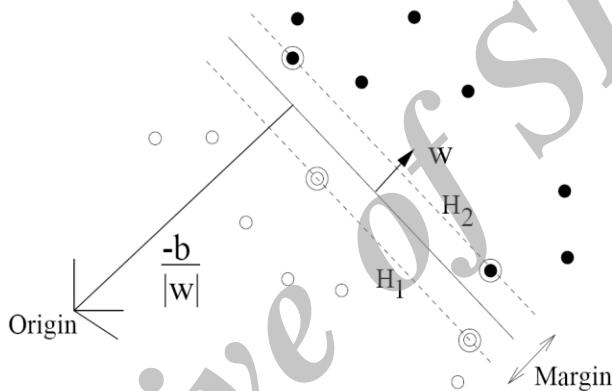
یا به عبارت کلی‌تر:

$$y_i(x_i \cdot w + b) \geq 1 \quad \forall i$$

اگر  $x_i$  یک بردار پشتیبان باشد  $\rightarrow y_i(x_i \cdot w + b) = 1$

اگر  $x_i$  یک بردار پشتیبان نباشد  $\rightarrow y_i(x_i \cdot w + b) > 1$

اولین مرحله برای محاسبه مرز تصمیم‌گیری بهینه، پیدا کردن نزدیک‌ترین نمونه‌های آموزشی دو دسته است. در مرحله بعد فاصله آن نقاط از هم در راستای عمود بر مرزهایی که دو دسته را به طور کامل جدا می‌کنند، محاسبه می‌شود. در شکل ۱ حالت تفکیک‌پذیر دسته‌ها نشان داده شده است. دو بردار پشتیبانی در شکل دایره کشیده شده است.  $H_1$  و  $H_2$  به ترتیب مربوط به دسته ۱ و دسته ۲ می‌باشند. فاصله بین اینها حاشیه<sup>۱۰</sup> می‌باشد و مرز تصمیم‌گیری بهینه باید حداقل حاشیه را داشته باشد. فاصله بین دو فوق صفحه موازی  $\|w\|^2 / 2$  است که هدف برآورده کردن  $\min_{w,b} \frac{1}{2} \|w\|^2$  است [۱۱].



شکل ۱: جداسازی خطی بین دسته‌ها، دور بردار پشتیبانی دایره کشیده شده است

مسئله فوق یک مسئله بهینه‌سازی مقید از نوع محدب و درجه دوم است. برای حل این مسئله تابع لاغرانژ<sup>۱۱</sup> ( $L$ ) را تشکیل داده و ضرایب لاغرانژ  $\alpha_i$  را بدست می‌آوریم.

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^l \alpha_i (y_i(w \cdot x_i + b) - 1) \quad (4-3)$$

برای اینکه  $(w, b, \alpha)$  جواب مسئله باشد باید در شرایط KKT<sup>۱۲</sup> صدق کند و در نقطه جواب مشتق  $L$  نسبت به  $w$  و  $b$  و  $\alpha$  برابر صفر باشد. به این ترتیب معادلات (۴-۴) حاصل می‌شود.

(۴-۴)

$$w = \sum_{i=1}^l \alpha_i y_i x_i$$

$$\sum_{i=1}^l \alpha_i y_i = 0$$

<sup>10</sup> Margin

<sup>11</sup> Karush-Kuhn-Tucker

با قرار دادن مقدار  $W$  از رابطه (۴-۵) در  $L(w, b, \alpha)$  به مسئله دوگان برای بهینه سازی مقید خواهیم رسید.

