

تبديل ويزگي با استفاده از خطاي کلاس‌بندی کمینه

مبتنی بر هسته برای بازشناسی الگو و گفتار

بهزاد زمانی، احمد اکبری و بابک ناصرشريف

آزمایشگاه پردازش صدا و گفتار، دانشکده مهندسی کامپیوتر، دانشگاه علم و صنعت ایران

چکیده:

روش‌های تبدیل ویژگی را می‌توان به دو دستهٔ خطی و غیرخطی تقسیم کرد. ایدهٔ اصلی در روش‌های تبدیل ویژگی مبتنی بر هسته، به عنوان دسته‌ای از روش‌های غیرخطی، نگاشت غیرخطی ویژگی‌ها به فضایی با بعد بالاتر است. در آنالیز متمايزساز خطی مبتنی بر هسته (KLDA)، معیار تفکیک‌پذیری بیشتر ویژگی‌ها در فضای جدید است. حال آن‌که در آنالیز مؤلفه‌های اصلی مبتنی بر هسته (KPCA)، معیار متعامدسازی ویژگی‌ها در فضای حاصل است. در مقاله حاضر یک روش جدید مبتنی بر هسته پیشنهاد و فرموله می‌شود که بر کمینه‌کردن خطای کلاس‌بندی در فضای ایجاد شده توسط هسته (KMCE) تکیه دارد. معیارهای بهینه‌سازی در روش‌های KLDA و KPCA مستقل از خطای کلاس‌بندی می‌باشند در صورتی که در روش پیشنهادی علاوه‌بر بهره‌برداری از ایدهٔ نگاشت غیرخطی هسته، معیار کمینه‌سازی خطای کلاس‌بندی نیز مورد نظر قرار می‌گیرد. نتایج حاصل بر روی دادگان UCI و کلاس‌بندهای مختلف، نشان می‌دهند که روش پیشنهادی در مقایسه با روش‌های تبدیل ویژگی خطی و روش‌های شناخته شده تبدیل ویژگی مبتنی بر هسته، در مورد کلاس‌بندهای مبتنی بر فاصله، نرخ بازشناسی بهتری دارد و در مورد کلاس‌بندهای آماری و مبتنی بر درخت تصمیم نیز، کارآیی قابل قبولی دارد. همچنین آزمایش‌های انجام شده روی دادگان گفتاری Aurora2 عملکرد مطلوب روش پیشنهادی را نسبت به روش‌های غیرخطی دیگر نشان می‌دهد.

واژگان کلیدی: تبدیل ویژگی، آنالیز تفکیک‌پذیری خطی، روش آنالیز مؤلفه اصلی، خطای کلاس‌بند کمینه،تابع هسته

آنالیز تفکیک‌پذیری خطی^۵ (LDA) یا تبدیل غیرخطی مانند آنالیز تفکیک‌پذیری مبتنی بر هسته^۶ (KDA) انجام گیرد. تبدیل ویژگی، فرآیندی است که در طی آن مجموعه ویژگی جدیدی ایجاد می‌شود. از دیدگاهی می‌توان تولید ویژگی^۷ و استخراج ویژگی را از انواع تبدیل ویژگی دانست. که به‌طور معمول به هر دو روش کشف ویژگی^۸ گفته می‌شود. در ایجاد ویژگی، فرآیند با تولید ویژگی‌های جدید همراه است که به این ترتیب علاوه‌بر ویژگی‌های اولیه، ویژگی‌های تولید شده نیز به مجموعه ویژگی‌ها اضافه می‌شود. ایجاد ویژگی تعداد ویژگی‌ها را زیاد می‌کند، در مقابل استخراج ویژگی تعداد ویژگی‌ها را کاهش می‌دهد. انتخاب ویژگی^۹ زیرمجموعه‌ای از ویژگی‌های اصلی را بدون تغییر آن‌ها انتخاب می‌کند و به نوعی کاهش ویژگی را نیز در بردارد.

۱- مقدمه

تبدیل ویژگی^۱ اصل مهمی در شناسایی الگو^۲ است. هدف اصلی آن انتقال دادگان از فضای ویژگی اصلی به فضای جدیدی است که در این فضا توصیف ساختار داده‌ها بهتر انجام گیرد. به عنوان مثال کلاس‌های داده‌ای که به‌طور خطی جدایی‌پذیر نیستند، با اعمال تبدیلی بر داده‌ها یا همان ویژگی‌ها به فضایی انتقال می‌یابند که به‌طور خطی جدایی‌پذیر باشند، در عمل کلاس‌بندی آسان‌تر می‌شود و تفکیک‌پذیری خطی کلاس‌ها در فضای جدید افزایش می‌یابد. تبدیل ویژگی خود می‌تواند مراحل استخراج ویژگی^۳، کاهش ویژگی^۴ و تبدیل ویژگی را در برداشته باشد که برای هر بخش روش‌های مختلفی ارایه شده است. از سویی تبدیل ویژگی می‌تواند به صورت تبدیل خطی مانند

⁵ Linear Discriminant Analysis (LDA)

⁶ Kernel Discriminant Analysis (KDA)

⁷ Feature Construction

⁸ Feature Discovery

⁹ Feature Selection

¹ Feature Transformation

² Pattern Recognition

³ Feature Extraction

⁴ Feature Reduction

از دیگر روش‌های تبدیل می‌توان به آنالیز مؤلفه‌های مستقل^{۱۲} (ICA) اشاره نمود. این روش همبستگی آماری مؤلفه‌های مختلف را کاهش می‌دهد (Hyvarinen, et al., 2001). از این تبدیل برای تفکیک پذیری کور منابع^{۱۳} ۲۰۰۱ استفاده می‌شود. عملکرد ICA متناسب با درستی فرض مستقل بودن منابع می‌باشد (Hyvarinen, et al., 2001). روش خطی آنالیز تفکیک پذیری ارجاعی^{۱۴} با ایجاد نیروی کشش بین نمونه‌های یک کلاس و نیروی رانش بین نمونه‌های دو کلاس متفاوت سعی در تمایز نمونه‌ها دارد (Kocsor and Kovacs, 2002). تکنیک‌های گفته شده با بهینه‌سازی معیاری سعی در بهدست آوردن تبدیلی دارند، که اصولاً با معیار مبتنی بر خطای کلاس‌بندی متفاوت است. روش خطای کلاس‌بند کمینه^{۱۵} (MCE) بر اساس کاهش خطای کلاس‌بندی عمل می‌کند. کاهش خطای کلاس‌بندی می‌تواند از طریق تغییر مدل‌ها در مرحله یادگیری یا تبدیل Juang, De la Torre, et al., 1996) ویژگی‌ها صورت پذیرد (Rudolph, 1995). روش تبدیل ویژگی MCE به صورت یک الگوریتم تکرار شونده است که در آن ماتریس تبدیل ویژگی با توجه به خطای کلاس‌بند بهدست می‌آید. رابطه تکرار شونده این الگوریتم می‌تواند مبتنی بر گرادیان کاهشی (Juang, 1997) یا الگوریتم‌های تکاملی مانند استراتژی تکاملی (Rudolph, 1995) باشد.

دسته دیگری از روش‌های تبدیل ویژگی، روش‌های غیرخطی می‌باشند. تبدیلات خطی در متایزسازی دادگانی که کلاس‌های آن ذاتاً به طور خطی جدایی پذیر نیستند، عملکرد ضعیفی دارند. روش غیرخطی آنالیز مؤلفه‌های اصلی (NLPCA)^{۱۶} مشابه با PCA برای تعیین و کاهش همبستگی داده‌ها به کار می‌رود. روش PCA همبستگی خطی بین ویژگی‌ها را مشخص می‌کند، اما NLPCA همبستگی خطی و غیرخطی بین ویژگی‌ها را بدون توجه به ماهیت غیرخطی داده‌ها مشخص می‌کند. در روش NLPCA یک شبکه عصبی برای تعیین نگاشت غیرخطی آموزش داده می‌شود. (Tzovaras, et al., 1998, Malthouse, 1998)

دیدگاه غیرخطی دیگر استفاده از تابع هسته می‌باشد، به این معنی که ابتدا با تابع هسته داده‌ها به فضای جدید نگاشت داده می‌شوند و در این فضا تبدیل خطی بر داده‌های

¹¹ Power Linear Discriminant Analysis (PLDA)

¹² Independent Component Analysis (ICA)

¹³ Blind Source Separation (BSS)

¹⁴ Springy Discriminant Analysis (SDA)

¹⁵ Minimum Classification Error (MCE)

¹⁶ Evolution Strategy (ES)

¹⁷ Nonlinear Principal Component Analysis (NLPCA)

مطالعات زیادی در زمینه روش‌های تبدیل داده و ویژگی انجام شده است (Jolliffe, 1986, Loog, et al., 2001, Jin, et al., 2001, Loog, et al., 2004). روش آنالیز مؤلفه اصلی^۱ (PCA) بر اساس مقادیر ویژه^۲ و بردارهای ویژه^۳ عمل می‌کند و بردارهای ویژه‌ای را بر می‌گرداند که دارای مقدار ویژه بزرگ‌تری باشند (Jolliffe, 1986). روش PCA یک تبدیل خطی و بدون ناظر بوده و سعی در متعامدسازی داده‌های تبدیل یافته دارد (Jolliffe, 1986). از روش‌های خطی دیگر می‌توان به روش MDS^۴ اشاره کرد که در آن از ماتریس ضرب داخلی داده‌ها استفاده می‌شود و نشان داده شده است که همارز PCA می‌باشد (Abdi, 2007).

