



ارزیابی الگوریتم‌های PCA و KPCA در تشخیص چهره انسان

بابک قاسمی^{۱*}، حمید عبادی^۲، فرشید فرنود احمدی^۳

- ۱- دانشجوی کارشناسی ارشد فتوگرامتری، دانشکده مهندسی ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی
- ۲- دانشیار گروه فتوگرامتری و سنجش از دور، دانشکده مهندسی ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی
- ۳- استادیار گروه نقشه برداری دانشگاه تبریز

چکیده:

استخراج ویژگی، یکی از مهم‌ترین مسائل در سیستم‌های تشخیص چهره می‌باشد. در این مقاله از روش‌های تحلیل مؤلفه‌های اساسی (PCA) و تحلیل مؤلفه‌های اساسی کرنل (KPCA) به منظور استخراج ویژگی و تشخیص چهره استفاده شده و نتایج آن‌ها با هم مقایسه شده است. با استفاده از تابع کرنل می‌توان به‌طور مؤثر مؤلفه‌های اساسی را در فضاهای ویژگی ابعاد بالا، بسته به نوع فضای ورودی و به وسیله تصویر کردن غیرخطی محاسبه کرد. کرنل استفاده شده در این مقاله کرنل پلی‌نومیال می‌باشد. نتایج عملی نشان‌گر این است که با افزایش تعداد مؤلفه‌های استفاده شده صحت کار بالاتر می‌رود و بعد از تعداد معینی ثابت باقی ماند. این مقدار ثابت مؤلفه می‌تواند با استفاده از رابطه نسبت انرژی و در مقدار ۰/۹۹ به دست آید. همچنین روش KPCA عملکرد بهتری نسبت به روش PCA داشته و با افزایش تعداد داده‌های آموزشی نتایج بهتر می‌شوند.

واژه‌های کلیدی: استخراج ویژگی، تشخیص چهره، تحلیل مؤلفه‌های اساسی کرنل، کرنل پلی‌نومیال، تحلیل مؤلفه‌های اساسی



۱- مقدمه

در سال‌های اخیر تشخیص چهره^۱ توجه زیاد محققان انجمن‌های زیست‌سنجی^۲، تشخیص الگو^۳ و بینایی ماشین^۴ را به خود جلب کرده است [۱-۳]. انجمن‌های گرافیک کامپیوتری^۵ و یادگیری ماشین^۶ نیز در حال استفاده از تکنولوژی‌های تشخیص چهره هستند. در سیستم‌های هوشمند و تعاملات بین انسان و کامپیوتر، تشخیص چهره به صورت اتوماتیک کاری ضروری است.

تحلیل مؤلفه‌های اساسی^۷ یک تکنیک کلاسیک استخراج ویژگی^۸ و نمایش‌دهنده داده است که از آن به صورت گسترده در حوزه‌های تشخیص الگو و بینایی ماشین استفاده می‌شود. PCA تبدیل به یکی از موفق‌ترین روش‌های تشخیص چهره شده است [۴]. اما PCA تنها از اطلاعات آماری مرتبه دوم در داده استفاده می‌کند و در حالات غیرخطی عملکرد آن با شکست مواجه می‌شود. تحلیل مؤلفه‌های اساسی کرنل^۹ روشی برای استخراج عوارض غیرخطی است. ایده اصلی آن توسط Vapnik ارائه شده است و در ابتدا در ماشین‌های بردار پشتیبان^{۱۰} (SVM) اعمال شده است. ثابت شده است که این روش در کاربردهای مختلف نظیر حذف نویز و مرحله پیش‌پردازش مسائل رگرسیون^{۱۱} کارآمد بوده است. این روش قادر است وابستگی‌های غیرخطی را در بین نقاط داده شناسایی کند و در برخی موارد بسیار موفق‌تر از روش PCA عمل می‌کند.

