

حذف افزونگی داده‌های خام از مجموعه داده‌ها، با استفاده از تحلیل مؤلفه‌های اصلی تُنک

علی اصغر شریفی نجف آبادی^۱ و فرح ترکمنی‌آذر^۲

چکیده

تحلیل مؤلفه‌های اصلی یکی از روش‌های مطرح به منظور کاهش ابعاد مجموعه داده است که برای داده‌های یک بُعدی و دوبعدی قابل استفاده است. با توجه به تُنک نبودن بردارهای پایه، تحلیل مؤلفه‌های اصلی تُنک مطرح گردیده است که با حفظ خواص تحلیل مؤلفه‌های اصلی استاندارد، بعضی از درایه‌های بردارهای پایه را صفر می‌کند. در این مقاله، با توجه به خاصیت تُنکی بردارهای پایه، که سبب بی تأثیر گشتن بعضی از مقادیر مجموعه داده در انتقال به فضای جدید می‌گردد، دو الگوریتم به منظور حذف افزونگی از داده‌های خام، در حالت یک بُعدی و دوبعدی ارائه شده است. در الگوریتم یک بُعدی، افزونگی بین درایه‌های سیگنال تشخیص و سپس از تمامی مشاهدات مجموعه حذف می‌شوند. در الگوریتم دوبعدی اهمیت سطر وستون‌های تصاویر مجموعه داده، تشخیص و سطر وستون‌های با اهمیت کمتر به طور مستقیم از داده‌های خام حذف می‌شوند. یکی از مهمترین مزیت الگوریتم‌های پیشنهادی که به عنوان روش‌های نمونه برداری غیریکنواخت نیز میتوانند خوانده شوند، حفظ ظاهر سیگنال‌ها می‌باشد. پس از حذف افزونگی داده‌های خام توسط دو الگوریتم ارائه شده، می‌توان از داده‌های جدید با ابعاد کمتر در کاربردهای دیگری همچون بازشناسی مجموعه داده، فشرده سازی و ... استفاده کرد.

کلیدواژه‌ها

حذف افزونگی از داده‌های خام، تحلیل مؤلفه‌های اصلی تُنک، تحلیل مؤلفه‌های اصلی دوبعدی دو طرفه تُنک، استخراج ویژگی.

۱- مقدمه

با توجه به رشد روز افزون داده‌ها در دنیای امروز، کاهش حجم داده‌ها و استخراج ویژگی، از فعال‌ترین حوزه‌های مربوط به ذخیره‌سازی داده‌ها، فشرده‌سازی، یادگیری ماشین، طبقه‌بندی تصاویر، خوشه‌بندی تصاویر، کاهش نویز، تحلیل تصاویر پزشکی، تصاویر ماهواره‌ای و ... است. الگوریتم‌های متفاوتی به منظور انجام این فرآیند وجود دارد. یکی از موارد کاربردی کاهش حجم داده‌ها، ذخیره‌سازی

مجموعه‌های داده‌های مشابه می‌باشد. به طور مثال مجموعه طیف‌های بازگشتی از مواد مختلف، یا در حالت دوبعدی مجموعه تصاویر انسانی، که در موارد امنیتی مطرح است. متداول‌ترین روش در این مورد، تبدیل هاتلینگ می‌باشد که مبتنی بر تحلیل مولفه‌های اصلی می‌باشد. به طور کلی با در اختیار داشتن مجموعه‌ای از مشاهدات از یک پدیده، ماتریسی از مجموعه مشاهدات در نظر گرفته می‌شود. فرض کنید که k مشاهده از یک پدیده صورت گرفته و هر مشاهده به صورت یک بردار به اندازه $1 \times p$ باشد. در این صورت تمامی مشاهدات در ماتریس X به اندازه $k \times p$ قرار می‌گیرد. حال در روش‌های مختلف به دنبال ماتریس انتقالی به نام $B \in \mathbb{R}^{p \times d}$ می‌باشیم که داده‌ها توسط ماتریس B به فضای جدید براساس رابطه (۱) انتقال پیدا کنند:

$$Y = XB \quad (1)$$

این مقاله در شهریورماه ۱۳۹۶ دریافت، در اردیبهشت‌ماه ۱۳۹۷ بازنگری و در تیرماه همان سال پذیرفته شد.

^۱ دانشجوی کارشناسی ارشد برق دانشگاه شهید بهشتی

رایانامه: Ali.sharifi@mail.sbu.ac.ir

^۲ آزمایشگاه پردازش سیگنال‌های دیجیتال، دانشکده مهندسی برق، دانشگاه شهید بهشتی

رایانامه: f-torkamani@sbu.ac.ir

نویسنده مسئول: فرح ترکمنی‌آذر

توسط تعداد مؤلفه اصلی کمتری صورت بگیرد. در واقع تحلیل مؤلفه‌های اصلی این اجازه را به ما می‌دهد که مجموعه‌ای از متغیرهای مشاهده شده که همبستگی^۵ بالایی با یکدیگر دارند با مؤلفه‌های اصلی که همبستگی آماری آن‌ها کم و یا صفر است بیان گردد. در این موارد اولین مؤلفه‌های اصلی، بیشترین انرژی را از متغیرهای اولیه با خود دارند و به صورت متوالی این اهمیت کمتر می‌شود. همواره فرض بر آن می‌شود که بردارهای مشاهده دارای متوسط صفر می‌باشند. در این صورت ماتریس کواریانس محاسبه و سپس بردارهای ویژه آن محاسبه می‌گردد که ترتیب قرارگرفتن بردارهای ویژه در ستون‌های ماتریس بردار ویژه W به ترتیب اهمیت و حداکثرسازی انرژی می‌باشد.