روش آنالیز تفکیک پذیری خطی، بر اساس معیار Fisher عمل می‌کند. این روش باناظر سعی در بهدست آوردن تبدیلی دارد که واریانس درون کلاسی را کاهش و واریانس برونی آن را افزایش دهد (Loog, et al., 2004). عدم همبستگی دادگان در کلاس‌بندی مطلوب بوده، از این رو روش آنالیز تفکیک پذیری خطی غیرهمبسته^۵ (ULDA) مطرح گردیده است. روش ULDA تبدیلی بهدست می‌آورد که علاوه بر افزایش معیار Fisher، مؤلفه‌های ویژگی تبدیل یافته به طور آماری همبستگی کمتری داشته باشند (Jin, et al., 2001). روش LDA برای مسائلی که فاصله کلاس‌ها در آن کم می‌باشد عملکرد ضعیفی دارد که به همین جهت روش آنالیز تفکیک پذیری خطی وزن دهنده^۶ (WLDA) شده، مطرح گردیده است (Jin, et al., 2001). عملکرد روش WLDA به نحوه انتخاب تابع وزن دهنده کلاس‌ها وابسته است که واریانس درون کلاس‌ها مشابه نیست، ضعیف می‌کند HDA^۷ (Kumar and Andreou, 1998)، روش‌های^۸ (Loog, et al., 2004) HLDA^۹، (Alphonso, 2001)، Sakai, et al., 2005) PLDA^{۱۰} و (Qin, et al., 2005) UHLDA^{۱۱}. این فرض را از LDA حذف کردند. (2007)

¹ Principal Component Analysis (PCA)

² Eigen Value

³ Eigen Vector

⁴ Metric Multi-Dimensional Scaling (MDS)

⁵ Uncorrelated LDA (ULDA)

⁶ Weighted LDA (WLDA)

⁷ Approximate Pairwise Accuracy Criteria (aPAC)

⁸ Heteroscedastic Discriminant Analysis (HDA)

⁹ Heteroscedastic Linear Discriminant Analysis (HLDA)

¹⁰ Uncorrelated Heteroscedastic LDA (UHLDA)



بر هسته می‌باشند. از سوبی دیگر روش خطای کلاس‌بند کمینه نسبت به روش‌های دیگر تبدیل ویژگی عملکرد بهتری دارد، چرا که معیار بهینه‌سازی آن کاهش نرخ خطای کلاس‌بندی است. با توجه به خواص سازوکار نگاشت غیرخطی و روش خطای کلاس‌بند کمینه، در این مقاله روشی ارایه می‌شود تا با تلفیق این دو روش از خواص و مزایای هر دوی آن‌ها بهره جوید در روش پیشنهادی ابتدا یک نگاشت غیرخطی دادگان را به فضای با ابعاد بزرگ‌تر می‌برد و سپس الگوریتم MCE در فضای جدید اعمال می‌شود. روش پیشنهادی یک روش باناظر و بدون کاهش ویژگی خواهد بود. عملکرد روش KMCE با روش‌های خطی LDA، MCE و PCA و روش‌های غیرخطی KLDA، KPCA مقایسه شده است. آزمایش‌ها بر روی دادگان مصنوعی، دادگان Iris، glass و vowel از مجموعه دادگان Aurora2 (UCI) و دادگان گفتاری (Blake, et al., 1998) انجام شده است.

در ادامه مقاله، در بخش دوم روش‌های تبدیل ویژگی خطی و غیرخطی بررسی می‌شوند. در بخش سوم روش پیشنهادی تبدیل ویژگی غیرخطی مبتنی بر هسته ارایه می‌شود. نتایج آزمایش‌ها در بخش چهارم بیان می‌شوند. درنهایت بخش پنجم به نتیجه‌گیری اختصاص دارد.

نگاشت یافته اعمال می‌گردد. این ایده در ماشین بردار پشتیبان (SVM) غیرخطی به کار می‌رود (Cristianini and Shawe-Taylor, 2000). Vapnik, 1998) روش آنالیز تفکیک‌پذیری ارجاعی مبتنی بر هسته^۱ (Kocsor and Kovacs, 2002) مبتنی بر هسته^۲ (Liu, 2004). Scholkopf, et al., 1998) و آنالیز تفکیک‌پذیری مبتنی بر هسته^۳ (Roth, et al., 1999) نمونه‌هایی از روش‌های مبتنی بر هسته می‌باشند. Mika و همکارانش الگوریتم تفکیک‌پذیری Fisher مبتنی بر هسته را به همراه منظم‌سازی ماتریس واریانس درون کلاسی ارایه کردن (Mika, et al., 1999) و همکارانش Xiong (Xiong, et al., 2005) و همکارانش QR استفاده می‌کند (Yang, et al., 2005). Xiong و همکارانش روش KPCA به همراه LDA را پیشنهاد کردن که متمایزسازی را دو چندان می‌کند (Yang, et al., 2005). Xiong و همکارانش دو روش آنالیز تفکیک‌پذیری غیرهمبسته مبتنی بر هسته^۴ و آنالیز تفکیک‌پذیری متعامد مبتنی بر هسته^۵ ارایه داده‌اند که سعی در ناهمبستگی بیشتر دادگان و تعامل آن‌ها دارند (Xiong, et al., 2006). در روش‌های مبتنی بر هسته تعیین نوع هسته در عملکرد روش تبدیل ویژگی مؤثر است، در این راستا بررسی‌هایی روی عملکرد توابع هسته مختلف در SVM و نیز سایر روش‌ها صورت گرفته است (Cao, et al., 2007). انتخاب تابع هسته به روش تبدیل ویژگی مبتنی بر هسته و ماهیت دادگان بستگی دارد.

از منظر دیگری روش‌های تبدیل ویژگی را می‌توان به دو دسته باناظر و بدون ناظر طبقه‌بندی کرد. در روش‌های باناظر اطلاعاتی از قبیل برچسب کلاس نمونه‌های آموزشی در اختیار قرار دارد؛ اما در روش‌های بدون ناظر هیچ اطلاعاتی از کلاس دادگان وجود ندارد. از روش‌های باناظر می‌توان به MCE، LDA و از روش‌های بدون ناظر می‌توان به PCA و KPCA اشاره نمود.

در این مقاله روش خطای کلاس‌بند کمینه مبتنی بر هسته^۶ (KMCE) ارایه شده است. همان‌گونه که گفته شد روش‌های تبدیل ویژگی عملکرد ضعیفی بر روی دادگانی که به‌طور خطی تفکیک‌پذیر نیستند، دارند. از این‌رو روش‌های غیرخطی مطرح شدند که شاخه‌ای از آن‌ها روش‌های مبتنی

¹ Kernel Springy Discriminant Analysis (KSDA)

² Kernel Principal Component Analysis (KPCA)

³ Kernel Discriminant Analysis (KDA)

⁴ kernel Uncorrelated Discriminant Analysis (KUDA)

⁵ Kernel Orthogonal Discriminant Analysis (KODA)

⁶ Kernel Minimum Classification Error (KMCE)

$$J(W) = \frac{W^T \text{trace}(S_b) W}{W^T \text{trace}(S_w) W} \quad (6)$$

که در این رابطه تابع trace مجموع مقادیر روی قطر اصلی ماتریس مربعی در آرگمنان وردیش را محاسبه می‌نماید.

۴-۳-۳- خطای کلاس‌بند کمینه

روش کمینه‌کردن خطای کلاس‌بندی (MCE)، روش متمايزسازی است که هم در گروه تبدیل ویژگی و هم در گروه آموزش کلاس‌بند به کار گرفته می‌شود (Duda, et al., 2001). هنگامی که روش MCE برای آموزش HMM (به عنوان یک کلاس‌بند) استفاده می‌شود، MCE پارامترهای مدل را به گونه‌ای تغییر می‌دهد که خطای کل کلاس‌بندی کاهش یابد (Juang, 1997). در روش آموزش به کمک MCE، ابتدا تابع هدف (که برای یافتن پارامترهای HMM به کار می‌رود) با استفاده از یک تابع پیوسته مدل می‌شود. سپس، کمینه این تابع با یک روش مانند گرادیان احتمالی کاهشی^۲ به دست می‌آید (De la Torre, et al., 1996).

ایده اصلی الگوریتم MCE، بهینه‌سازی نرخ خطای تجربی با استفاده از یک مجموعه داده آموزشی، جهت بهبود نرخ خطای بازناسی می‌باشد. پس از آن که نرخ خطای تجربی، توسط یک بازناسنایس یا کلاس‌بند، کمینه شد، تخمینی بایاس شده از نرخ خطای واقعی به دست می‌آید. یک راه مؤثر جهت کاهش این نرخ و بهبود کارآیی کلی سیستم، افزایش مرز میان کلاس‌ها در داده‌های آموزشی است. به این منظور از گرادیان کاهشی (De la Torre, et al., 1996) یا ترکیب امتیازهای حاشیه و نرخ خطای تجربی استفاده شده است.

روش MCE برای یافتن ماتریس تبدیل ویژگی‌ها با هدف کمینه‌کردن خطای کلاس‌بندی نیز استفاده شده است (Hung and Lee, 2002) و Wang (Wang and Paliwal, 2003) برای بازناسی واکه‌ها بهبود بخشیدند (Wang and Paliwal, 2003). در این رویکرد تابع هزینه برای کلاس k به صورت زیر تعریف شده است:

$$d_k(O, F) = -g_k(O, F) + \frac{1}{\eta} \log \left[\frac{1}{M-1} \sum_{i=1, i \neq k}^M \exp(g_i(O, F)\eta) \right] \quad (7)$$

² Gradient Probabilistic Descent

می‌باشد و هدف در آن به دست آوردن ماتریس تبدیلی است که خطای کلاس‌بندی را کاهش دهد. در این زیربخش سه روش PCA، LDA و MCE بررسی خواهند شد.

۲-۱-۱- آنالیز مؤلفه‌های اصلی

تبديل خطی PCA داده‌ها را به فضای نگاشت می‌کند که در آن بیشترین واریانس را داشته باشند. فرض کنید دادگان شامل N مشاهده، $\sum_{k=1}^N X_k = 0$ و $X_k \in R^M$ باشند. ماتریس کوواریانس مجموعه دادگان از رابطه زیر به دست می‌آید: (Lima, et al., 2003)

$$C = \frac{1}{N} \sum_{k=1}^N X_k X_k^T \quad (1)$$

با قطعی سازی C مؤلفه‌های اصلی به دست می‌آیند که این مؤلفه‌ها تصویر معتمد روی بردارهای ویژه هستند که با حل معادله مقادیر ویژه محاسبه می‌شوند. (Lima, et al., 2003)

$$\lambda V = CV \quad (2)$$

که $\lambda \geq 0$ مقادیر ویژه و $V \in R^{M \times \{0\}}$ (به معنی به استثنای {0}) بردارهای ویژه می‌باشند. از طرفی $CV = \frac{1}{N} \sum_{k=1}^N (X_k \cdot V) X_k$ ترکیب خطی از مشاهدات باشند، داریم: (Lima, et al., 2003)

$$V = \sum_{k=1}^N \alpha_k X_k \quad (3)$$

که α_k ها ضرایبی هستند که مقادیر آن‌ها به گونه‌ای انتخاب می‌شوند که رابطه بالا برقرار باشد. (Lima, et al., 2003)

۲-۱-۲- آنالیز تفکیک پذیری خطی

LDA یکی از روش‌های شناخته شده برای ایجاد تمایز میان ویژگی‌ها و کاهش خطی ابعاد ویژگی^۱ باناظر می‌باشد. در LDA کلاسیک، ماتریس کوواریانس درون کلاسی و برون کلاسی به صورت زیر محاسبه می‌شوند: (Fukunaga, 1990)

$$S_W = \frac{1}{N} \sum_{i=1}^I \sum_{n_i=1}^{N_i} (X_{n_i} - \mu_i)(X_{n_i} - \mu_i)^T \quad (4)$$

$$S_b = \frac{1}{N} \sum_{i=1}^I N_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (5)$$

که N تعداد کل نمونه‌ها، N_i تعداد نمونه‌های کلاس آم، μ_i میانگین کلاس آم، I تعداد کلاس‌ها و X_{n_i} نمونه از کلاس آم می‌باشند (Golub and Van Loan, 1996). هدف LDA به دست آوردن ماتریس تبدیل، W است به نحوی که معیار Fisher را در معادله (6) را بیشینه کند. (Fukunaga, 1990)

¹ Linear Dimensionality Reduction (LDR)

کمينه نماید. برای کمينه کردن خطای رابطه (۹) نسبت به \mathbf{W} مشتق گرفته می‌شود. به این ترتیب می‌توان نوشت:

$$\frac{\partial l_k(O, F)}{\partial W} = \frac{\partial l_k(O, F)}{\partial d_k(O, F)} \frac{\partial d_k(O, F)}{\partial W} \quad (13)$$

تابع هزینه $l_k(O, F)$ در رابطه (۹) تعریف شده است.