(۴-۴)

$$\max_{\alpha} - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j x_i x_j + \sum_{i=1}^l \alpha_i$$

$$\text{Subject to } \alpha_i \geq 0, \sum_{i=1}^l \alpha_i y_i = 0 \\ \text{پس از حل این مسئله ضرایب لاغرانژ } \alpha_i \text{ بدست می آید.}$$

#### ۵- نتایج تجربی و تحلیل آنها

در این بخش به بررسی بانک اطلاعاتی و الگوریتم استفاده شده می پردازیم

#### ۱-۵- بانک چهره

تصاویر آزمایشی از بانک اطلاعاتی ORL<sup>12</sup> هستند این داده ها شامل ۴۰۰ تصویر شخصی از ۴۰ نفر است. برای هر فرد ۱۰ تصویر متفاوت در زمانهای مختلف و با تغییرات روشنایی، ژستهای مختلف (چشمها بار و بسته، لبخند و بدون لبخند) و وضعیتهای دیگر مانند با عینک و بدون عینک تهیه شده اند.



شکل ۲: گوشه ای از تصاویر انتخاب شده برای آموزش در بانک ORL



شکل ۳: گوشه ای از تصاویر انتخاب شده برای آزمون در بانک ORL

از ۱۰ تصویر هر فرد، ۷ تصویر در مرحله آموزش و ۳ تصویر دیگر در مرحله آزمایش استفاده شده اند. تصاویر آموزشی به صورت هوشمند طوری انتخاب شده اند که حداقل اطلاعات غیر وابسته به یکدیگر را دارا باشند.

#### ۲-۵- اجرای الگوریتم

<sup>12</sup> Olivetti Research Ltd

تحقيق انجام شده شامل مراحل زیر است:

۱- خواندن مجموعه تصاویر و ایجاد ماتریس هدف:  $400 \times 400 \times 1$  و  $112 \times 92 \times 1$

۲- اجرای PCA : انتخاب تعداد داده جهت کاهش با استفاده از PCA

۳- تبدیل تصاویر به ابعاد  $400 \times 90 \times 70$  و سپس تبدیل به بردار  $400 \times 6300$

۴- محاسبه میانگین بردارهای ویژگی و کاهش هر بردار ویژگی از بردار میانگین

۵- یافتن مقادیر ویژه و مرتب سازی آنها در نهایت کاهش بعد مطابق با مقدار از قبل تعیین شده در مرحله ۱ و ۲

۶- انتخاب داده آموزش و آزمون به همراه بردار هدف هر یک:

۷۰٪ کل داده برای داده آموزش و آزمون بصورت تصادفی و مستقل از هر کلاس انتخاب شد.

۷- اجرای ماشین بردار پشتیبان چندکاله (MSVM)<sup>۱۳</sup> . با توجه به آن که تعداد کلاس های داده ۴۰ عدد می باشد از SVM و روش یکی در برابر همه استفاده کردیم. در این تحقیق پس از بررسی هسته های مختلف طبقه بندی کننده SVM، هسته RBF نتایج بهتری را در مقایسه با سایر هسته ها ارائه داد. دو پارامتر در نحوه عملکرد این طبقه بندی کننده نقش مهمی دارند. اولین پارامتر مقدار پراش تابع RBF (5) است، که هرچه کوچک تر باشد تابع RBF تیزتر و صحت را بالا می برد، ولی در مقابل از میزان قابلیت تمییم روش می کاهد. پارامتر دوم، ضربی جرمیة C است که با میزان خطای قابل قبول نسبت عکس دارد و بنابراین هر چه C را کمتر فرض کنیم خطای بیشتری را پذیرفتایم. انتخاب پارامترها با سعی و خطا و ارزیابی نتایج حاصل از پارامترهای مختلف بر روی یک دادگان کوچک اولیه انجام شد و پس از تعیین پارامترهای بهینه، روش بر روی کل دادگان اعمال و نتایج آن استخراج شد. برای اجرای MSVM با الگوریتم یکی در برابر همه ازتابع SVM موجود در STPRTool استفاده شد [۱۲]. نگاشت داده با استفاده از مدل بدست آمده از SVM

۸- انتخاب تصادفی ۳۰ درصد از کل داده برای آزمون و جهت تعیین درصد صحت.

۹- محاسبه درصد صحت داده آزمون.

۱۰- برگشت به مرحله ۲ و تغییر تعداد کاهش با استفاده از PCA جهت مقایسه و تحصیل حالت بهینه.