$$X^T X = W \Lambda W \quad (۳)$$

در رابطه (۳) ماتریس W در ابعاد $p \times p$ و شامل بردارهای ویژه بوده و ماتریس قطری Λ شامل مقادیر ویژه به ترتیب اهمیت می‌باشد. یکی از روش‌های محاسبه ماتریس W می‌تواند مطابق رابطه بهینه‌سازی زیر صورت گیرد:

$$W = \max_{\hat{W}} \hat{W}^T X^T X \hat{W}, \text{ subject to } \hat{W}^T \hat{W} = I \quad (۴)$$

برای کاهش بُعد بردار مشاهده p بُعدی لازم است تا فقط d ستون از ماتریس W برای انتقال در نظر گرفته شود که اگر آنان در ماتریس B جای‌گذاری شوند، در این صورت مطابق رابطه (۱) انتقال به فضای جدید قابل انجام است. در واقع i امین عضو از هر بردار انتقال یافته جدید، نگاشت بردار مشاهده بر روی i امین بردار ویژه از مجموعه بردارهای متعامد است.

در مورد داده‌های دوبعدی مانند مجموعه تصاویر، به دو روش می‌توان عمل کرد. اولین مدل تبدیل سیگنال دوبعدی به یک بُعدی با قرار دادن متوالی سطرها یا ستون‌های آن به دنبال یکدیگر می‌باشد. تبدیل مجموعه دوبعدی به یک بُعدی مشکلات زیر را دارد:

- ابعاد ماتریس مشاهدات بسیار بزرگ شده و پیچیدگی محاسباتی زیادی به دنبال خواهد داشت.
- اساس کار الگوریتم PCA براساس همبستگی بین داده‌ها است که با تبدیل تصویر به بردار، همبستگی بین بعضی از پیکسل‌های همسایه از بین رفته و این خود سبب پایین آمدن کارایی الگوریتم می‌شود.

برای رفع این مشکلات راه‌حلی در چند سال اخیر ارائه شده است که در ادامه به طور مختصر توضیح داده خواهند شد. به منظور جلوگیری از تبدیل ماتریس به بردار، تحلیل مؤلفه‌های اصلی دوبعدی^۶ 2DPCA مطرح شد تا دیگر نیازی به تبدیل تصویر به بردار نباشد [۷]–[۴]. در تحلیل مؤلفه‌های اصلی

در این صورت بردار مشاهدات انتقال یافته در سطریهای ماتریس Y و در اندازه $1 \times d$ با $d \leq p$ خواهد بود. کاهش حجم ذخیره‌سازی در دو مورد کاربرد قابل بحث است.

• بازگشت و ساخت مجدد بردارهای مشاهدات اصلی با خطای قابل قبول امکان‌پذیر باشد. در این صورت لازم است تا ماتریس بازگشت $A \in \mathbb{R}^{d \times p}$ به گونه‌ای طراحی شود که:

$$\hat{X} = Y A \quad (۲)$$

و $|X - \hat{X}| \leq \varepsilon$ به ازای ε به اندازه کافی کوچک برقرار باشد. در واقع در اینجا به جای ذخیره‌سازی i امین بردار مشاهده از X ، i امین بردار (سطر) از ماتریس Y ذخیره می‌شود و هر چقدر d کوچکتر از p باشد، ذخیره‌سازی کارآمدتر است.

• مورد دیگر بحث شناسایی و تأیید^۱ یک مشاهده جدید از میان مجموعه مشاهدات در اختیار می‌باشد. در این حالت بحث بازگشت و بدست آوردن مشاهده جدید مطرح نیست. در واقع، به دنبال در اختیار داشتن یک بردار جدید متناظر با هر مشاهده به صورت یکتا با تمام ویژگیها و به خصوص ویژگیهای منحصر به فرد می‌باشیم و صرفاً هدف تشخیص و تأیید است. در این صورت احتیاجی به ماتریس A نیست. ولی ماتریس B باید به گونه‌ای باشد که توانایی انتقال تمامی مشخصه‌های هر مشاهده را فراهم سازد. ماتریس B می‌تواند ماتریس انتقال هر تبدیلی مانند تبدیل فوری، تبدیل کسینوسی و ... باشد. در مقاله حاضر، مورد دوم کاربرد، مدنظر است. در واقع در این مقاله به دنبال قرار دادن یک سیستم پیش پردازش می‌باشیم که ضمن حفظ ظاهر داده، تعدادی از عضوهای هر مشاهده را کاهش دهیم به نحوی که امکان پردازش های بعدی نه تنها فراهم باشد که خواص سیگنال اصلی نیز از بین نرود. این سیستم را به عنوان یک سیستم نمونه برداری غیر یکنواخت با حفظ ظاهر سیگنال نیز می‌توان معرفی کرد که احتیاجی به سیستم بازگشت و درونیاب ندارد.

در این پژوهش تمرکز بر روی تجزیه مؤلفه‌های اصلی $^2(PCA)$ [۲۱] و به ویژه مؤلفه‌های اصلی تُنک می‌باشد $^3(SPCA)$ [۳]. در ادامه به توضیح مختصر PCA که از الگوریتم‌های متداول کاهش بُعد است پرداخته می‌شود.