بردار O رشته مشاهده یا رشته بردار ويزگي های تبدیل یافته است و به صورت $\{o_1, o_2, \dots, o_T\}$ می‌باشد. همچنین بردار ويزگي های اصلی به صورت $\{x_1, x_2, \dots, x_T\}$ نشان $X = \{x_1, x_2, \dots, x_T\}$ داده شده است. با توجه به رابطه (۹) خواهیم داشت (وانگ و پالیوال ۲۰۰۳):

$$\frac{\partial l_k(O, F)}{\partial d_k(O, F)} = \alpha l_k(O, F)(1 - l_k(O, F)) \quad (14)$$

برای محاسبه بخش دوم رابطه (۱۴)،

از رابطه (۷) بر حسب W مشتق‌گیری می‌شود:

$$\frac{\partial d_k(O, F)}{\partial W} = -\frac{\partial g_k(O, F)}{\partial W} + \sum_{i=1, i \neq k}^M \left(\frac{\exp(g_i(O, F)\eta)}{\sum_{j=1, j \neq k}^M \exp(g_j(O, F)\eta)} \times \frac{\partial g_i(O, F)}{\partial W} \right) \quad (15)$$

در این رابطه $\frac{\partial g_j(O, F)}{\partial W}$ با توجه به نوع کلاس‌بند

محاسبه می‌شود. به عنوان مثال نحوه محاسبه برای کلاس‌بند مبتنی بر فاصله به صورت زیر است.

$$\frac{\partial g_i(O, F)}{\partial w_d} = 2w_d(O(d) - y_i(d))^2 \quad (16)$$

که $y_i(d)$ در (d) مرکز کلاس i می‌باشد. با جایگذاری (۱۶) در رابطه (۱۵) مقدار $\frac{\partial d_k(O, F)}{\partial W}$ به دست می‌آید. با جایگزین کردن رابطه محاسبه شده $\frac{\partial d_k(O, F)}{\partial W}$ و رابطه (۱۴) در (۱۳) مقدار $\frac{\partial l_k(O, F)}{\partial W}$ به دست می‌آید. با به کارگیری مقادیر $\frac{\partial l_k(O, F)}{\partial W}$ در رابطه (۱۲) ماتریس بهینه به دست می‌آید.

۲-۲- روش‌های تبدیل ويزگي غیرخطی

همان‌طور که گفته شد می‌توان روش‌های تبدیل ويزگي را به دو دسته روش‌های خطی و غیرخطی تقسیم نمود. علت پیدایش روش‌های غیرخطی عملکرد ضعیف روش‌های تبدیل ويزگي خطی برای دادگانی است که به طور خطی تفکیک‌پذیر نیستند. روش‌های غیرخطی به این صورت عمل می‌کنند که به کمک یک نگاشت غیرخطی داده‌ها را به سال ۱۳۸۹ شماره ۱ پیاپی ۱۳

که در آن M تعداد کلاس‌ها، η مقداری مثبت (ارایه شده در (Juang, 1997)، و $g_i(O, F)$ لگاریتم احتمال تعلق به کلاس i است که به صورت زیر تعریف می‌شود:

$$g_i(O, F) = \log p(O | \lambda_i) \quad (8)$$

که F مجموعه پارامترهای مرتبط با ويزگي ها و کلاس‌بندها می‌باشد. در روش MCE، هدف کمينه کردن تابع هزینه (۷) است. اما از آنجا که این تابع مشتق‌پذیر نیستند، از یک تابع پیوسته نرم مانند تابع سیگموئید به عنوان تابع هزینه استفاده می‌کنیم. بنابراین خواهیم داشت:

$$l_k(O, F) = \frac{1}{1 + \exp(-\alpha d_k(O, F))} \quad (9)$$

که $d_k(O, F)$ تابع هزینه (۷) می‌باشد و α پارامتر تنظیم بزرگ‌تر از یک است. بنابراین اگر $d_k(O, F)$ خیلی کوچک‌تر از صفر باشد، درواقع یک کلاس‌بندی درست رخداده و $l_k(O, F)$ به صفر نزدیک می‌شود. از طرفی مقدار مثبت برای $d_k(O, F)$ نشان‌دهنده جریمه برای کلاس‌بندی نادرست است و در این صورت $l_k(O, F)$ به یک متمایل می‌شود. کل خطای کلاس‌بند برای مشاهده O از رابطه (۱۰) به دست می‌آید:

$$L = \sum_{k=1}^M l_k(O, F) \quad (10)$$

با استفاده از ماتریس تبدیل، بردارهای ويزگي از فضای ويزگي اولیه به فضای جدید برده می‌شود تا تمایز کلاس‌ها بیشتر گردد. تمایز بیشتر باعث کاهش خطای می‌شود. از این‌رو با استفاده از معیار تابع هزینه، سعی می‌شود ماتریس تبدیل بهینه به دست آید. مقادیر دُرایه‌های ماتریس تبدیل به روش تکراری با استفاده از گرادیان کاهشی برای تابع L با رابطه (۱۱) قابل محاسبه خواهد بود.

$$w_{n,iter} = w_{n,iter-1} - \beta \frac{\partial L}{\partial w_n} \quad (11)$$

رابطه فوق را می‌توان به صورت ماتریسی بیان کرد:

$$\mathbf{W}_{iter} = \mathbf{W}_{iter-1} - \beta \frac{\partial L}{\partial \mathbf{W}} \quad (12)$$

که \mathbf{W} ماتریس تبدیل؛ \mathbf{W}_{iter-1} شاخص n امین دُرایه ماتریس تبدیل \mathbf{W} ؛ $iter$ اندیس تکرار الگوریتم، و β پارامتر یادگیری می‌باشد. روابط (۱۱) و (۱۲) نشان‌دهنده روش تکراری هستند. این رویه زمانی متوقف می‌شود که مقدار تابع هزینه از یک حد آستانه کم‌تر شود.

فرض کنید ماتریس تبدیل \mathbf{W} بردار ويزگي های n بعدی x را به بردار z با بعد $d \leq n$ تبدیل می‌کند. هدف، به دست آوردن ماتریس تبدیل \mathbf{W} است که تابع هزینه را

$$\hat{\phi}(X_k) = \phi(X_k) - \frac{1}{N} \sum_{j=1}^N \phi(X_j) \quad (21)$$

ماتریس کوواریانس از رابطه (۲۲) محاسبه می‌شود:

$$\hat{\Sigma} = \frac{1}{N} \sum_{j=1}^N \hat{\phi}(X_j) \hat{\phi}(X_j)^T \quad (22)$$

معادله مقادیر ویژه برای ماتریس کوواریانس فوق به صورت $\hat{\Sigma}\hat{V} = \hat{\lambda}\hat{V}$ می‌باشد. که $0 \leq \hat{\lambda} \leq \hat{\lambda}$ مقادیر ویژه و $\hat{V} \in F \setminus \{0\}$ (به معنی F به استثنای $\{0\}$) بُردارهای ویژه می‌باشند. معادل معادله مقادیر ویژه را می‌توان به صورت رابطه (۲۳) نوشت:

$$\hat{\lambda} \left(\hat{\phi}(X_k) \cdot \hat{V} \right) = \left(\hat{\phi}(X_k) \cdot \hat{\Sigma}\hat{V} \right), k = 1, \dots, N \quad (23)$$

اگهای $\hat{\alpha}_k$ ضرایبی هستند که مقادیر آنها به گونه‌ای انتخاب می‌شوند که رابطه (۲۴) برقرار باشد.

$$\hat{V} = \sum_{k=1}^N \hat{\alpha}_k \hat{\phi}(X_k) \quad (24)$$

که با جایگذاری رابطه (۲۴) در رابطه (۲۳) خواهیم داشت:

$$\hat{\lambda}\alpha = K\alpha, (\alpha = (\alpha_1, \dots, \alpha_N)^T) \quad (25)$$

که K ماتریس هسته بوده و به صورت ماتریس مرتعی $K_{i,j} = (\phi(X_i), \phi(X_j)) = k(X_i, X_j)$ با عناصر $N \times N$ می‌باشد. برای نرم‌السازی راه حل‌های (λ_k, α^k) ، بایستی رابطه $\lambda_k(\alpha^k \cdot \alpha^k) = 1$ در فضای نگاشت یافته اعمال شود. همچنین، همانند هر الگوریتم PCA دیگری، دادگان در فضای نگاشت یافته باید متمرکز^۲ شوند. برای این کار ماتریس هسته با رابطه زیر جایگزین می‌شود،

$$\hat{K} = K - 1_N K - K 1_N + 1_N K 1_N \quad (26)$$

که $(1_N)_{i,j} = 1/N$ می‌باشد. (شولونخ و همکاران ۱۹۹۱)

۲-۲-۳- آنالیز تفکیک پذیری خطی مبتنی بر هسته فرض کنید مشاهدات، X از طریق تابع $\Phi(\cdot)$ به فضای جدید نگاشت داده شوند، ماتریس کوواریانس درون کلاسی و بروون کلاسی در فضای نگاشت یافته به صورت زیر محاسبه می‌شوند. (Kocsor and Toth, 2004)

فضای جدید با ابعاد زیاد می‌برند که در این فضای دادگان به طور خطی تفکیک پذیر می‌شوند (Xie and Lam, 2006). بعضی از روش‌های غیرخطی با کمک شبکه عصبی نگاشت غیرخطی ایجاد می‌کنند و سپس تبدیل خطی به کار می‌برند همانند روش NLPICA. دسته دیگر از روش‌های غیرخطی روش‌های مبتنی بر هسته می‌باشند. در روش‌های تبدیل غیرخطی، نگاشت غیرخطی در دست نمی‌باشد و با روش‌هایی آن را تخمین می‌زنند. روش‌های مبتنی بر هسته بر این ایده استوارند که ضرب داخلی دادگان نگاشت یافته با یکتابع غیرخطی نامعلوم را می‌توان با تابع هسته تخمین زد، که به آن ایده هسته^۱ گفته می‌شود. در ادامه ابتدا ایده هسته و سپس دو روش KPCA و KLDA بررسی خواهند شد.