۱۱- محاسبه زمان اجرای الگوریتم و متوسط درصد صحت.

به منظور اطمینان از صحت نتایج بدست آمده، برنامه بین ترتیب عمل می کند که در هر مرحله از ۱۰ عضو موجود در هر کلاس ۷تا برای آموزش و ۳تا برای آزمون بتصادف و مستقل از هم انتخاب می شود (با استفاده از روش KCV<sup>۱۴</sup>). همچنین نتایج بدست آمده متوسط ۱۰ بار اجرای برنامه بوده است. همچنین به منظور بررسی اثر استفاده از تعداد مولفه های PCA و KPCA در میزان دقت دسته بندی سیستم و زمان دسته بندی چهره های بانک اطلاعاتی بکار رفته، مراحل دسته بندی با تعداد مولفه های مختلف انجام شدند. نتایج بدست آمده در جداول و نمودارهای زیر آورده شده است.

جدول ۱ - نتایج بدست آمده با استفاده از MSVM بر روی مجموعه داده ORL شامل ۴۰ کلاس با متوسط ۱۰ مرتبه اجرا

#	تعداد ویژگی کاهش با PCA	درصد آموزش	درصد آزمون	تعداد تصاویر غلط شناسایی شده در آموزش	تعداد تصاویر غلط شناسایی شده در آزمون	زمان سپری شده (Sec)
۱	۱۲۰	۱۰۰	۹۳.۳۳	۰	۸.۰۰	۱۷۰.۹۱۱
۲	۱۱۵	۱۰۰	۹۴.۰۸	۰	۷.۱۰	۱۶۷.۳۵۱
۳	۱۱۰	۱۰۰	۹۶.۱۶	۰	۴.۶۰	۱۶۲.۲۶۲
۴	۱۰۵	۱۰۰	۹۵.۰۰	۰	۶.۰۰	۱۵۰.۴۵۹
۵	۱۰۰	۱۰۰	۹۵.۲۵	۰	۵.۷۰	۱۴۲.۹۴۹
۶	۹۱	۱	۹۱.۱	۱	۱.۵	۱۵.۶۳۱

<sup>13</sup> Support v  
<sup>14</sup> K-Fold C

# اولین همایش ملی پیشرفت های تکنولوژی در مهندسی برق، الکترونیک و کامپیوتر

First National Conference of Technology Developments on Electronical, Electronics and Computer Engineering

... WWW.TDECN.F.IR ...

#	تعداد ویژگی کاهش با PCA	درصد صحت آموزش	درصد صحت آزمون	تعداد تصاویر غلط شناسایی شده در آزمون	تعداد تصاویر غلط شناسایی شده در آزمون	زمان سپری شده (Sec)

نتایج بدست آمده از اجرای الگوریتم در جدول ۱ نشان داده میدهد که می توان مجموعه تصاویر را با تعداد ۱۱۰ ویژگی PCA و با استفاده از الگوریتم `oaaSVM` تا ۹۶.۱۶۶٪ از یکدیگر تفکیک کرد اما اجرای الگوریتم در این حالت دارای زمان بالایی در حدود ۱۲۶ ثانیه می باشد. با توجه به جدول ۱ مشاهده می کنیم افزایش تعداد مولفه ها تا ۱۱۰ مولفه دقت سیستم را افزایش داده و افزایش بیشتر تعداد مولفه ها سبب کاهش دقت می شود. همچنین زمان دسته بندی با بکارگیری تعداد مولفه بیشتر افزایش می یابد.