ایده تحلیل مؤلفه‌های اصلی، کاهش بُعد یک مجموعه داده است که تعداد زیادی از متغیرهای آن وابسته هستند. این کاهش بُعد باید به گونه‌ای باشد که حداکثر انرژی داده‌های اولیه حفظ شود. فرض کنید بین متغیرهای داده‌ها افزونگی^۴ وجود دارد، به این معنی که متغیرها با یکدیگر همبسته و در واقع یک ساختار را اندازه‌گیری می‌کنند. در این صورت تعداد متغیرهای اندازه‌گیری شده می‌تواند کاهش و نمایش داده‌ها

¹ Recognition and verification

² Principal Component Analysis (PCA)

³ Sparse principal Component Analysis

⁴ Redundancy

⁵ Correlation

⁶ Two Dimensional Principle Component Analysis

الگوریتم‌هایی به منظور تنگ سازی ماتریس‌های انتقال بیان شد. در ادامه در قسمت دوم به معرفی PCA تنگ (SPCA) و B2DPCA تنگ (BS2DPCA) که مورد کاربرد ما در این تحقیق است خواهیم پرداخت. در قسمت سوم ایده‌های پیشنهادی و توضیحات مرتبط آورده شده‌است. در بخش چهارم روش‌های ارائه شده، با استفاده از نرم‌افزار Matlab شبیه‌سازی شده و قدرت شناسایی و طبقه‌بندی این روش‌ها ارزیابی می‌شوند.

۲- تحلیل مؤلفه‌های اصلی تنگ

به منظور افزایش توانایی تحلیل ویژگی‌های استخراج شده، محققان با ارائه الگوریتم‌های مختلف، مؤلفه‌های اصلی تنگ را ارائه کردند.

تحلیل مؤلفه‌های اصلی تنگ (SPCA) برای اولین بار در سال ۱۹۸۵ بیان شد. در این روش در ابتدا مؤلفه‌های اصلی محاسبه و سپس پردازش بر روی آن‌ها انجام می‌شود [۱۴]. به منظور تنگ کردن ضرایب مؤلفه‌های اصلی، مرجع [۱۵] یک سطح آستانه برای ضرایب در نظر گرفته است و در صورتی که ضرایب کوچک‌تر از سطح آستانه باشند، مساوی صفر قرار داده می‌شوند. برخی از روش‌های دیگر، از الگوریتم‌های حریصانه^۳ [۱۶]، [۱۷] و دسته‌ای دیگر، از الگوریتم‌های بهینه‌سازی استفاده کرده‌اند [۱۸]، [۱۹]. مرجع [۲۰] نیز با استفاده از قیود نرم یک و دو، روشی را برای استخراج ضرایب تنگ با استفاده از رابطه بهینه سازی (۸) بیان کرده است که از میان همه روش‌های گفته شده بهتر عمل می‌کند که در ادامه به بررسی آن پرداخته می‌شود [۲۱ و ۸].

$$(A, B) = \arg \min_{\hat{A}, \hat{B}} \sum_{i=1}^k \|x_i - \hat{A}x_i \hat{B}\|^2 + \lambda \|\hat{B}\|^2 + \sum_{j=1}^k \lambda_j \|\hat{\beta}_j\|_1, \text{ subject to } \hat{A}^T \hat{A} = 1 \quad (8)$$

در این رابطه x_i بیان گر سطر i ام ماتریس X یا در واقع مشاهده i ام است، همچنین $\hat{\beta}_j$ ستون j ام از ماتریس B می باشد که با اعمال ضرایب متفاوت برای هر ستون، مقدار تنگی مختلف بر روی ستون‌های مختلف اعمال می شود. می توان B را ماتریس انتقال و A را ماتریس برگشت نامید. رابطه (۸) یک مسئله الاستیکنت می‌باشد که به راحتی توسط الگوریتم بازگشتی قابل حل خواهد بود [۳]. برای حل معادله (۸) با استفاده از الگوریتم تکرار، با مقداردهی اولیه ماتریس A ، مسئله به پیدا کردن مقادیر بردارهای ستونی β_j در مسئله الاستیکنت زیر منجر می‌شود [۳].

دو بُعدی یک طرفه فقط تعداد سطرها و یا تعداد ستون‌ها کاهش پیدا می‌کند اما به این نکته باید توجه داشت که در بین سطرها و ستون‌های یک تصویر افزونگی وجود دارد. در نتیجه تحلیل مؤلفه‌های اصلی دو بُعدی دو طرفه^۱ B2DPCA بیان شد [۱۳]–[۸]. روش‌های B2DPCA افزونگی بین سطرها و ستون‌های یک ماتریس را از بین می‌برند. مفهوم تحلیل مؤلفه‌های اصلی دو بُعدی دو طرفه براساس یک مفهوم در مراجع [۸–۱۱] به روش‌های گوناگون بیان شده است. مرجع [۱۲] را می‌توان تعمیم یافته سایر روش‌های پیشین تحلیل مؤلفه‌های اصلی دو بُعدی دانست در این الگوریتم به جای استفاده از نرم صفر، یک و یا دو که در روش‌های قبلی در تابع هدف و قید مسئله استفاده شده بودند، نرم P را بیان کرده است که سایر نرم‌ها زیر مجموعه نرم P قرار می‌گیرند و همچنین مرجع [۱۳] نیز از نرم هسته^۲ برای تعریف تابع هدف استفاده کرد.

در تحلیل مؤلفه‌های اصلی دو بُعدی دو طرفه، استخراج ویژگی‌های هر یک از تصاویر $X_i \in \mathbb{R}^{n \times m}$ ، توسط ماتریس انتقال چپ $R \in \mathbb{R}^{m \times r}$ ، $1 \leq r \leq n$ و ماتریس انتقال راست $L \in \mathbb{R}^{n \times h}$ ، $1 \leq h \leq m$ انجام می‌گیرد. ماتریس $Y_i \in \mathbb{R}^{h \times r}$ ماتریس استخراج ویژگی از هر تصویر است. شکل ۱ شماتیکی از نحوه عملکرد الگوریتم را نشان می‌دهد.

$$Y_i = L^T X_i R \quad (5)$$

برای محاسبه ماتریس انتقال راست R ، ماتریس کواریانس راست و برای محاسبه ماتریس انتقال چپ L ، ماتریس کواریانس چپ به صورت زیر محاسبه می‌شوند [۸–۱۱].