۲-۱-۲-۱- ایده تابع هسته

مجموعه X را در نظر بگیرید، تابع هسته k به صورت زیر تعریف می‌شود:

$$k : X \times X \rightarrow \mathbb{R} \quad (17)$$

از ویژگی‌های تابع هسته می‌توان متقاضی بودن و مشیت بودن را نام برد، که در روابط (۱۸) و (۱۹) این مطلب بیان شده است.

$$k(x, y) = k(y, x) \quad \forall x, y \in X \quad (18)$$

$$\sum_{i,j=1}^n c_i c_j k(x_i, x_j) \geq 0, \quad (19)$$

$\forall c_1, c_2, \dots, c_n \in \mathbb{R}, x_1, x_2, \dots, x_n \in X$ می‌توان نشان داد که برای یک تابع هسته، k ، فضای هیلبرت H و یک تبدیل $\phi : X \rightarrow H$ وجود دارد که رابطه زیر برقرار باشد:

$$k(x, y) = \langle \phi(x), \phi(y) \rangle = \phi(x) \cdot \phi(y) \quad (20)$$

۲-۲-۲- آنالیز مؤلفه‌های اصلی مبتنی بر هسته

تکنیک اصلی KPCA محاسبه تبدیل PCA در فضای نگاشت یافته توسط یک تابع نگاشت غیرخطی است که از ایده هسته برای تخمین این نگاشت استفاده می‌شود. داده‌های نگاشت یافته (X_1, \dots, X_N) را در نظر بگیرید که میانگین آنها صفر نباشد. ابتدا با رابطه زیر میانگین داده‌های نگاشت یافته صفر می‌شود:

^۱ Kernel Trick



غیرخطی روش‌های مبتنی بر هسته است. در این راستا فرض می‌شود که دادگان با یکتابع غیرخطی به فضای با ابعاد بزرگ‌تر نگاشت داده می‌شوند؛ سپس الگوریتم MCE روی دادگان نگاشت یافته اعمال می‌شود. با توجه به نامعلوم بودن تابع نگاشت باقیستی تمامی روابط به گونه‌ای بازنویسی شوند که بتوان ضربهای نقطه‌ای نمونه‌های نگاشت یافته را با تابع هسته جایگزین کرد. در ادامه الگوریتم پیشنهادی فرموله می‌شود.

فرض کنید مشاهده X از طریق تابع $\Phi(\cdot)$ به فضای جدید نگاشت داده شود که به صورت زیر نمایش داده می‌شود:

$$X^\Phi = \Phi(X) \quad (35)$$

همچنین فرض کنید که با ماتریس تبدیل W داده‌های نگاشت یافته به $X^{\Phi, W}$ تبدیل شوند.

$$\begin{aligned} X^{\Phi, W} &= W \Phi(X) \\ W &= \sum_{i=1}^N \alpha_i X_i^\Phi \end{aligned} \quad (36)$$

از طرفی W به صورت $W = \sum_{i=1}^N \alpha_i X_i^\Phi$ تعریف

می‌شود که N تعداد کل نمونه‌های آموزشی و X_i^Φ نمونه i داده آموزشی نگاشت یافته می‌باشد. بنابراین رابطه (۳۶) به صورت زیر در می‌آید:

$$\begin{aligned} X^{\Phi, W} &= WX^\Phi = \left(\sum_{n=1}^N \alpha_n (X_n^\Phi)^T \right) X^\Phi = \\ &\sum_{n=1}^N \alpha_n ((X_n^\Phi)^T X^\Phi) = \sum_{n=1}^N \alpha_n (X_n^\Phi \cdot X^\Phi) = \\ &\sum_{n=1}^N \alpha_n (\Phi(X_n), \Phi(X)) = \\ &\sum_{n=1}^N \alpha_n k(X_n, X) = X^{\Phi, \alpha} \end{aligned} \quad (37)$$

روش خطای کلاس‌بندی کمینه سعی در به دست آوردن تبدیلی دارد که خطای کلاس‌بندی را کاهش دهد. تابع هزینه در فضای نگاشت یافته بازنویسی شده است.

$$\begin{aligned} d_k(X_{n_k}^{\Phi, \alpha}, Y^{\Phi, \alpha}) &= -g_k(X_{n_k}^{\Phi, \alpha}, y_k^{\Phi, \alpha}) + \\ &\frac{1}{\eta} \log \left[\frac{1}{I-1} \sum_{i=1, i \neq k}^I \exp(g_i(X_{n_k}^{\Phi, \alpha}, y_i^{\Phi, \alpha}) \eta) \right] \end{aligned} \quad (38)$$

$$S_W^\varphi = \frac{1}{N} \sum_{i=1}^I \sum_{n_i=1}^{N_i} (\varphi(X_{n_i}) - \mu_i^\varphi)(\varphi(X_{n_i}) - \mu_i^\varphi)^T \quad (27)$$

$$S_b^\varphi = \frac{1}{N} \sum_{i=1}^I N_i (\mu_i^\varphi - \mu^\varphi)(\mu_i^\varphi - \mu^\varphi)^T \quad (28)$$

که N تعداد کل نمونه‌ها، N_i تعداد نمونه‌های کلاس i ، μ_i^φ میانگین کلاس i در فضای نگاشت یافته، I تعداد کلاس‌ها و μ^φ نمونه i از کلاس i در فضای نگاشت یافته می‌باشد. هدف KFDA بیشینه کردن رابطه زیر می‌باشد:

$$J(W) = \frac{W^T S_W^\varphi W}{W^T S_b^\varphi W} \quad (29)$$

اگر ماتریس تبدیل W را می‌توان به صورت میانگین وزنی داده‌های آموزشی نگاشت یافته نوشت،

$$W = \sum_{i=1}^I \sum_{n_i=1}^{N_i} \alpha_{n_i} \varphi(X_{n_i}) = \Phi \alpha \quad (30)$$

بنابراین رابطه Fisher به صورت زیر خواهد شد:

$$J(W) = \frac{\alpha^T \Phi^T S_b^\varphi \Phi \alpha}{\alpha^T \Phi^T S_W^\varphi \Phi \alpha} = \frac{\alpha^T P \alpha}{\alpha^T Q \alpha} = J(\alpha) \quad (31)$$

که P و Q از طریق توابع هسته قابل محاسبه می‌باشند. روابط زیر نحوه محاسبه P و Q را نشان می‌دهند.
(Kocsor and Toth, 2004)

$$P = K(R - \hat{1})K \quad (32)$$

$$Q = K(I - R)K \quad (33)$$

که K ماتریس هسته، $\varphi(X_i), \varphi(X_j)$ و تابع $k(\cdot, \cdot)$ تابع هسته می‌باشد. و I ماتریس همانی، $\hat{1}_{i,j} = 1/N$ که در آن N تعداد کل مشاهدات می‌باشد. و ماتریس R به صورت زیر محاسبه می‌شود.

$$[R]_{i,j} = \begin{cases} \frac{1}{N_j}, & \text{if } i = j \\ 0, & \text{otherwise.} \end{cases} \quad (34)$$

که N_j تعداد مشاهدات مربوط به کلاس j است.

۳- روش پیشنهادی - خطای کلاس‌بند (KMCE)

روش پیشنهادی، KMCE، غیرخطی‌سازی روش MCE از طریق ایده هسته است. این روش از سویی دارای خاصیت MCE یعنی انطباق معیار تخمین تبدیل با خطای کلاس‌بندی می‌باشد. و از سوی دیگر دارای خاصیت نگاشت

که $d_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha})$ نشان‌دهنده جریمه برای کلاس‌بندی نادرست است که در این صورت $(l_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha}))$ به یک متمایل می‌شود. کل خطای کلاس‌بندی برای مشاهده از رابطه (۴۳) بدست می‌آید:

$$L = \sum_{k=1}^I \sum_{n_k=1}^{N_k} l_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha}) \quad (43)$$

که I تعداد کلاس‌ها، N_k تعداد مشاهدات کلاس k و $N = \sum_{k=1}^I N_k$ کل مشاهدات است. با استفاده از ماتریس تبدیل بردارهای ویژگی را از فضای ویژگی اوپله به فضای جدید برد تا تمایز کلاس‌ها بیشتر شود. تمایز بیشتر باعث کاهش خطای می‌شود. از همین‌رو با استفاده از معیار تابع هزینه سعی در به‌دست آوردن ماتریس تبدیل بهینه داریم. مقادیر دُرایه‌های ماتریس بر طبق رابطه (۳۶) وابسته به مقادیر α هستند که با تبدیل به‌روش تکراری با استفاده از گرادیان کاهشی با رابطه زیر محاسبه می‌شود:

$$\alpha_{pq,iter} = \alpha_{pq,iter-1} - \beta \frac{\partial L}{\partial \alpha_{pq}} \quad ; p = 1, 2, \dots, N, q = 1, 2, \dots, M \quad (44)$$

هدف به‌دست آوردن ماتریس تبدیل بهینه‌ای است که تابع هزینه را کاهش دهد. از این‌رو از تابع هزینه براساس مشتق می‌گیریم.

$$\frac{\partial l_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha})}{\partial \alpha_{pq}} = \frac{\partial l_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha})}{\partial d_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha})} \frac{\partial d_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha})}{\partial \alpha_{pq}} \quad (45)$$

با توجه به رابطه (۴۲) داریم:

$$\frac{\partial l_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha})}{\partial d_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha})} = \gamma l_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha}) (1 - l_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha})) \quad (46)$$

برای محاسبه نرم دوم در رابطه (۴۵)، $\frac{\partial d_k(X_{n_k}^{\Phi,\alpha}, y_i^{\Phi,\alpha})}{\partial \alpha_{pq}}$ از رابطه (۳۸) استفاده می‌شود. بعد از مشتق‌گیری از روابط فوق می‌توان نوشت:

که I تعداد کلاس‌ها، η عدد مثبتی است. همچنین $X_{n_k}^{\Phi,\alpha}$ مشاهده نگاشت‌یافته و تبدیل‌یافته از کلاس k می‌باشد. $(g_i(X_{n_k}^{\Phi,\alpha}, y_i^{\Phi,\alpha}))$ برابر با مربع فاصله با نماینده کلاس i در فضای نگاشت‌شده و تبدیل‌یافته یعنی $y_i^{\Phi,\alpha}$ می‌باشد که به صورت رابطه زیر بیان می‌گردد.

$$y_i^{\Phi,\alpha} = \frac{1}{N_i} \sum_{n_i=1}^{N_i} X_{n_i}^{\Phi,\alpha} = \frac{1}{N_i} \sum_{n_i=1}^{N_i} \sum_{n=1}^N \alpha_n k(X_n, X_{n_i}) \quad (39)$$