در این مقاله یک روش استخراج ویژگی برای تشخیص چهره بر اساس KPCA و کلسیفایر نزدیک‌ترین همسایه با استفاده از فاصله اقلیدسی به کار گرفته می‌شود. نتایج عملی نشان‌گر یک تشخیص با دقت بالا با استفاده از KPCA است.

۲- تحلیل مؤلفه اساسی

استفاده از ویژگی‌های غیرضروری اغلب باعث عملکرد نامناسب در تشخیص الگو می‌شود. یک دیدگاه سودمند عام این است که کاهش ابعاد فضای ویژگی درحالی‌که اطمینان داریم ساختار کلی نقاط داده دست‌نخورده باقی می‌ماند، کار ارزشمندی است. PCA یک روش محبوب برای انجام این کار است. PCA یک مجموعه از پایه‌های متعامد^{۱۲} تولید می‌کند که جهت‌های بیشینه پراکندگی (واریانس) در داده‌های آموزشی را می‌گیرد، و ضرایب PCA در زیرفضا نا همبسته^{۱۳} یا متعامد هستند. PCA می‌تواند ساختار کلی را حفظ کرده و داده در یک فضای ویژگی با ابعاد پایین‌تر پردازش می‌شود.

فرض می‌شود m تصویر برای آموزش انتخاب شده‌اند و هر تصویر شامل n پیکسل می‌باشد. ماتریس داده به شکل $X = \{x_i \mid i = 1, \dots, m\} \in R$ نشان داده می‌شود. ماتریس کوواریانس^{۱۴} داده آموزشی عبارت است از [۵، ۶]:

¹ Face Recognition

² Biometry

³ Pattern Recognition

⁴ Computer Vision

⁵ Computer Graphics

⁶ Machine Learning

⁷ Principal Component Analysis

⁸ Feature Extraction

⁹ Kernel Principal Component Analysis

¹⁰ Support Vector Machines

¹¹ Regression

¹² Orthogonal

¹³ Uncorrelated

¹⁴ Covariance Matrix



$$C = \sum_{i=1}^m (x_i - u)(x_i - u)^T \quad (1)$$

که

$$u = \frac{1}{m} \sum_{i=1}^m x_i \quad (2)$$

بردار میانگین می‌باشد.

می‌توان تعیین کرد $A = [x_{1-u}, x_{2-u}, \dots, x_{m-u}]$ که $C = AA^T$ یک ماتریس با ابعاد بالای $n \times n$ می‌باشد. پیدا کردن مقادیر ویژه^{۱۵} و بردارهای ویژه^{۱۶} ماتریس C کار مشکلی می‌باشد. بنابراین به جای آن مقادیر ویژه و بردارهای ویژه ماتریس $A^T A$ محاسبه می‌شود.

بردارهای ویژه v_i ($i = 1, 2, \dots, r$) ماتریس $A^T A$ متناظر با مقادیر ویژه λ_i ($i = 1, 2, \dots, r$) محاسبه می‌شوند. سپس بردارهای ویژه متناظر u_i از رابطه زیر به دست می‌آید:

$$u_i = \frac{1}{\sqrt{\lambda_i}} A v_i \quad (i = 1, 2, \dots, r) \quad (3)$$

این بردارهای ویژه به ترتیب نزولی بر اساس بزرگی مقادیر ویژه آن‌ها چیده می‌شوند $\lambda_1 \geq \lambda_2 \geq \dots \lambda_r > 0$ که بردارهای ویژه آن‌ها u_i می‌باشد.