$$S^R = \frac{1}{k} \sum_{i=1}^k X_i X_i^T \quad (6)$$

$$S^L = \frac{1}{k} \sum_{i=1}^k X_i^T X_i \quad (7)$$

اثبات می‌شود که ستون‌های ماتریس R در ساده ترین حالت برابر بردارهای ویژه متناظر با بزرگترین مقادیر ویژه ماتریس S^R و همچنین ستون‌های ماتریس L بردارهای ویژه متناظر با بزرگترین مقادیر ویژه ماتریس S^L است [۸].

$$\begin{pmatrix} \dots & \dots & \dots \\ \dots & \dots & \dots \\ \dots & \dots & \dots \end{pmatrix} = \begin{pmatrix} \dots & \dots & \dots \\ \dots & \dots & \dots \\ \dots & \dots & \dots \end{pmatrix} \times \begin{pmatrix} \dots & \dots & \dots \\ \dots & \dots & \dots \\ \dots & \dots & \dots \end{pmatrix} \times \begin{pmatrix} \dots & \dots & \dots \\ \dots & \dots & \dots \\ \dots & \dots & \dots \end{pmatrix}$$

$Y_i^{h \times r} \quad L^{n \times h} \quad X_i^{n \times m} \quad R^{m \times r}$

شکل ۱: تحلیل مؤلفه‌های اصلی دو بُعدی دو طرفه.

در PCA و B2DPCA ضرایب استخراج شده برای انتقال داده‌ها به فضای جدید همگی غیر صفر بوده که عمل تحلیل بردار ویژگی استخراج شده را سخت کرده است. در نتیجه

^۱ Bidirectional Principle Component Analysis

^۲ Nuclear norm

^۳ Greedy algorithm

۳- ایده‌های پیشنهادی جهت کاهش افزونگی خام در یک مجموعه داده

۳-۱ حذف افزونگی خام از سیگنال‌های یک بعدی

در این قسمت ابتدا سیگنال‌های یک بعدی یک مجموعه به صورت بردار سطری نمایش داده شده و سپس در داخل ماتریس X به عنوان داده‌های خام قرار می‌گیرند. زمانی که ما از SPCA استفاده می‌کنیم همان‌طور که ذکر شد داده‌ها در فضای جدید به صورت $Y = XB$ مدل می‌شوند. بنا بر روابط می‌توان میزان تُنکی متفاوت به ستون‌های ماتریس انتقال B تحمیل نمود که محل آنان وابسته به ماهیت ماتریس داده‌های X می‌باشد. حال هرچه تعداد صف‌های موجود در یک سطر بیشتر باشد نشان‌دهنده‌ی این است که یک ستون از ماتریس داده‌ها (یک عضو با آدرس یکسان از هر بردار مشاهده) در انتقال به حوزه جدید نقش کمتری دارد. نکته قابل توجه این است که عضوهایی که در فضای جدید نقشی نداشته‌اند، در مرحله بازگشت توسط ماتریس A بازسازی می‌شوند. با توجه به این مفهوم می‌توان داده‌ها با اهمیت کمتر را تشخیص و از ابتدا از ماتریس داده‌های اصلی خام حذف کرده و باقی داده‌ها با تعداد کمتر را برای ادامه پردازش استفاده کرد.

جزئیات مراحل ایده پیشنهادی به این صورت است:

اول: ماتریس انتقال مورد نظر B با استفاده از الگوریتم SPCA به دست می‌آید (با استفاده از رابطه (۸) با ضرایب ثابت λ و λ_1). میزان تُنکی تحمیلی به هر ستون به دلخواه و بنا به کاربرد می‌تواند متغیر باشد.

دوم: تعداد صف‌های هر سطر از ماتریس B شمرده می‌شود که هر سطر از B نشان‌دهنده اهمیت هر ستون از ماتریس داده‌ها (عضوی با آدرس یکسان در هر بردار مشاهده) در انتقال به فضای جدید است.

سوم: به تعداد دلخواه ستون کم ارزش از ماتریس داده‌های خام حذف می‌شود. سپس بردارهای مشاهده کاهش یافته (نمونه برداری شده) را که شباهت ظاهری بسیاری به بردارهای اصلی دارند را می‌توان در کاربردهای دیگر استفاده کرد.

توجه کنید که در اینجا هیچ‌گونه فشردن سازی صورت نگرفته است و فقط درایه‌های بی‌اهمیت در آدرس مشخص را در تمامی سیگنال‌های مشاهدات مجموعه از همان ابتدا حذف می‌کنیم. همچنین هر چند که در اینجا از ماتریس B و A به طور مستقیم برای انتقال استفاده نمی‌کنیم، ولی لازم است تا این ماتریس‌ها شرایط بهینه را داشته باشند. در واقع صف‌های آنان در محل مناسب قرار گیرد. بدین دلیل برای بردارهای اولیه ماتریس B شرط تُنکی را در نظر نمی‌گیریم و برای بردارهای بعدی به ترتیب می‌توان میزان تُنکی را به تدریج بالا

$$\beta_j = \arg \min_{\hat{\beta}_j} (\alpha_j - \hat{\beta}_j)^T X^T X (\alpha_j - \hat{\beta}_j) + \lambda \|\hat{\beta}_j\|^2 + \lambda_{1,j} \|\hat{\beta}_j\|_1 \quad (9)$$