با توجه به استفاده نرم اقلیدسی و رابطه (۳۹) داریم:

$$g_i(X_{n_k}^{\Phi,\alpha}, y_i^{\Phi,\alpha}) = \|X_{n_k}^{\Phi,\alpha} - y_i^{\Phi,\alpha}\|^2 = \left(\sum_{n=1}^N \alpha_n k(X_n, X_{n_k}) - \frac{1}{N_i} \sum_{n_i=1}^{N_i} \sum_{n=1}^N \alpha_n k(X_n, X_{n_i}) \right)^2 \quad (40)$$

$$\left(\sum_{n=1}^N \alpha_n k(X_n, X_{n_k}) - \frac{1}{N_i} \sum_{n_i=1}^{N_i} \sum_{n=1}^N \alpha_n k(X_n, X_{n_i}) \right)^T$$

با بسط ضرب ماتریسی فوق به صورت عددی خواهیم داشت:

$$g_i(X_{n_k}^{\Phi,\alpha}, y_i^{\Phi,\alpha}) = \|X_{n_k}^{\Phi,\alpha} - y_i^{\Phi,\alpha}\|^2 = \sum_{m=1}^M \left(\sum_{n=1}^N \alpha_{nm} k(X_n, X_{n_k}) - \frac{1}{N_i} \sum_{n_i=1}^{N_i} \sum_{n=1}^N \alpha_{nm} k(X_n, X_{n_i}) \right)^2 \quad (41)$$

هدف روش خطای کلاس‌بندی کمینه، این است که توابع هزینه بیشینه شوند. ولی این توابع مشتق‌پذیر نیستند؛ از این‌رو از تابع پیوسته نرم، مانند تابع سیگموید به عنوان تابع هزینه استفاده می‌گردد، خواهیم داشت:

$$l_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha}) = \frac{1}{1 + \exp(-\gamma d_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha}))} \quad (42)$$

که $(d_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha}))$ تابع هزینه (۳۸) می‌باشد و γ پارامتر تنظیم بزرگ‌تر از یک است. بنابراین اگر $d_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha})$ خیلی کوچک‌تر از صفر باشد، درواقع یک کلاس‌بندی درست داریم و $l_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha})$ به صفر نزدیک می‌شود. از طرفی مقدار مثبت برای

۴- ارزیابی روش پیشنهادی KMCE

در این بخش به مقایسه و ارزیابی روش پیشنهادی با روش‌های MCE، PCA، LDA و KLDA پرداخته خواهد شد. نتایج آزمایش‌ها در سه زیربخش ارایه می‌شود. در زیربخش اول عملکرد روش‌ها در فضای دو بعدی بررسی می‌شود. و در زیربخش دوم نتایج کلاس‌بندی پس از اعمال هر یک از روش‌های پیش‌پردازش مطرح شده در مقاله روی دادگان UCI گزارش می‌گردد. و در زیربخش سوم نتایج بازنگاری گفتار گستته روی دادگان Aurora2 آورده شده است.

۴-۱- ارزیابی روش KMCE در فضای دو بعدی

ابتدا روش‌های تبدیل ویژگی بر روی دو مجموعه داده دو بعدی تعریف شده با نام‌های Chess و CircleLine به صورت شکل‌های (۱-الف) و (۱-ب) اعمال می‌شوند. این مجموعه دادگان دارای ساختاری به صورت (جدول ۱) می‌باشد. در این دو مجموعه داده میانگین و واریانس هر ویژگی برای هر دو کلاس یکسان می‌باشد. همان‌طور که در شکل‌های (۱-الف) و (۱-ب) مشاهده می‌شود، هر دو دادگان تقییک‌پذیر خطی نیستند. از این‌رو انتظار می‌رود که روش‌های متمازیزاساز خطی عملکرد ضعیفی داشته باشند.

$$\frac{\partial d_k(X_{n_k}^{\Phi,\alpha}, Y^{\Phi,\alpha})}{\partial \alpha_{pq}} = -\frac{\partial g_k(X_{n_k}^{\Phi,\alpha}, y_k^{\Phi,\alpha})}{\partial \alpha_{pq}} + \sum_{i=1, i \neq k}^I \left\{ \frac{\exp(g_i(X_{n_k}^{\Phi,\alpha}, y_i^{\Phi,\alpha})\eta)}{\sum_{j=1, j \neq k}^I \exp(g_j(X_{n_k}^{\Phi,\alpha}, y_j^{\Phi,\alpha})\eta)} \times \frac{\partial g_i(X_{n_k}^{\Phi,\alpha}, y_i^{\Phi,\alpha})}{\partial \alpha_{pq}} \right\} \quad (47)$$

مقدار $\frac{\partial g_i(X_{n_k}^{\Phi,\alpha}, y_i^{\Phi,\alpha})}{\partial \alpha_{pq}}$ از رابطه زیر محاسبه می‌گردد:

$$\frac{\partial g_i(X_{n_k}^{\Phi,\alpha}, y_i^{\Phi,\alpha})}{\partial \alpha_{pq}} = 2 \left(k(X_p, X_{n_k}) - \frac{1}{N_i} \sum_{n=1}^{N_i} k(X_p, X_{n_i}) \right) \quad (48)$$

$$\left(\sum_{n=1}^N \alpha_{nq} k(X_n, X_{n_k}) - \frac{1}{N_i} \sum_{n_i=1}^{N_i} \sum_{n=1}^N \alpha_{nq} k(X_n, X_{n_i}) \right)$$

با جایگذاری (۴۸) در رابطه (۴۷) مقدار

$$\frac{\partial d_k(X_{n_k}^{\Phi,\alpha}, y^{\Phi,\alpha})}{\partial \alpha} \quad \text{به دست می‌آید. با جانشینی رابطه}$$

$$\frac{\partial d_k(X_{n_k}^{\Phi,\alpha}, y^{\Phi,\alpha})}{\partial \alpha} \quad \text{و رابطه (۴۶) در (۴۵) محسوبه شده}$$

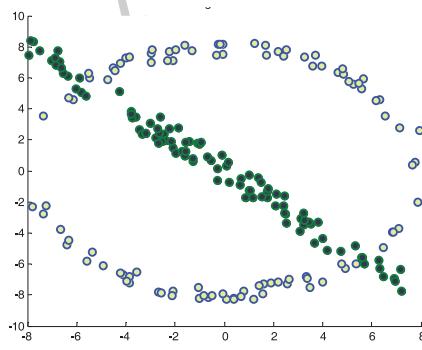
$$\frac{\partial l_k(X_{n_k}^{\Phi,\alpha}, y^{\Phi,\alpha})}{\partial \alpha} \quad \text{به دست می‌آید. با به کارگیری}$$

$$\frac{\partial l_k(X_{n_k}^{\Phi,\alpha}, y^{\Phi,\alpha})}{\partial \alpha} \quad \text{در رابطه (۴۴) ماتریس بهینه}$$

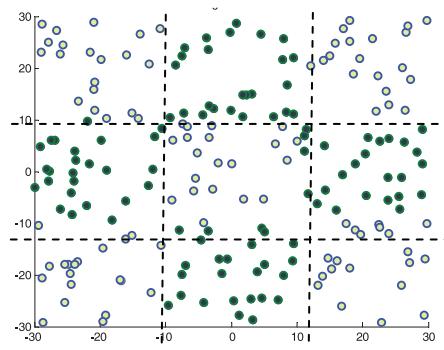
به دست می‌آید.

(جدول ۱) ساختار دادگان دو بعدی Chess و CircleLine

نام دادگان	تعداد کلاس	تعداد دادگان	تعداد ویژگی	تعداد نمونه آموزشی	تعداد نمونه تست
CircleLine	۲	۲	۲	۴۰۰	۲۰۰
Chess	۲	۲	۲	۴۰۰	۲۰۰



ب- دادگان CircleLine



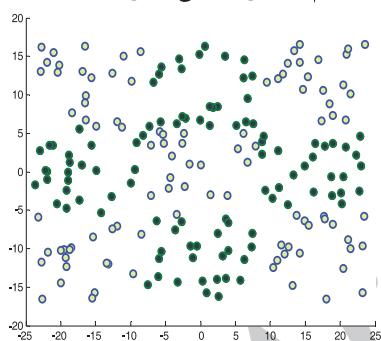
الف- دادگان Chess

(شکل ۱) نمایش دو بعدی مجموعه تست دادگان Chess و CircleLine در فضای ویژگی

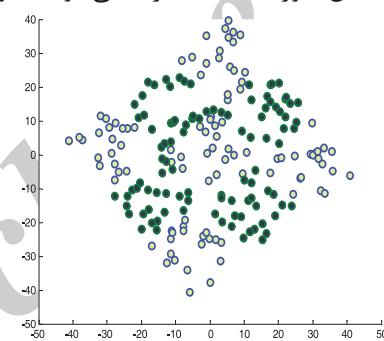
در شکل دیده می‌شود عملکرد ضعیفی برای دادگان Chess دارد. (شکل ۲-د) تبدیل یافته از روش KLDA و (شکل ۵-ه) تبدیل یافته از روش KPCA را نشان می‌دهند. در هر دو روش ازتابع هسته گوسین با پارامتر ۲ استفاده شده است. همان‌طور که مشاهده می‌شود روش‌های مبتنی بر هسته نسبت به روش‌های معمولی عملکرد بهتری داشته و پراکنده‌گی دادگان به گونه‌ای است که دو کلاس توسط یک کلاس‌بند خطی تفکیک‌پذیر بوده و خطای کمتری نسبت به روش‌های تبدیل معمولی حاصل می‌شود.

(شکل ۲-و) نمونه‌های تبدیل یافته در فضای

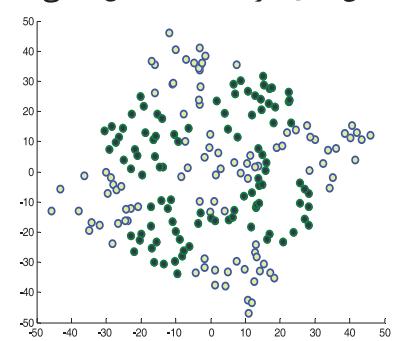
ویژگی‌های جدید پس از اعمال روش پیشنهادی، KMCE را نشان می‌دهد. تابع هسته به کار رفته در این روش نیز تابع گوسین با پارامتر ۲ می‌باشد. با توجه به شکل می‌توان دید که عملکرد روش پیشنهادی نسبت به روش MCE بسیار بهتر بوده، همچنین نسبت به روش تبدیلات مبتنی بر هسته دیگر مثل KPCA و KLDA نیز عملکرد مناسب‌تری داشته است. این امر با توجه به الگوریتم روش پیشنهادی و معیاری که تبدیل بر اساس آن به دست می‌آید قابل انتظار است. از سویی روش پیشنهادی یک روش غیرخطی بوده بنابراین برتری روش‌های تبدیل ویژگی مبتنی بر هسته را در بردارد و از سوی دیگر معیاری که براساس آن ماتریس تبدیل تخمین زده می‌شود به طور مستقیم خطای کلاس‌بندی است.