جدول ۲- نتایج بدست آمده با استفاده از MSVM بر روی مجموعه داده ORL شامل ۴۰ کلاس با متوسط ۱۰ مرتبه اجرا

# اولین همایش ملی پیشرفت های تکنولوژی در مهندسی برق، الکترونیک و کامپیوتر

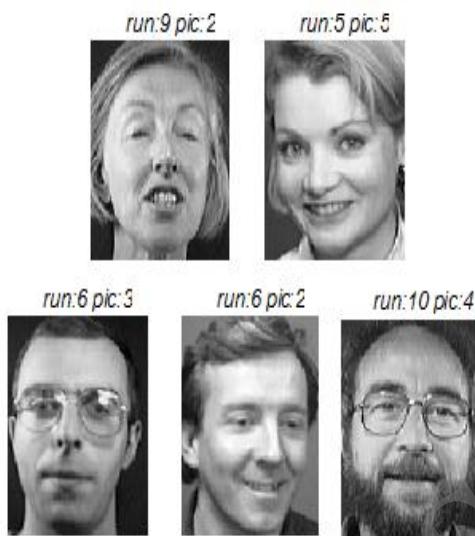
First National Conference of Technology Developments on Electronical, Electronics and Computer Engineering

. . . W W W . T D E C O N F . I R . . .

۱	۱۲۰	۱۰۰	۹۶.۴۱	.	۴.۳۰	۱۴۸.۵۶۰
۲	۱۱۵	۱۰۰	۹۶.۶۶	.	۴.۰۰	۱۴۵.۰۰۰
۳	۱۱۰	۱۰۰	۹۷.۴۱	.	۳.۱۰	۱۳۹.۹۱۱
۴	۱۰۵	۱۰۰	۹۶.۴۱	.	۴.۳۰	۱۲۸.۱۰۸
۵	۱۰۰	۱۰۰	۹۶.۲۵	.	۴.۵۰	۱۲۰.۰۹۸
۶	۹۵	۱۰۰	۹۶.۳۳	.	۴.۴۰	۱۱۸.۲۸۴
۷	۹۰	۱۰۰	۹۷.۱۶	.	۳.۴۰	۱۱۶.۲۸۴
۸	۸۵	۱۰۰	۹۶.۹۱	.	۳.۷۰	۱۰۹.۷۴۵
۹	۸۰	۱۰۰	۹۶.۵۰	.	۴.۲۰	۱۰۶.۰۷۹
۱۰	۷۵	۱۰۰	۹۷.۰۰	.	۳.۶۰	۹۹.۷۲۴
۱۱	۷۰	۱۰۰	۹۷.۰۰	.	۳.۶۰	۸۸.۲۱۰
۱۲	۶۵	۱۰۰	۹۷.۰۰	.	۳.۶۰	۸۷.۲۳۰
۱۳	۶۰	۱۰۰	۹۷.۱۶	.	۴.۵۰	۸۵.۰۰۰

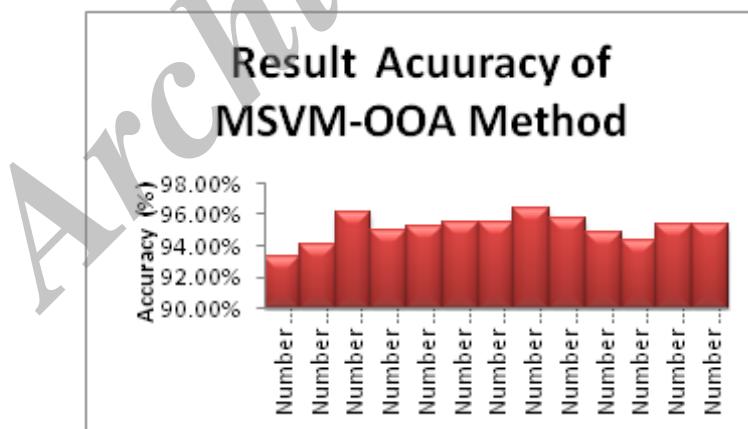


شکل ۴- مجموعه تصاویری که در طول ۱۰ بار اجرا در PCA با اکثریت، غلط شناسایی شدند.



شکل ۵- مجموعه تصاویری که در طول ۱۰ بار اجرا در KPCA با اکثریت، غلط شناسایی شدند.