که در آن α_j ستون j ام از ماتریس A است. با توجه به رابطه (۹) مشاهده می‌شود که ماتریس ضرایب سازنده مؤلفه‌های اصلی، توسط ماتریس کواریانس ورودی محاسبه می‌شود. در نتیجه برای تحلیل مؤلفه‌های اصلی دو بُعدی دو طرفه تُنک، ماتریس کواریانس چپ S^L و راست S^R (روابط ۶ و ۷) محاسبه شده و مسئله الاستیکنت متناظر با آنان حل می‌شود [۲۱و۲۲]. با حل دو رابطه (۱۰ و ۱۱) بردارهای انتقال با ضرایب تُنک، در ماتریس‌های انتقال $L = [\beta_1^L, \beta_2^L, \dots, \beta_h^L]$ و $R = [\beta_1^R, \beta_2^R, \dots, \beta_h^R]$ حاصل می‌شود.

$$\beta_j^L = \arg \min_{\hat{\beta}_j} (\alpha_j^L - \hat{\beta}_j)^T S^L (\alpha_j^L - \hat{\beta}_j) + \lambda \|\hat{\beta}_j\|^2 + \lambda_{1,j} \|\hat{\beta}_j\|_1 \quad (10)$$


$$\beta_j^R = \arg \min_{\hat{\beta}_j} (\alpha_j^R - \hat{\beta}_j)^T S^R (\alpha_j^R - \hat{\beta}_j) + \lambda \|\hat{\beta}_j\|^2 + \lambda_{1,j} \|\hat{\beta}_j\|_1 \quad (11)$$

جهت آشنائی بیشتر با جزئیات محاسبات می‌توان به مرجع [۲۱] مراجعه نمود.

در سال ۲۰۱۶ در [۲۲] الگوریتم SLE^1 ارائه شد. این الگوریتم برای کاهش ابعاد سیگنال‌های یک بعدی مورد استفاده قرار می‌گیرد. در این الگوریتم ابتدا مشاهدات X یکبار توسط SPCA مورد کاهش ابعاد قرار می‌گیرند. سپس ماتریس همبستگی بین بردارهای انتقال یافته Y محاسبه و بنا بر آن ماتریس وزن دهی برای مشاهدات نزدیک هم به نام V نوشته شده و حال دوباره SPCA بر روی VYV^T اعمال می‌گردد. از آنجا که این الگوریتم دارای حجم محاسبات بیشتری بوده و مشاهدات اصلی X نیز از دسترس خارج می‌شود، الگوریتم ارائه شده برای آن قابل استفاده نمی‌باشد. هر چند ما از این الگوریتم برای ارزیابی توانایی طبقه بندی الگوریتم‌های پیشنهادی استفاده کرده ایم.

در بخش بعد، با بهره‌گیری از تحلیل مؤلفه‌های اصلی تُنک و مؤلفه‌های اصلی دو بُعدی دو طرفه تُنک، به کاهش حجم مجموعه‌های مختلف پرداخته خواهد شد.

¹ Spares Liner Embedding



د

شکل ۲: الف) مجموعه سیگنال‌های یک بُعدی (ب) تعداد صفرهای هر سطر ماتریس B (ج) بردارهای ویژه (د) سیگنال‌های یک بُعدی پس از حذف یک چهارم از متغیرها

اول: ماتریس‌های انتقال L و R با توجه به روابط ۱۱ و ۱۲ و با میزان تُنکی کافی در ستون‌های آنان محاسبه می‌شوند.

دوم: تعداد صفرهای هر سطر از ماتریس L و همچنین از ماتریس R شمرده می‌شوند.

سوم: با توجه به رابطه انتقال رابطه (۵) مشخص است که سطرهای ماتریس L بر روی هر سطر تصویر تاثیر مستقیم دارد و اگر یک سطر ماتریس L صفر شود (یا تعداد زیادی از مولفه‌های آن صفر باشند) مؤلفه‌های سطر متناظر با آن در ماتریس تصویر خام در انتقال به فضای جدید تاثیر کمتری خواهند داشت. به همین ترتیب اگر سطری از ماتریس R صفر باشد (یا تعداد زیادی از مولفه‌های آن صفر باشند) مؤلفه‌های متناظر با آن در ماتریس داده‌های خام تصویر نقشی در انتقال به فضای جدید نخواهد داشت. پس همانند قسمت قبل، صفرهای موجود در سطرهای ماتریس‌های انتقال را شمرده و سپس متناظر با سطرهایی از ماتریس L که بیشترین صفر را دارند سطرهای تصویر و متناظر با سطرهایی از ماتریس R که بیشترین صفر را در خود جای داده‌اند می‌توان ستون‌های تصویر را حذف کرد.

روند انجام فرآیند به صورت شماتیک در شکل ۳ آورده شده‌است. در واقع در اینجا می‌توانیم روش‌های موجود را به عنوان روش‌های نمونه برداری غیر یکنواخت در تصاویر نام ببریم که ظاهر تصاویر را نیز حفظ می‌نماید.

لازم به ذکر است که روش‌های بیان شده در بالا فقط به منظور حذف داده‌های خام بدون تاثیر در استخراج ویژگی در بین داده‌ها است و داده‌های جدید را می‌توان به عنوان ورودی به سایر الگوریتم‌های کاهش ابعاد و استخراج ویژگی دوباره اعمال کرد. در ادامه نتایج شبیه‌سازی‌ها به منظور ارزیابی الگوریتم‌های ارائه شده آمده است.

۴- نتایج شبیه سازی


در این بخش به منظور ارزیابی روش‌های ارائه شده نتایج دسته‌ای از آزمایشات آورده شده‌است. در واقع قصد ما آن است که نشان دهیم سیگنال‌های بدست آمده پس از حذف افزونگی‌ها، همچنان مانند سیگنال‌های اصلی کارایی خود را از

برد. (البته این امکان در جعبه ابزار متلب به نام Sparselab فراهم است) [۲۳].