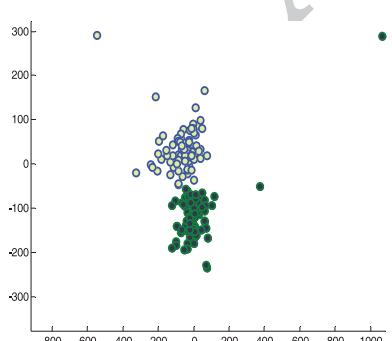
ج- تبدیل MCE



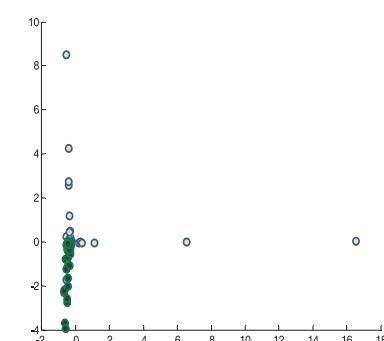
ب- تبدیل PCA



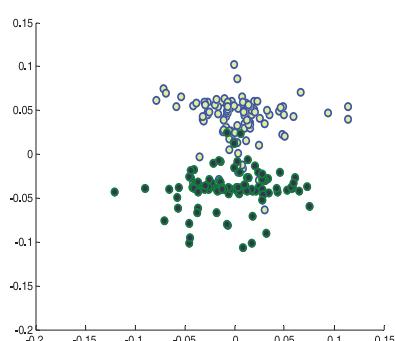
الف- تبدیل LDA



و- تبدیل KMCE



ه- تبدیل KPCA



د- تبدیل KLDA

(شکل ۲) نمایش دوبعدی مجموعه تست دادگان Chess بعد از اعمال تبدیلات ویژگی

KMCE و KPCA .KLDA .MCE .PCA .LDA

(شکل ۲) تبدیل یافته‌های دادگان Chess را پس از اعمال الگوریتم‌های پیش‌پردازش نشان می‌دهد. در تمام روش‌ها از دادگان آموزش برای بهدست آوردن ماتریس تبدیل ویژگی استفاده شده است، سپس ماتریس تبدیل ویژگی به دست آمده روی دادگان تست اعمال می‌شود. شکل (۲-الف) فضای دوبعدی دادگان بعد از اعمال روش LDA را نشان می‌دهد. با توجه به فرض اویله LDA مبنی بر تفکیک‌پذیری خطی دادگان و عدم تطبیق این فرض با دادگان Chess این روش عملکرد مطلوبی نداشته و صرفاً باعث دوران دادگان شده است.

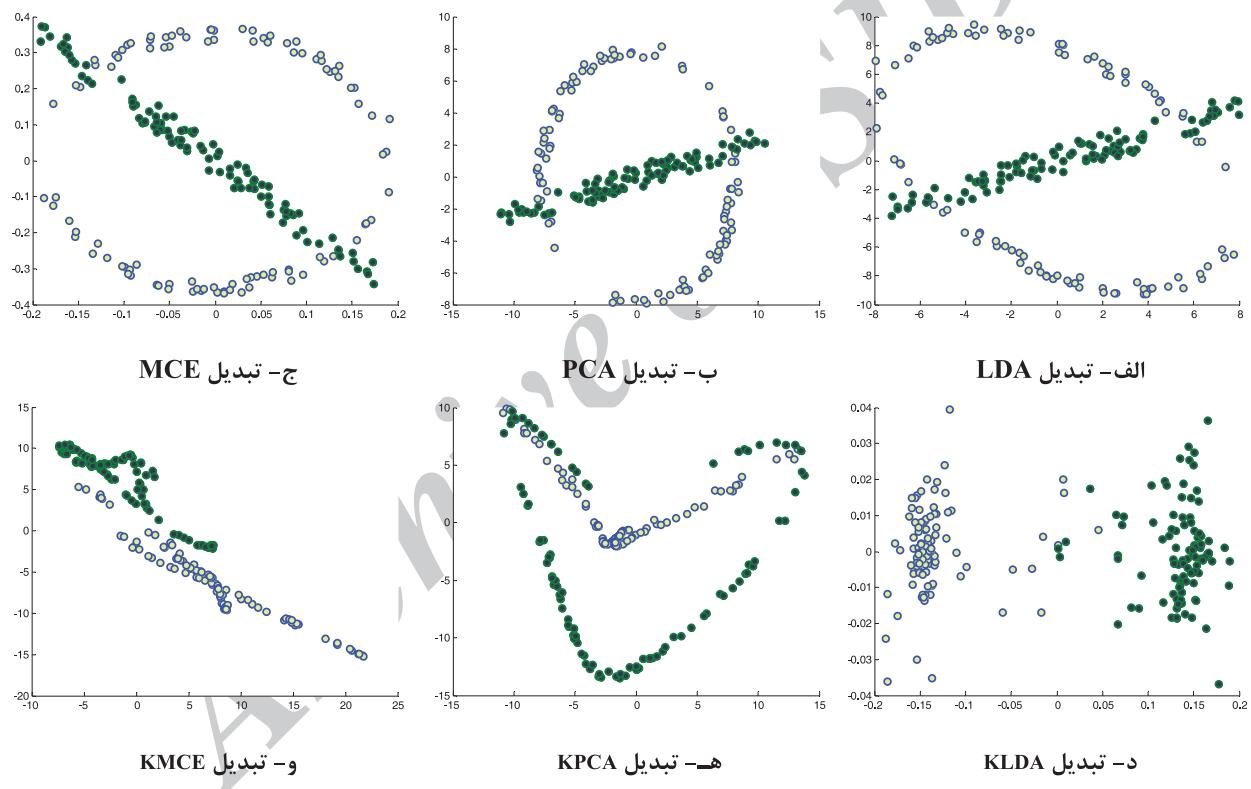
شکل (۲-ب) فضای دوبعدی ویژگی‌ها را بعد از اعمال الگوریتم PCA نمایش می‌دهد. روش PCA بدون توجه به برچسب کلاس نمونه‌های آموزشی سعی در بهدست آوردن تبدیلی دارد که واریانس ویژگی‌ها در راستای آن بیشینه گردد، لذا با توجه به ساختار دادگان Chess واریانس در راستای قطر دادگان بیشینه است که انتظار می‌رود تبدیل PCA دادگان را دوران داده به نحوی که قطرها در راستای محورهای جدید ویژگی قرار گیرند. بنابراین مشاهده می‌گردد که تبدیل PCA نیز عملکرد ضعیفی دارد.

شکل (۲-ج) پراکنده‌گی نمونه‌ها پس از تبدیل MCE را نشان می‌دهد. این تبدیل سعی در کاهش خطای کلاس‌بندی دارد اما یک تبدیل خطی است و همان‌طور که



تمامی جهات یکسان است؛ لذا PCA نمی‌تواند تبدیل بهینه‌ای به دست آورد. روش MCE ماتریس تبدیلی را به دست می‌آورد که خطای کلاس‌بندی را کاهش دهد. روش MCE یک تبدیل خطی به دست می‌آورد و عملکرد ضعیفی برای دادگانی مانند CircleLine که تفکیک پذیر خطی نیستند، دارد.

(شکل ۳-د) نمونه‌های تبدیل یافته از روش KLDA و (شکل ۳-ه) نمونه‌ای تبدیل یافته از روش KPCA را نشان می‌دهند. همان‌طور که مشاهده می‌شود، روش‌های مبتنی بر هسته نسبت به روش‌های معمولی، عملکرد بهتری داشته و پراکندگی دادگان به گونه است که دو کلاس توسط یک کلاس‌بند خطی تفکیک پذیر بوده و خطای کمتری نسبت به روش‌های تبدیل معمولی حاصل می‌شود.



(شکل ۳) نمایش دوبعدی مجموعه تست دادگان CircleLine بعد از اعمال تبدیلات ویژگی

KMCE و KPCA .KLDA .MCE .PCA .LDA

قرار خواهد گرفت. برای انجام آزمایش‌ها علاوه‌بر دو مجموعه دادگان Chess و Glass از CircleLine و UCI (Blake, et al., 1998) نیز Vowel مربوط به دادگان UCI است. مشخصات مجموعه دادگان در (جدول ۲) آورده شده است. برای کلاس‌بندی از ابزار Weka استفاده شده است. کلاس‌بندی‌های مورد استفاده در این بخش در سه گروه طبقه بندی می‌شوند: گروه کلاس‌بندی‌های مبتنی بر

سال ۱۳۸۹ شماره ۱ پیاپی ۱۳

(شکل ۳) تبدیل یافته‌های دادگان CircleLine را پس از اعمال الگوریتم‌های پیش‌پردازش نشان می‌دهد. در تمامی روش‌های تبدیل ویژگی از دادگان آموزش برای به دست آوردن ماتریس تبدیل ویژگی استفاده شده است و این ماتریس روی دادگان تست اعمال گردیده است. (شکل‌های ۳-الف)، (۳-ب) و (۳-ج) به ترتیب فضای دوبعدی دادگان بعد از اعمال روش‌های PCA، LDA و MCE را نشان می‌دهند. در LDA فرض بر تفکیک پذیر خطی بودن دادگان است و با توجه به ماهیت دادگان CircleLine یعنی تفکیک پذیر بودن غیرخطی، این روش عملکرد خوبی ندارد. روش PCA که یک روش بدون ناظر است تبدیل ویژگی‌ای به دست می‌آورد که واریانس ویژگی‌های جدید بیشتر شود، با توجه به پراکندگی دادگان در فضای ویژگی‌ها، واریانس در

۴-۲-۴- ارزیابی روش KMCE به عنوان پیش پردازش در کلاس‌بندی

جهت بررسی بهتر عملکرد روش پیشنهادی نسبت به دیگر روش‌های تبدیل ویژگی، این تبدیلات را به عنوان پیش‌پردازش در کلاس‌بندی دادگان نگاشت یافته با هر یک از روش‌های فوق به کار برد و نتایج کلاس‌بندی مورد ارزیابی

ویژگی خطی و KPCA و KLDA به عنوان روش‌های تبدیل ویژگی غیرخطی، مورد ارزیابی قرار گرفته است. ستون Normal نتایج کلاس‌بندی را برای دادگانی که هیچ تبدیلی روی آن‌ها انجام نگرفته است را نشان می‌دهد. اعداد مندرج در (جدول ۳) نتایج کلاس‌بندی دادگان نگاشت یافته را به درصد نشان می‌دهد. در هر سطر بیشترین مقدار به صورت ضخیم به همراه خط زیر و مقدار دوم به صورت فقط ضخیم نمایش داده شده است.

فاصله مانند IB1، IBK و KStar، گروه کلاس‌بندهای آماری مانند BayesNet، گروه کلاس‌بندهای مبتنی بر درخت تصمیم‌گیری مانند NBTTree.