با این کار هر تصویر به زیرفضای u_1, u_2, \dots, u_r منتقل می‌شوند. به منظور کاهش ابعاد d بردار ویژه اول انتخاب می‌شود. d می‌تواند با استفاده از نسبت انرژی مقادیر ویژه به دست آید:

$$\frac{\sum_{i=1}^d \lambda_i}{\sum_{i=1}^r \lambda_i} > \alpha \quad (4)$$

با استفاده از این روابط می‌توان ویژگی‌های تصویر پایگاه داده حالات مختلف چهره انسان‌ها را استخراج کرد. ماتریس پروجکشن^{۱۷} W شامل u_i به صورت $W = \{u_1, u_2, \dots, u_d\}$ تعریف می‌شود، سپس ویژگی‌های تصاویر با استفاده از رابطه زیر استخراج می‌شود:

$$g_i = W^T (x_i - u) \quad (5)$$

¹⁵ Eigenvalues

¹⁶ Eigenvectors

¹⁷ Projection Matrix



۳- تحلیل مؤلفه اساسی به روش کرنل

تحلیل مؤلفه اساسی به روش کرنل [۷]، بر بسیاری از محدودیت‌های روش خطی PCA به وسیله نگاشت غیرخطی فضای ورودی به یک فضای ویژگی با ابعاد بالا غلبه می‌کند. خطی بودن در فضای ویژگی ولی غیرخطی بودن آن در فضای ورودی [۸، ۹]، KPCA را قادر به استخراج ویژگی‌های با ابعاد پایینی که در اطلاعات آماری مرتبه بالاتر وجود دارند، می‌کند. برای یک نگاشت غیرخطی موجود، فضای ورودی R^N می‌تواند به یک فضای ویژگی با ابعاد بالاتر F منتقل شود. به عبارتی $\Phi: R^N \rightarrow F, x_i \rightarrow \Phi(x_i), i = 1, 2, \dots, M$ مدل خطی تفکیک‌ناپذیر در فضای R^N می‌تواند به یک مدل خطی تفکیک‌پذیر تبدیل شود.

در فضای ویژگی F [۱۰، ۱۱]، (که ممکن است ابعاد آن بی‌نهایت باشد) فرض می‌شود:

$$\sum_{i=1}^M \Phi(x_i) = 0 \quad (6)$$

ماتریس کوواریانس عبارت است از:

$$\bar{C} = \frac{1}{M} \sum_{i=1}^M \Phi(x_i) \Phi(x_i)^T \quad (7)$$

به‌منظور به دست آوردن ماتریس کوواریانس C ، باید معادله $\lambda V = \bar{C}V$ حل شود. در فضای ویژه F دقیقاً مانند روش PCA، هر مقدار ویژه $\lambda \neq 0$ که به بردار ویژه V نگاشت می‌شود، به زیر فضای $(\Phi(x_1), \dots, \Phi(x_M))$ منتقل می‌شود. اگر برای تمام $k = 1, \dots, M$ $\lambda(\Phi(x_k)V) = (\Phi(x_k).\bar{C}V)$ ، برای برخی $\alpha_i \in R^N$

$$V = \sum_{i=1}^M \alpha_i \Phi(x_i) \quad (8)$$

برای تمام $k = 1, \dots, M$ رابطه زیر حاصل می‌شود:

$$\lambda \sum_{i=1}^M \alpha_i (\Phi(x_k).\Phi(x_i)) = \frac{1}{M} \sum_{i=1}^M \alpha_i \left(\Phi(x_k).\sum_{j=1}^M \Phi(x_j) \right) (\Phi(x_j).\Phi(x_i)) \quad (9)$$

ماتریس کرنل $K = K_{ij} = \Phi(x_i)\Phi(x_j)$ با $K_{ij} = \Phi(x_i)\Phi(x_j)$ تعریف می‌شود. لذا معادله می‌تواند به شکل $M\lambda K\alpha = K^2\alpha$ نوشته شود. K یک ماتریس با رنک کامل^{۱۸} می‌باشد، زیرا یک ماتریس متقارن است، پس می‌توان نوشت $M\lambda\alpha = K\alpha$

به منظور سهولت محاسبات از d استفاده می‌شود.