به طور مثال به شکل ۲ توجه نمایید. در شکل ۲ الف) مجموعه ۲۱۰۲۵ سیگنال یک بُعدی با اندازه 1×200 و با متوسط صفر از یک مجموعه تصاویر هایپراسپکترال نشان داده شده‌اند. در شکل ۲ ب) تعداد صفرهای موجود در سطرهای ماتریس انتقال B نشان داده شده‌است. به طور مشخص بیشترین صفرها در مکان‌هایی اتفاق می‌افتد که مقادیر بردارهای موجود از مشاهدات دارای یکنواختی بوده و اطلاعات خاصی نداشته و قابل حذف از داده‌های خام می‌باشند. در شکل ۲ ج) نیز بردارهای ویژه غیر تُنک سیگنال‌ها دیده می‌شوند که به طور مشخص در همان مکانی که بردارهای ویژه دارای یکنواختی بیشتری هستند صفرها ظاهر می‌شوند. شکل ۲ د) نیز بردارهای مشاهدات اصلی را پس از حذف یک چهارم از داده‌های خام نشان می‌دهد. همانطور که مشاهده می‌گردد سیگنال‌های مشاهدات از نظر نمود ظاهری چندان تغییری نمانده‌اند.

۲-۳ حذف افزونگی خام از سطر و ستون‌های تصاویر یک مجموعه


نوآوری دیگر این پژوهش استفاده از مؤلفه‌های اصلی دوبُعدی دوطرفه تُنک (B2DSPCA) به منظور حذف افزونگی بین سطر و ستون‌های یک تصویر است. در این روش از ماتریس‌های تصاویر دو بُعدی یک مجموعه داده استفاده کرده و آنان را به بردار تبدیل نمی‌کنیم. جزییات ایده پیشنهادی به شرح زیر می‌باشد:



الف



ب



کنیم. باز شناسی و طبقه بندی نیز همچنان با KNN صورت می‌گیرد.

در آزمایشات سه مجموعه داده تصاویر صورت انسان Yale [۲۵] و ORL [۲۶] و مجموعه داده COIL20 [۲۷] مد نظر قرار گرفتند.

در مجموعه داده تصاویر صورت Yale، ۱۱ تصویر از ۱۵ نفر در شرایط مختلف تغییرات نور و حالت‌های مختلف چهره (تصویر با عینک، تصویر بدون عینک، حالت تعجب، حالت شگفت‌زده، حالت غمگین، حالت خوشحال، تصویر با چشم‌های بسته و ...) وجود دارد. در کل این مجموعه داده شامل ۱۶۵ تصویر با ابعاد 320×243 می‌باشد. لازم به ذکر است که در مرجع [۲۵] جهت بازشناسی بهتر تصاویر، تصاویر برش خورده به طور دستی نیز موجود می‌باشند.

مجموعه داده ORL شامل ۱۰ تصویر از ۴۰ نفر است که در زمان‌های مختلف، شرایط نوری و حالت‌های مختلف چهره گرفته شده‌است. این مجموعه در کل شامل ۴۰۰ تصویر با ابعاد 112×92 است.


مجموعه داده اشیا COIL20 شامل ۲۰ شیء مختلف و از هر شیء، ۷۲ تصویر در زوایای مختلف می‌باشد. این مجموعه داده در کل شامل ۱۴۴۰ تصویر با ابعاد 128×128 است. نمونه‌ای از تصاویر هر سه مجموعه در شکل ۴ آورده شده است.

جهت نمایش نتایج آزمایشات دسته اول، در شکل‌های ۵ و ۶ نمونه‌هایی از حذف افزونگی بین تصاویر در حالت یک‌بعدی آورده شده‌است. به طور مشخص مشاهده می‌شود که پیکسل‌های حذفی، از نقاط با اهمیت کمتر بوده‌است. در شکل ۵ نواحی پیشانی به عنوان نواحی با اهمیت کمتر شناخته شده و در شکل ۶ به خاطر وجود حاشیه در مجموعه تصاویر، حاشیه‌ها به عنوان نواحی با اهمیت کمتر شناخته شده‌اند.

در ادامه، سه آزمایش بر روی مجموعه Yale انجام شد. در ابتدا توسط روش بخش ۳-۱، در تصویر اصلی پیکسل‌های قابل حذف مشخص و به تعدادی حذف می‌شوند که پس از تبدیل به بردار به اندازه تصویر بُرش داده شده به صورت دستی برسند. سپس توسط الگوریتم SLE دوباره کاهش بُعد یافته و نرخ بازشناسی در ابعاد مختلف مقایسه شده‌است. نتایج به ازای تعداد مختلف بردارهای ویژگی مورد استفاده در شکل ۷ آورده شده‌است. در آزمایشی دیگر ابعاد تصاویر بُرش یافته به صورت خودکار را از تصویر بُرش یافته به صورت دستی کمتر کرده و نرخ بازشناسی مقایسه شده‌است. نتایج را می‌توان در شکل ۸ مشاهده کرد.

همه جهات حفظ کرده‌اند. آزمایشات در دو دسته صورت می‌گیرد.

در دسته اول برای حذف افزونگی‌ها از روش بخش ۳-۱ استفاده شده و در نتیجه تصاویر ابتدا به بردار یک بعدی تبدیل شده و سپس درایه‌هایی (پیکسل‌های تصاویر) با آدرس مشخص از تمامی مشاهدات حذف می‌شوند. تصاویر با برش دستی نیز به بردار یک بعدی تبدیل می‌شوند. سپس به ترتیب الگوریتم SLE^1 [۲۲] جهت کاهش ابعاد دوباره و الگوریتم نزدیکترین همسایگی (KNN^2) [۲۴] برای بازشناسی و دسته بندی بر روی هر دو گروه داده استفاده گردیده است.