در نهایت مجدداً کلیه آزمایش‌های فوق را با روش KPCA انجام دادیم که نتایج بدست آمده در جدول ۲ و نمودارهای مربوط به آن نشان داده اند. نتایج بدست آمده نشان می‌دهند استفاده از SVM در KPCA دقیق‌تر تشخیص را افزایش داده است. همچنین نتایج بدست آمده از اجرای الگوریتم در جدول ۲ نشان میدهد که می‌توان مجموعه تصاویر را با تعداد ۱۱۰ ویژگی KPCA و با استفاده از الگوریتم oaasvm تا ۹۷.۴۱۶۷٪ از یکدیگر تفکیک کرد اما اجرای الگوریتم در این حالت دارای زمان بالایی در حدود ۱۳۹ ثانیه می‌باشد.

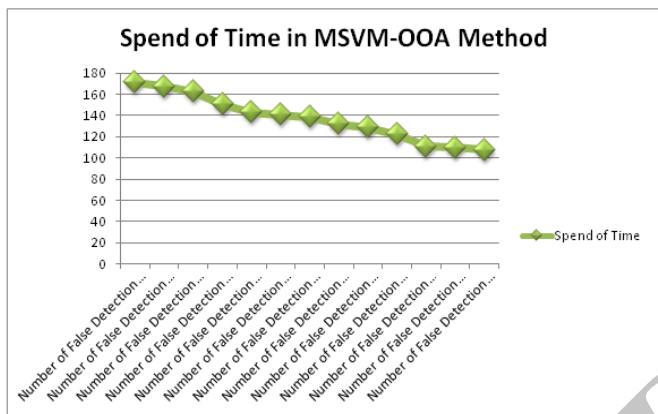


نمودار ۱- درصد صحت نتایج توسط ماشین بردار پشتیبان پس از متوسط گیری در ۱۵ بار اجرا در PCA

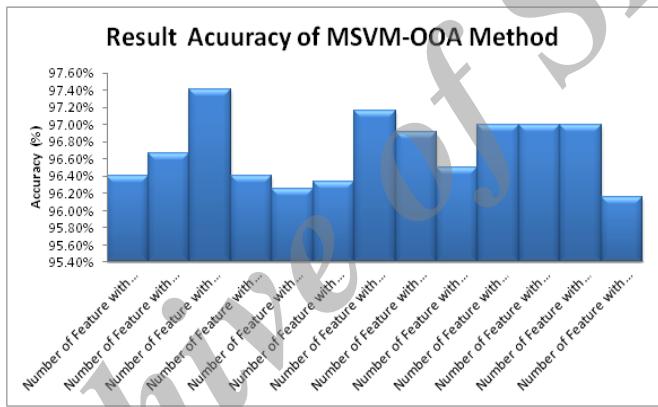
# اولین همایش ملی پیشرفت های تکنولوژی در مهندسی برق، الکترونیک و کامپیوتر

First National Conference of Technology Developments on Electronical, Electronics and Computer Engineering

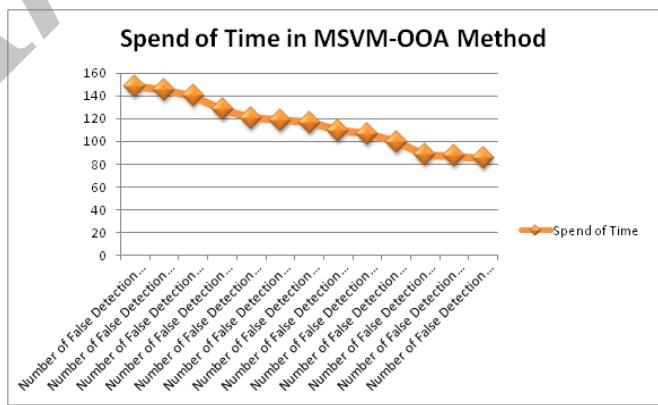
... WWW.TDECN.F.IR ...