(جدول ۳) نتایج کلاس‌بندی را روی کلاس‌بندهای مختلف و دادگان مختلف نشان می‌دهد. ستون‌های جدول نشان‌دهنده روش تبدیل ویژگی و سطراها نشان‌دهنده روش کلاس‌بند می‌باشد. روش پیشنهادی یعنی KMCE در کنار روش‌های MCE، LDA و PCA به عنوان روش‌های تبدیل

(جدول ۲) مشخصات مجموعه دادگان UCI (Blake, et al., 1998)

نام دادگان	تعداد کلاس	تعداد ویژگی	تعداد نمونه آموزشی	تعداد نمونه تست
Iris	۳	۴	۹۰	۶۰
Vowel	۱۱	۱۰	۵۲۸	۴۶۲
Glass	۶	۹	۱۲۷	۸۷

(جدول ۳) نتایج کلاس‌بندهای مختلف روی دادگان نگاشت یافته با تبدیلات مختلف

			Normal	LDA	PCA	MCE	KLDA	KPCA	KMCE
کلاس‌بند مبتنی بر فاصله	IB1	Chess	93.00	93.00	92.00	93.00	92.50	71.50	<u>97.00</u>
		CircleLine	98.00	98.00	97.50	98.00	97.00	96.50	<u>100.00</u>
		Iris	95.00	93.33	95.00	95.00	96.67	96.67	<u>98.33</u>
		Vowel	49.57	44.16	41.13	49.57	53.27	57.58	<u>58.44</u>
		Glass	66.67	67.82	72.41	66.67	68.97	71.26	<u>74.71</u>
کلاس‌بند مبتنی بر فاصله	IBK,3	Chess	92.50	93.00	93.00	92.50	92.50	71.50	<u>97.50</u>
		CircleLine	96.50	97.00	96.50	97.00	97.00	96.50	<u>100.00</u>
		Iris	95.00	95.00	95.00	95.00	96.67	<u>98.33</u>	<u>98.33</u>
		Vowel	49.13	42.86	39.39	49.13	54.33	58.23	<u>59.74</u>
		Glass	65.52	65.52	71.26	65.52	74.71	65.52	<u>77.01</u>
کلاس‌بند آماری	KStar	Chess	94.00	92.50	90.00	94.00	92.00	75.50	<u>99.00</u>
		CircleLine	97.00	95.50	95.50	97.00	97.50	94.50	<u>99.50</u>
		Iris	95.00	96.67	93.33	95.00	96.67	96.67	<u>98.33</u>
		Vowel	45.24	36.58	38.10	50.22	50.64	53.03	<u>57.80</u>
		Glass	<u>77.01</u>	63.22	68.97	<u>77.01</u>	66.67	72.41	<u>77.01</u>
کلاس‌بند آماری	BayesNet	Chess	50.00	73.50	82.50	50.00	<u>90.50</u>	68.50	<u>94.50</u>
		CircleLine	76.00	88.00	88.00	78.00	<u>97.00</u>	81.00	<u>88.50</u>
		Iris	91.67	<u>95.00</u>	<u>96.67</u>	<u>96.67</u>	<u>95.00</u>	<u>95.00</u>	<u>96.67</u>
		Vowel	36.58	41.56	37.01	36.36	<u>44.81</u>	39.61	<u>42.86</u>
		Glass	<u>68.97</u>	43.68	64.37	<u>68.97</u>	<u>66.67</u>	51.72	<u>66.67</u>
کلاس‌بند مبتنی بر درخت تصمیم	NBTTree	Chess	<u>97.50</u>	88.50	82.00	<u>97.50</u>	90.50	68.50	<u>94.50</u>
		CircleLine	95.00	92.00	89.00	95.00	<u>97.00</u>	81.00	<u>99.00</u>
		Iris	<u>96.67</u>	<u>95.00</u>	91.67	<u>96.67</u>	<u>96.67</u>	91.67	<u>95.00</u>
		Vowel	33.33	29.44	33.55	<u>35.71</u>	35.04	35.50	<u>42.64</u>
		Glass	60.92	65.52	<u>77.01</u>	60.92	58.62	<u>67.82</u>	65.52



به نتایج مندرج در جدول، روش KMCE در اغلب موارد بیشترین نتیجه بازشناسی را دارد و یا رتبه دوم را در بین روش‌های تبدیل ویژگی به خود اختصاص داده است.

۴-۳- نتایج روی دادگان Aurora2

برای ارزیابی روش‌های پیشنهادی، آزمایش‌هایی برای تشخیص کلمات مجزا بر روی دادگان Aurora2 انجام شده است (Hirsch and Pearce, 2000). بعده بردار ویژگی ۳۹ است که شامل دوازده ضریب MFCC به اضافه انرژی و مشتق اوّل و دوم این ضرایب می‌باشد. پس از استخراج ضرایب MFCC روی آن‌ها هنجارسازی بهرهٔ ضرایب کیپسترا (CGN^۱) انجام می‌شود (Yoshizawa, et al., 2004). هم‌چنین هر مدل مخفی مارکف که در اینجا برای بازشناسی گفتار به کار گرفته شده است، دارای شش حالت و هشت مخلوط گاوی در هر حالت می‌باشد.

در (جدول ۴) میانگین مقادیر دقّت بازشناسی گفتار در هر مجموعه آزمایش دادگان Aurora2، به صورت جداگانه گزارش شده است. نتایج MFCC بدون اعمال CGN آورده شده است تا به عنوان مبنای کار باشد و نتایج قابل مقایسه با مقالات دیگر باشد. در تمامی موارد PCA، LDA، MCE، KLDA و KPCA و KMCE پس از استخراج ویژگی‌های MFCC و اعمال CGN این تبدیلات روی ویژگی‌ها اعمال شده است.

مشاهده می‌شود که روش پیشنهادی KMCE در هر سه مجموعه تست، نسبت به روش‌های تبدیل غیرخطی مبتنی بر هسته دیگر عملکرد بهتری داشته است. همان‌طور که مشاهده می‌گردد پس از روش پیشنهادی روش KPCA عملکرد مطلوبی داشته و روش KLDA عملکرد ضعیفی از خود نشان داده است.

(جدول ۴) میانگین مقادیر دقّت بازشناسی کلمه Aurora2 روی مجموعه‌های A,B,C (انواع نویز) با نرخ سیگنال 20dB تا 0dB به نویز

	متوسط درصد دقّت بازشناسی کلمه برای سه مجموعه آزمایش Aurora2		
	A	B	C
MFCC (baseline)	60.68	65.75	45.07
MFCC+CGN	79.19	80.91	70.68
PCA	80.74	81.67	74.47
KPCA	81.58	82.27	74.82
LDA	76.62	80.48	71.21
KLDA	78.95	81.19	74.76
MCE	79.03	80.57	71.78
KMCE	81.96	83.27	76.71

^۱ Cepstral Gain Normalization

در ابتدای (جدول ۳) نتایج کلاس‌بندهای مبتنی بر فاصله بیان شده است. در اینجا سه روش کلاس‌بندی KStar^{*}، نزدیک‌ترین همسایه (IB1) و k نزدیک‌ترین همسایه با شعاع همسایگی، k، سه (IBK,3) مدت نظر قرار گرفته است. با توجه به نتایج، روش‌های تبدیل ویژگی غیرخطی عملکرد بهتری نسبت به روش‌های تبدیل ویژگی خطی دارند و این تفاوت در دادگان با تعداد ویژگی و تعداد کلاس بیشتر مانند Glass و Vowel مشهودتر است. روش پیشنهادی، KMCE، نسبت به روش MCE دارای نرخ کلاس‌بندی بالاتری است، این امر به دلیل ویژگی مبتنی بر هسته‌بودن روش پیشنهادی است. همان‌گونه که در قبل گفته شد روش MCE یک روش تبدیل ویژگی خطی است و در دادگان با تعداد ویژگی و تعداد کلاس بیشتر عملکرد ضعیفی دارد. با به کارگیری MCE در قالب روش‌های مبتنی بر هسته این نقیصه بر طرف گردید. روش پیشنهادی بر اساس کاهش خطای کلاس‌بندی عمل می‌کند، برای به دست آوردن خطای از کلاس‌بند فاصله استفاده شده است. بنابراین انتظار می‌رود که در کلاس‌بندهای مبتنی بر فاصله عملکرد بهتری داشته باشد و همان‌طور که در (جدول ۳) مشاهده می‌شود در تمامی دادگان و روش‌های کلاس‌بندی مبتنی بر فاصله، روش KMCE نرخ کلاس‌بندی بالاتری دارد.

باید توجه داشت که روش KMCE بر اساس کاهش خطای کلاس‌بند مبتنی بر فاصله عمل می‌کند و کارآیی برتر این روش نسبت به دیگر روش‌های تبدیل ویژگی در کلاس‌بندهای مبتنی بر فاصله مشاهده شد. در ادامه عملکرد این روش در کلاس‌بندهایی که از معیار فاصله استفاده نمی‌کنند نیز ارزیابی خواهد شد. برای این منظور ابتدا روش پیشنهادی در کلاس‌بندهای آماری و سپس در کلاس‌بندهای مبتنی بر درخت تصمیم مورد بررسی قرار می‌گیرد.

بخشی از (جدول ۳) نتایج کلاس‌بندی را روی کلاس‌بند آماری BayesNet نشان می‌دهد. چنان‌چه مشاهده می‌شود برای کلاس‌بند BayesNet روش KMCE نسبت به روش‌های تبدیل ویژگی خطی نتایج بالاتری در کلاس‌بندی دارد. در ضمن روش KMCE نسبت به روش KPCA عملکرد بالاتری داشته است، به عنوان مثال، این بهبود در دادگان Glass از ۵۱.۷۲ درصد برای روش تبدیل ویژگی PCA به ۶۶.۶٪ درصد برای روش تبدیل ویژگی KMCE رسیده است. در این کلاس‌بند روش KLDA و روش پیشنهادی نتایج نزدیک به هم دارند.