شکل ۳: نحوه کار الگوریتم بُرش خودکار تصاویر در حالت دو بُعدی.

در دسته دوم، ماتریس‌های تصاویر توسط روش بخش ۳-۲ بُرش اتوماتیک یافته و ماتریس جدیدی حاصل می‌گردند که به همراه ماتریس‌های تصاویر بُرش خورده دستی به عنوان ورودی برای سایر الگوریتم‌های کاهش دهنده ابعاد قرار گرفته و نرخ بازشناسی آنان مقایسه می‌شود.




در این دسته آزمایشات که ورودی دو بعدی داریم از الگوریتم B2DPCA جهت کاهش دوباره ابعاد استفاده می‌

¹ Spares Liner Embedding

² K-Nearest Neighbors

در دسته دوم از آزمایش‌ها، تصاویر به صورت دوبعدی در نظر گرفته شده و از روش 2BDSPCA جهت حذف سطرها و ستون‌های کم اهمیت استفاده می‌شود. در واقع یک بُرش خودکار غیر یکنواخت به تصاویر داده شده‌است.


در شکل‌های ۹، ۱۰ و ۱۱ نمونه‌هایی از حذف افزونگی بین سطر و ستون مجموعه تصاویر در حالت دوبعدی آورده شده‌است. در شکل ۹ تصاویر خام ORL از اندازه 112×92 پس از برش غیر یکنواخت اتوماتیک به اندازه 60×50 تغییر یافته‌اند. در شکل ۱۰ تصاویر خام Yale از اندازه 320×243 پس از برش غیر یکنواخت اتوماتیک، به اندازه 121×160 کاهش یافته‌اند و در شکل ۱۱ نیز نمونه‌های تصاویر مجموعه اشیا از اندازه 128×128 پس از برش غیر یکنواخت اتوماتیک به اندازه 90×90 تبدیل شده‌اند. همانگونه که در تصاویر نیز دیده می‌شود با وجود کاهش اندازه بیش از ۵۰٪، تصاویر برش خورده و یا نمونه برداری شده غیر یکنواخت همچنان مشخص کننده ظاهر تصویر اصلی می‌باشند.



شکل ۹: مجموعه تصاویر ORL، سطر اول: تصاویر اصلی، سطر دوم: سطر و ستون‌های کم اهمیت که باید حذف شوند، سطر سوم: تصاویر پس از حذف سطر و ستون‌های مشخص شده در سطر دوم.




شکل ۱۰: مجموعه تصاویر Yale، سطر اول: تصاویر اصلی، سطر دوم: سطر و ستون‌های کم اهمیت که باید حذف شوند، سطر سوم: تصاویر پس از حذف سطر و ستون‌های مشخص شده در سطر دوم، سطر چهارم: تصاویر برش خورده دستی از [۲۵].




شکل ۵: تصاویر مربوط به مجموعه داده ORL، 120 پیکسل از هر تصویر با ابعاد 112×92 قابل حذف می‌باشند.



شکل ۶: تصاویر مربوط به مجموعه Yale، تعداد 1000 پیکسل از تصاویر با ابعاد 150×150 قابل حذف می‌باشند.




شکل ۷: بازشناسی توسط الگوریتم SLE، تصاویر در حالت برش دستی و اتوماتیک به صورت بردارهای 1×1000 از مجموعه Yale می‌باشند. شش تصویر به عنوان داده آموزشی استفاده شده‌است.




شکل ۸: بازشناسی توسط الگوریتم SLE، تصاویر در حالت برش دستی به صورت بردارهای 1×1000 و در حالت برش اتوماتیک به صورت بردارهای 1×240 از مجموعه Yale می‌باشند. پنج تصویر به عنوان داده آموزشی استفاده شده‌است.

تصویر به عنوان داده ارزیابی مورد استفاده قرار گرفته است. با وجود اینکه ابعاد تصاویر در حالت برش خودکار از برش دستی کمتر شده است مشاهده می‌شود که نرخ بازشناسی در ماتریس‌های ویژگی با ابعاد متفاوت همچنان بهبود یافته است. به طور مثال در ماتریس ویژگی در ابعاد 22×22 نرخ بازشناسی در حالت برش دستی $35,58$ و در برش خودکار 60 درصد است. که بیانگر بهبود نرخ بازشناسی 25 درصدی است.


در شکل ۱۲ نتایج شبیه سازی بیشترین نرخ بازشناسی ممکن در مجموعه تصاویر Yale، توسط الگوریتم B2DPCA، که در اندازه‌های مختلف به دو روش دستی و خودکار برش یافته‌اند، آورده شده است. مشاهده می‌شود که نرخ بازشناسی در حالت‌های مختلف بهبود یافته است و همچنین تصاویر در سایز 65×65 تا 75×75 نرخ بازشناسی مناسبی داشته‌اند که در مقایسه با حالات برش دستی به طور میانگین در این بازه 15 درصد بهبود نرخ بازشناسی رخ داده است.



شکل ۱۲: بیشینه نرخ بازشناسی توسط الگوریتم B2DPCA، تصاویر به صورت دستی و خودکار در اندازه‌های یکسان برش خورده‌اند. شش تصویر از مجموعه Yale به عنوان داده آموزشی استفاده شده است.



شکل ۱۳: نرخ بازشناسی توسط الگوریتم B2DPCA به ازای ماتریس ویژگی در ابعاد 17×6 ، تصاویر به صورت دستی و خودکار در سایزهای یکسان برش خورده‌اند. شش تصویر از مجموعه Yale به عنوان داده آموزشی استفاده شده است.



شکل ۱۱: مجموعه تصاویر coil20، سطر اول: تصاویر اصلی، سطر دوم: سطر و ستون‌های کم اهمیت که باید حذف شوند، سطر سوم: تصاویر پس از حذف سطر و ستون‌های مشخص شده در سطر دوم.