$$k(x_i, x_j) = (x_i, x_j)^d \quad (10)$$

¹⁸ Full Rank



مقادیر ویژه ماتریس K به شکل $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_M$ و بردارهای ویژه متناظر آن به شکل $\alpha^1, \dots, \alpha^M$ نشان داده می‌شود. λ_p اولین مقدار ویژه غیر صفر می‌باشد [۱۲]. $\alpha^p, \dots, \alpha^M$ به نحوی نرمالیزه می‌شوند که برای

$$k = p, \dots, M$$

$$(V^k V^k) = 1 \quad (11)$$

از رابطه (۸) استفاده شده و نتیجه زیر حاصل می‌شود:

$$\sum_{i,j=1}^M \alpha_i^k \alpha_j^k (\Phi(x_i) \cdot \Phi(x_j)) = \sum_{i,j=1}^M \alpha_i^k \alpha_j^k K_{ij} = (\alpha^k \cdot K \alpha^k) = \lambda_k (\alpha^k \cdot \alpha^k) = 1 \quad (12)$$

لذا $\alpha^p, \dots, \alpha^M$ مجموعه بردار ویژگی متعامد ماتریس کوواریانس \bar{C} می‌باشد. به منظور استخراج ویژگی، باید انتقال بردارهای ویژه به روی V^k ($k = p, \dots, M$) در فضای ویژه F محاسبه شود. اگر فرض شود x یک نمونه ورودی است که نگاشت آن در فضای ویژگی F ، $\Phi(x)$ می‌باشد، انتقال آن در بردارهای ویژگی V^k به شکل زیر می‌باشد.

$$(V^k \cdot \Phi(x)) = \sum_{i=1}^M \alpha_i^k (\Phi(x_i) \cdot \Phi(x)) = \sum_{i=1}^M \alpha_i^k k(x_i, x) \quad (13)$$

با معرفی تابع کرنل، از محاسبه زمان بر و پیچیده ضرب داخلی در فضای ویژگی F با ابعاد بالا جلوگیری می‌شود. برخی توابع کرنل نظیر پلی‌نومیال^{۱۹}، گوسین^{۲۰} و سیگموئید^{۲۱} به صورت رایج در بسیاری از کاربردهای اجرایی روش‌های کرنل استفاده شده‌اند.

۴- نتایج عملی و تحلیل

آزمایشات بر اساس پایگاه داده حالات چهره ORL می‌باشد. پایگاه داده شامل تصاویر ۱۰ حالت مختلف از ۴۰ شخص می‌باشد. در این مطالعه هیچ پیش‌پردازشی انجام نمی‌شود. این پایگاه داده شامل حالات چهره (چشم باز یا بسته، لبخند یا بدون لبخند) و جزئیات چهره (با عینک یا بدون عینک) متفاوت می‌باشد که نمونه‌ای از آن‌ها در شکل ۱ نشان داده شده است.

تصاویر با یک تلورانس برای دوران و تیلت چهره تا ۲۰ درجه اخذ شده‌اند. و همچنین اختلافاتی تا اندازه ۱۰ درصد نیز در مقیاس وجود دارد. تمام تصاویر درجه خاکستری بوده و برای یک رزولوشن ۱۱۲×۹۲ پیکسل نرمال‌سازی شده‌اند که در این آزمایش برای رزولوشن ۹۰×۹۰ پیکسل نرمال‌سازی می‌شوند. لازم به ذکر است که در این تحقیق هیچ پیش‌پردازشی انجام نمی‌شود.

در این آزمایش از ۴۰ شخص متفاوت که هر کدام ۱۰ تصویر دارند، ۵ تصویر برای آموزش و ۵ تصویر برای تست انتخاب می‌شوند. به عبارتی ۲۰۰ تصویر آموزشی و ۲۰۰ تصویر تست وجود خواهد داشت. روش‌های PCA و KPCA برای استخراج ویژگی تصویر و کلسیفایر نزدیک‌ترین همسایه با استفاده از فاصله اقلیدسی برای تشخیص استفاده می‌شود. از بین روش‌های زیر، تابع کرنل پلی‌نومیال برای KPCA استفاده می‌شود.