نمودار ۲: زمان سپری شده بر حسب تعداد تصاویر غلط شناسایی شده در آزمون توسط ماشین بردار پشتیبان  $PCA$  پس از متوسط گیری دردباره با راجرا در



نمودار ۳- درصد صحت نتایج توسط ماشین بردار پشتیبان پس از متوسط گیری دردباره با راجرا در  $KPCA$



نمودار ۴: زمان سپری شده بر حسب تعداد تصاویر غلط شناسایی شده در آزمون توسط ماشین بردار پشتیبان  $KPCA$  پس از متوسط گیری دردباره با راجرا در

#### ۶- نتیجه‌گیری

در این مقاله از روش آنالیز مولفه های اصلی  $PCA$  و روش آنالیز مولفه های اصلی مبتنی بر هسته  $KPCA$  با روش تقسیم داده  $KCV$  و روش دسته بندی ماشین بردار پشتیبان  $SVM$  برای دسته بندی تصاویر چهره بانک  $ORL$  استفاده شده است. همچنین اثر بکارگیری مولفه های  $KPCA$  و  $PCA$  از ۶۰ مولفه تا ۱۲۰ مولفه در میزان تشخیص سیستم و زمان اجرای برنامه بررسی و نیز مقایسه گردید. نتایج بدست آمده نشان می دهند استفاده از  $SVM$  در  $KPCA$  دقت تشخیص را افزایش داده است. به عنوان ادامه کار مقایسه  $KPCA$  و  $PCA$  با روشهای دیگر دسته بندی مانند شبکه های عصبی مورد نظر است.

#### ۷- مراجع

- [۱] ابراهیم روزگار، محمد شهرام معین، بررسی سیستمهای شناسایی چهره، گزارش داخلی مرکز تحقیقات مخابرات ایران، ۱۳۸۸
- [۲] ابراهیم روزگار، محمد شهرام معین، تجزیه و تحلیل تکنیکهای مختلف شناسایی چهره، گزارش داخلی مرکز تحقیقات مخابرات ایران، ۱۳۸۸
- [۳] علی مطیع نصرآبادی، "ارزیابی کیفی و کمی تغییرات هوشیاری و عمق هیپنوتیزم به کمک پردازش هوشمند سیگنال EEG"، رساله دکتری مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، اسفند ۱۳۸۲
- [۴] Jianke Li, Baojun Zhao, Hui Zhang, " Face Recognition System Using SVM Classifier and Feature Extraction by PCA and LDA Combination", College of Information & Technology Hebei University of Economics & Business, China, (2009)
- [۵] Zhao Lihong , Song Ying , Zhu Yushi , Zhang Cheng , Zheng Yi," Face Recognition based on multi-class SVM", College of Information Science and Engineering, Northeastern University, Shenyang, (2009)
- [۶] Kebin Cui, Feng Han, Ping Wang, " Research on Face Recognition based on Boolean Kernel SVM" , School of Computer Science and Technology, North China Electric Power University, Baoding, Hebei, China (2008)
- [۷] Bernhard Scholkopf, Alexander Smola, and Klaus-Robert Muller, "Nonlinear component analysis as a kernel eigenvalue problem", Max-Planck-Institut für biologische Kybernetik Arbeitsgruppe Bühltho Spemannstraße 38 \* 72076 Tübingen \* Germany, December 1996
- [۸] B. Scholkopf, A. Smola, and K. R. Muller, Nonlinear component analysis as a kernel eigenvalue problem, Neural Comput., vol. 10, no. 5 pp. 1299–1319, 1998.
- [۹] Cortes.C,Vapnik.V, "Support-Vector Networks", Machine Learning, 1995: 20:273-297.
- [۱۰] Zhiwei.L, Minfen.S, "Classification of Mental Task EEG Signals Using Wavelet Packet Entropy and SVM", the Eighth International Conference on Electronic Measurement and Instruments, ICEMI, In IEEE, 2007:3:17-24.
- [۱۱] http://www.statistical pattern recognition Toolbox