نتایج کلاس‌بندهای مبتنی بر درخت تصمیم NBTree در انتهای (جدول ۳) نشان داده شده است. با توجه

۵- نتیجه‌گیری

در این مقاله روش خطای کلاس‌بندی کمینه مبتنی بر هسته (KMCE) برای بازناسی الگو پیشنهاد و فرموله گردیده است. این روش بر مبنای معیار کمینه کردن خطای کلاس‌بند در فضای ایجادشده توسط هسته می‌باشد. معیار پیشنهادی با متعامدسازی ویژگی‌های در فضای هسته (Manifold) و تفکیک‌پذیری بیشتر کلاس‌ها در فضای هسته (KLDA) و دیگر تبدیلات خطی ویژگی‌ها مانند (PCA، LDA، MCE) مقایسه شده است. از سه گروه کلاس‌بند مبتنی بر فاصله، آماری و مبتنی بر درخت تصمیم جهت ارزیابی تأثیر روش پیشنهادی نسبت به دیگر روش‌ها بر نرخ بازناسی استفاده شده است. نتایج نشان می‌دهند که روش KMCE برای تمامی دادگان و تمامی کلاس‌بندی‌های مبتنی بر فاصله عملکرد بهتری داشته است. این امر به معیار بهدست آوردن تبدیل در روش پیشنهادی کاهش خطای کلاس‌بندی بر می‌گردد که روش برای کلاس‌بند فاصله فرموله شده است. بنابراین انتظار کارآیی بهتر در کلاس‌بندی‌های مبتنی بر فاصله می‌رود. به علاوه عملکرد KMCE در کلاس‌بندی‌های آماری و مبتنی بر درخت تصمیم‌گیری نیز قابل قبول است. نتایج بازناسی گفتار تحت نویز بر روی دادگان 2 Aurora نیز بیان‌گر عملکرد بهتر روش پیشنهادی یعنی KMCE است.

۶- منابع

- kernel-based learning methods, Cambridge University Press.
- De la Torre, A., et al., 1996. An application of minimum classification error to feature space transformations for speech recognition, *Speech Communication*, Vol. 20, pp. 273-290.
- Duda, R.O., et al., 2001. Pattern classification, 2nd edition, John Wiley & Sons.
- Fukunaga, K., 1990. Introduction to statistical pattern recognition, Academic Press, San Diego, California, USA.
- Golub, G.H., Van Loan, C.F., 1996. Matrix computations, The Johns Hopkins University Press, Baltimore, MD, USA, 3rd edition.
- Hirsch, H.G., Pearce, D., 2000. The AURORA experimental framework for the performance evaluation of speech recognition systems under noisy conditions, ISCA ITRW ASR, Paris, France.
- Hung, J., Lee, L.S., 2002. Data-driven temporal filters for robust features in speech recognition obtained via minimum classification error (MCE). In: Proceedings of ICASSP, pp. 373-376.
- Hyvarinen, A., et al., 2001. Independent component analysis, John Wiley & Sons.
- Jin, Z., et al., 2001. Face recognition based on the uncorrelated discriminant transformation, *Pattern Recognition*, Vol. 34, No. 7, pp. 1405-1416.
- Jolliffe, I.T., 1986. Principal component analysis, Springer-Verlag, New York.
- Juang, B.H., et al., 1997. Minimum classification error rate methods for speech recognition, *IEEE Transaction Speech Audio Processing*, Vol. 5, No. 3, pp. 257-265.
- Kocsor, A., Kovacs, K., 2002. Kernel springy discriminant analysis and its application to a phonological awareness teaching system, in *Proceedings of Text, Speech and Dialogue (TSD): 5th International conference*, pp. 325-328.
- Kocsor, A., Toth, L., 2004. Kernel-based feature extraction with a speech technology application, *IEEE Transactions on Signal Processing*, Vol. 52, No. 8, pp. 2250-2263.
- Kramer, M.A., 1991. Nonlinear principal component analysis using auto associative neural networks, *AIChE J.*, Vol. 37, No. 2, pp. 233-243.
- Kumar, N., Andreou, A.G., 1998. Heteroscedastic discriminant analysis and reduced rank HMMs for
- Abdi, H., 2007. Metric multidimensional scaling, in *Encyclopedia of Measurement and Statistics*, pp. 598-605.
- Alphonso, I., 2001. Heteroscedastic discriminant analysis, Critical Review Paper, ECE 8990 - Special Topics in ECE-Pattern Recognition, Institute for Signal and Information Processing, Mississippi State University.
- Blake, C., et al., 1998. UCI repository of machine learning databases. Available: www.ics.uci.edu/mlearn/MLRepository.html
- Cao, W., et al., 2007. Kernel function characteristic analysis based on support vector machine in face recognition, *Proceedings of the Sixth International Conference on Machine Learning and Cybernetics*, Vol. 5, pp. 2869-2873.
- Cristianini, N., Shawe-Taylor, J., 2000. An introduction to support vector machines and other kernel-based learning methods, Cambridge University Press.

- Wang, X., Paliwal, K.K., 2003. Feature extraction and dimensionality reduction algorithms and their applications in vowel recognition. Pattern Recognition, Vol. 36, pp. 2429-2439.
- Xie, X., Lam, K.M., 2006. Gabor-based kernel PCA with doubly nonlinear mapping for face recognition with a single face image, IEEE Transactions on Image Processing, Vol. 15, No. 9, pp. 2448-2492.
- Xiong, T., et al., 2005. Efficient kernel discriminant analysis via QR decomposition, In NIPS, pp. 1529-1536.
- Xiong, T., et al., 2006. Kernel uncorrelated and orthogonal discriminant analysis: a unified approach, Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06), pp. 125-131.
- Yang, J., et al., 2005. KPCA plus LDA: A complete kernel fisher discriminant framework for feature extraction and recognition. IEEE TPAMI, Vol. 27, No. 2, pp. 230-244.
- Yoshizawa, S., et al., 2004. Cepstral gain normalization for noise robust speech recognition, Proc. ICASSP, pp. 209-212.
- Zhang, B., Matsoukas, S., 2005. Minimum phoneme error based heteroscedastic linear discriminant analysis for speech recognition. In: Proceedings of ICASSP, Vol. 1, pp. 925-928.
- improved speech recognition, Speech Communication, Vol. 25, No. 4.
- Lima, A., et al., 2003. On the use of kernel PCA for feature extraction in speech recognition, Proceeding of EuroSpeech, pp. 2625-2628.
- Liu, C., 2004. Gabor-based kernel PCA with fractional power polynomial models for face recognition, IEEE Transaction Pattern Anal. Machine Intelligence, Vol. 26, No. 5, pp. 572-581.
- Loog, M., et al., 2001. Multiclass linear dimension reduction by weighted pairwise Fisher criteria, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 23, No. 7.
- Loog, M., et al., 2004. Linear dimensionality reduction via a heteroscedastic extension of LDA: the Chernoff criterion, IEEE Transaction Pattern Analysis and Machine Intelligence, Vol. 26, No. 6, pp. 732-739.
- Malthouse, E.C., 1998. Limitations of nonlinear PCA as performed with generic neural networks, IEEE Transaction on Neural Networks, Vol. 9, No. 1, pp. 165-173.
- Mika, S., et al., 1999. Fisher discriminant analysis with kernels, In IEEE Neural Networks for Signal Processing Workshop, pp. 41-48.
- Qin, A.K., et al., 2005. Uncorrelated heteroscedastic LDA based on the weighted pairwise Chernoff criterion, Pattern Recognition, Vol. 38, pp. 613 - 616.



بهزاد زمانی دانشجوی دوره دکترای هوش
مصنوعی در دانشکده مهندسی کامپیوتر
دانشگاه علم و صنعت می‌باشد. وی هم‌چنین
درجه کارشناسی ارشد هوش مصنوعی را از
دانشگاه علم و صنعت در سال ۱۳۸۴ و کارشناسی
سختافزار را از دانشگاه صنعتی اصفهان در سال ۱۳۸۱ اخذ
نموده است. در حال حاضر وی در آزمایشگاه پردازش صوت
و گفتار در زمینه تشخیص گفتار و روش‌های متمازیسازی بر
مبانی توابع هسته مشغول به تحقیق است. زمینه تحقیق
وی شامل بهبود گفتار، بازشناسی گفتار، تبدیلات متمازیساز
ویژگی و توابع هسته می‌باشد.

نشانی رایانمک ایشان عبارت است از:

bzamani@iust.ac.ir

Roth, V., et al., 1999. Nonlinear discriminant analysis using kernel functions, in Advances in Neural Information Processing Systems, pp. 568-574.

Rudolph, T., 1995. Minimum classification error optimization of word recognizers using evolution strategies, IEEE International Conference on Evolutionary Computation, Vol. 2, pp. 521-526.

Sakai, M., et al., 2007. Power linear discriminant analysis, 9th International Symposium on Signal Processing and Its Applications (ISSPA).

Scholkopf, B., et al., 1998. Nonlinear component analysis as a kernel eigenvalue problem, Neural Comput., Vol. 10, No. 5, pp. 1299-1319.

Tzovaras, D., Strintzis, M.G., 1998. Use of nonlinear principal component analysis and vector quantization for image coding, IEEE Transactions On Image Processing, Vol. 7, No. 8, pp 1218-1223.

Vapnik, V.N., 1998. Statistical learning theory, John Wiley & Sons Inc.

احمد اکبری درجه کارشناسی را در
مهندسی الکترونیک و درجه کارشناسی ارشد
را در مهندسی مخابرات از دانشگاه صنعتی
اصفهان در سال های ۱۳۶۶ و ۱۳۶۹ دریافت

کرد. وی درجه دکترا را در پردازش سیگنال و مخابرات راه
دور از دانشگاه رن فرانسه در سال ۱۳۷۴ اخذ نمود و در
همان سال به عنوان عضو هیأت علمی به دانشگاه علم و
صنعت پیوست و در حال حاضر به عنوان دانشیار دانشکده
مهندسی کامپیوتر مشغول به فعالیت است. وی سرپرست
مرکز تحقیقات فناوری اطلاعات و آزمایشگاه پردازش صوت
و گفتار در این دانشگاه است. در ضمن ایشان از سال ۱۳۷۹
عضو انجمن کامپیوتر ایران می باشد. زمینه تحقیقاتی وی
شامل بهبود گفتار، تشخیص گفتار، مقاوم سازی بازناسی
گفتار، انتقال صوت از طریق شبکه و پروتکل های مربوطه
می باشد.

نشانی رایانامک ایشان عبارت است از:

akbari@iust.ac.ir

بابک ناصر شریف متولد ۱۳۵۳ در تهران
است. ایشان درجه کارشناسی را در رشته
مهندسی کامپیوتر گرایش سخت افزار از
دانشگاه صنعتی امیرکبیر در سال
۱۳۷۶ دریافت نمود. وی موفق به اخذ درجه کارشناسی ارشد
و دکترا در رشته مهندسی کامپیوتر گرایش هوش مصنوعی
از دانشگاه علم و صنعت ایران در سال های ۱۳۷۹ و ۱۳۸۶
گردید. نامبرده از سال ۱۳۸۶ تاکنون عضو هیئت علمی گروه
مهندسی کامپیوتر در دانشکده فنی دانشگاه گیلان است.
زمینه تحقیقاتی ایشان بهبود گفتار، بازناسی گفتار و
مقاوم سازی آن، تبدیل موجک، مدل سازی و بازناسی الگو و
واژه بابی گفتاری می باشد.

نشانی رایانامک ایشان عبارت است از:

nasser_s@iust.ac.ir

فصلنامه
دولتی

سال ۱۳۸۹ شماره ۱ پیاپی ۱۳

پردازش داده ها
www.Semtar.com