¹⁹ Polynomial

²⁰ Gaussian

²¹ Sigmoid



کرنل پلی نومیال: $k(x_i, x_j) = (x_i \cdot x_j)^d$

کرنل گوسین: $k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$

کرنل سیگموئید: $k(x_i, x_j) = \tanh(k(x_i, x_j) + \theta)$



شکل ۱: نمونه‌ای از تصاویر مختلف چهره پایگاه داده ORL

نتایج آزمایشات حالات چهره بر اساس پایگاه داده ORL و با استفاده از روش PCA با مؤلفه‌های اساسی متفاوت به صورت جدول ۱ است.

جدول ۱: میزان صحت روش PCA در مؤلفه‌های اساسی مختلف

تعداد مؤلفه‌های اساسی	۵	۱۵	۲۵	۳۵	۴۵
درصد صحت PCA	۶۱/۰۰	۷۱/۰۰	۷۲/۵۰	۷۲/۵۰	۷۲/۵۰

مشاهده می‌شود که صحت روش PCA با ۲۵ مؤلفه اساسی ۷۲/۵۰ درصد بوده و پس از آن با افزایش مؤلفه‌های اساسی صحت ثابت می‌ماند. همچنین با استفاده از رابطه نسبت انرژی با $\alpha = 0.99$ تعداد مؤلفه‌های اساسی ۱۵۶ عدد به دست می‌آید که صحت روش با آن تعداد مؤلفه اساسی نیز ۷۲/۵۰ درصد خواهد بود.

قبل از ورود به استفاده از روش KPCA با مؤلفه‌های اساسی متفاوت، میزان صحت این روش با کرنل پلی نومیال و درجات مختلف d و در زمانی که $\alpha = 0.99$ می‌باشد در جدول ۲ نمایش داده می‌شود.



جدول ۲: میزان صحت روش KPCA در درجات مختلف کرنل پلی‌نومیال و نسبت انرژی ۰/۹۹

d	۱	۲	۳	۴	۵
تعداد مؤلفه اساسی	۱۶۸	۱۷۶	۱۷۳	۱۶۴	۱۵۲
صحت (%)	۷۸/۰۰	۷۳/۰۰	۷۲/۵۰	۷۲/۰۰	۷۱/۰۰

طبق جدول ۲ مشاهده می‌شود صحت روش با افزایش درجه پلی‌نومیال کاهش می‌یابد. لذا در ادامه روش از کرنل پلی‌نومیال با درجه ۱ و $\alpha = 0.99$ استفاده خواهد شد. همچنین می‌توان ثابت کرد که همانند روش PCA، صحت روش KPCA نیز با افزایش تعداد مؤلفه‌های اساسی از مقدار مشخصی ثابت مانده و تغییر نمی‌کند.

همان‌طور که معلوم است، نرخ تشخیص روش KPCA از روش PCA بالاتر است. بالاترین نرخ تشخیص برای روش KPCA، ۷۸ درصد و برای روش PCA، ۷۲/۵۰ درصد و با نسبت انرژی $\alpha = 0.99$ می‌باشد. لازم به ذکر است که بعد از تعداد مؤلفه‌های اساسی معینی، صحت روش افزایش پیدا نمی‌کند.

روش پیشنهادی برای بهبود صحت روش، افزایش تعداد تصاویر آموزشی از هر شخص به ۸ و کاهش تصاویر تست به ۲ می‌باشد و در کل ۳۲۰ تصویر آموزشی و ۸۰ تصویر تست در دست خواهد بود. با انجام این کار صحت روش KPCA با $\alpha = 0.99$ به ۹۲/۵۰ درصد افزایش می‌یابد. همچنین لازم به ذکر است اجرای این مرحله روی روش PCA با $\alpha = 0.99$ باعث بهبود صحت به ۸۷/۵۰ درصد می‌شود. لذا با افزایش تعداد تصاویر آموزشی نتایج بهتری به دست می‌آید. به این دلیل که چون الگوریتم در فضای دوبعدی و مبتنی بر اطلاعات پیکسل کار می‌کند، افزایش تنوع تصاویر چهره با حالات مختلف ژست، مقیاس و روشنایی باعث می‌شود الگوریتم بهتر آموزش داده‌شده و جواب بهتری بدهد.

۵- نتیجه‌گیری

در این مقاله الگوریتم‌های PCA و KPCA برای تشخیص چهره در حالات مختلف استفاده شد. PCA یک روش کلاسیک استخراج ویژگی و کاهش ابعاد می‌باشد که کاربردهای مهمی در رشته‌هایی نظیر تشخیص الگو، بینایی ماشین و آمار داشته است. روش تحلیل KPCA حالت بهبودیافته الگوریتم PCA می‌باشد که مفهوم PCA را در یک فضای ویژگی منتقل شده غیرخطی اجرا می‌کند. استخراج ویژگی از تصاویر چهره در حالات مختلف به روش KPCA، از تابع کرنل پلی‌نومیال و کلسیفایر نزدیک‌ترین همسایه بر اساس فاصله اقلیدسی استفاده می‌شود. آزمایشات بر روی پایگاه داده چهره ORL و با استفاده از PCA و KPCA انجام شد. نتایج آزمایش حاکی از آن است که تحلیل مؤلفه اساسی به روش کرنل نه تنها باعث کاهش داده شده، بلکه نرخ تشخیص بهتری از روش PCA دارد. همچنین با افزایش تعداد تصاویر آموزشی، الگوریتم نتایج مناسب‌تری را به دست می‌دهد.

مراجع

- [1] Chellappa, R., C.L. Wilson, and S. Sirohey, *Human and machine recognition of faces: A survey*. Proceedings of the IEEE, 1995. **83**(5): p. 705-741.
- [2] Jain, A.K., A. Ross, and S. Prabhakar, *An introduction to biometric recognition*. Circuits and Systems for Video Technology, IEEE Transactions on, 2004. **14**(1): p. 4-20.
- [3] Zhao, W., et al., *Face recognition: A literature survey*. ACM computing surveys (CSUR), 2003. **35**(4): p. 399-458.



- [4] Grudin, M.A., *On internal representations in face recognition systems*. Pattern recognition, 2000. **33**(7): p. 1161-1177.
- [5] SUN, T., S. GU, and Y. FEI, *A Comparative Study on Face Recognition Using PCA-based Methods [J]*. Modern Electronics Technique, 2007. **1**: p. 039.
- [6] Zhang, M., T. Li, and S. Zhong, *Implementation of Principal Component Analysis method (PCA) Based on Matlab*, ". Journal of Guangxi University (Nat Sci Ed). **30**: p. 74-77.
- [7] HUANG, G. and H. SHAO, *Kernel Principal Component Analysis and Application in Face Recognition [J]*. Computer Engineering, 2004. **13**: p. 005.
- [8] Lu, J., et al., *An efficient kernel discriminant analysis method*. Pattern Recognition, 2005. **38**(10): p. 1788-1790.
- [9] Yang, J., J.-y. Yang, and A.F. Frangi, *Combined fisherfaces framework*. Image and Vision Computing, 2003. **21**(12): p. 1037-1044.
- [10] Schölkopf, B., A. Smola, and K.-R. Müller, *Nonlinear component analysis as a kernel eigenvalue problem*. Neural computation, 1998. **10**(5): p. 1299-1319.
- [11] Schölkopf, B. and A.J. Smola, *Learning with kernels: Support vector machines, regularization, optimization and beyond*. 2002: MIT press.
- [12] Yang, J., et al., *KPCA plus LDA: a complete kernel Fisher discriminant framework for feature extraction and recognition*. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 2005. **27**(2): p. 230-244.