جهت ارزیابی کارایی روش پیشنهادی، تصاویر اصل Yale، یک بار به صورت دستی (یادآوری می‌شود که برش دستی این تصاویر در مرجع [۲۵] موجود می‌باشند) و بار دیگر به صورت خودکار برش خورده و نتایج بازشناسی با تعداد بردارهای ویژگی مختلف مقایسه شده است. همان‌طور که انتظار می‌رفت در برش خودکار کلیات تصویر حفظ شده و قابل توجه است که در حالت برش به صورت دستی در اکثر اوقات گوش‌ها و موها حذف می‌شوند ولی با استفاده از الگوریتم ارائه شده این نواحی حفظ شده‌اند (شکل ۱۰).

در جدول ۱ نتایج شبیه سازی بازشناسی توسط الگوریتم B2DPCA برای تصاویر برش‌یافته خودکار و برش‌یافته به صورت دستی در مجموعه Yale مقایسه شده است. ابعاد تصویر از 243×32 به 100×100 رسیده است (در هر دو حالت دستی و خودکار). در این آزمایش پنج تصویر از هر فرد به عنوان داده آموزشی و شش تصویر دیگر آن به عنوان داده ارزیابی مورد استفاده قرار گرفته است. به منظور طبقه بندی از الگوریتم نزدیک ترین همسایگی استفاده شده است [۲۴]. هر سلول از جدول بیانگر نرخ بازشناسی به ازای ماتریس ویژگی با ابعاد $LD \times RD$ است که در سمت چپ و بالای جدول مشخص شده‌اند. مشاهده می‌شود که نرخ بازشناسی تقریباً به ازای تمام ماتریس‌های ویژگی با ابعاد متفاوت، بهبود یافته است. به طور مثال بیشترین مقدار نرخ بازشناسی در حالت برش دستی 80 درصد بوده است در صورتی که در برش اتوماتیک نرخ $85,56$ است. در ماتریس ویژگی با ابعاد 22×3 نرخ بازشناسی در حالت برش دستی $35,58$ و در حالت برش خودکار $65,66$ است که بیانگر بهبود نرخ بازشناسی 30 درصدی است.

در ادامه آزمایش‌ها، ابعاد تصاویر به صورت برش‌یافته خودکار را از ابعاد تصاویر برش‌یافته به صورت دستی کمتر کرده و نرخ بازشناسی مقایسه شده است. در جدول ۲، ابعاد تصاویر برش‌یافته به صورت خودکار به 60×40 رسیده و با تصاویر برش‌یافته به صورت دستی در اندازه 100×100 مقایسه شده است. در این آزمایش پنج تصویر به عنوان داده آموزشی و شش

حذف می شوند از آنجا که داده های حذف شده، افزودگی های موجود در تصاویر خام بوده اند که کمکی به ادامه پردازش نمی نمایند تأثیر منفی در روند ادامه کار ندارند. در واقع با این روش، ما سطر ها و ستون های دارای مشخصه متمایز کننده تصاویر را حفظ می کنیم و به این دلیل ظاهر تصاویر نیز حفظ می شوند.

همچنین در شکل ۱۳ نرخ بازشناسی توسط آلوگوریتیم B2DPCA به ازای ثابت نگاه داشتن ماتریس ویژگی استخراج شده با ابعاد 17×6 و تصاویر با اندازه های مختلف آورده شده است. مشاهده می شود با اینکه ابعاد ماتریس ویژگی نسبتاً کوچک انتخاب شده است، در حالت برش خودکار تصاویر، همچنان نرخ بازشناسی خوبی حاصل می شود.


همانگونه که در آزمایشات دیده می شود با وجود آنکه در روش نمونه برداری غیر یکنواخت پیشنهادی، درصد بالایی از داده ها

جدول ۱: نرخ بازشناسی توسط آلوگوریتیم B2DPCA بر روی مجموعه داده Yale (اندازه تصاویر برش داده شده به صورت خودکار و برش یافته به صورت دستی برابر شده) (RD = Right Dimension, LD = Left Dimension) *

RD	۲		۴		۶		۸		۱۶		۲۲		۳۲	
LD	برش دستی	برش خودکار	برش دستی	برش خودکار	برش دستی	برش خودکار	برش دستی	برش خودکار	برش دستی	برش خودکار	برش دستی	برش خودکار	برش دستی	برش خودکار
۲	۴۰,۰۰	۵۸,۸۹	۵۳,۳۳	۷۴,۴۴	۴۵,۵۶	۵۵,۵۶	۴۴,۴۴	۵۸,۸۹	۴۶,۶۷	۵۳,۳۳	۴۷,۸۸	۵۳,۳۳	۴۳,۳۳	۵۳,۳۳
۴	۴۱,۱۱	۶۱,۱۱	۶۲,۲۲	۷۷,۷۸	۶۵,۵۸	۷۲,۲۲	۶۸,۸۹	۷۴,۴۴	۷۱,۱۱	۷۲,۲۲	۶۷,۷۸	۷۴,۴۴	۶۷,۷۷	۷۴,۴۴
۶	۳۷,۷۸	۶۰,۰۰	۶۶,۶۷	۷۴,۴۴	۶۸,۸۹	۷۷,۷۸	۷۱,۱۱	۷۷,۷۸	۷۲,۲۲	۷۵,۵۶	۷۴,۴۴	۷۷,۷۸	۷۴,۴۴	۷۷,۷۸
۸	۳۶,۶۷	۶۵,۵۶	۶۵,۵۶	۷۷,۷۸	۷۲,۲۲	۷۸,۸۹	۷۵,۵۶	۸۱,۱۱	۸۱,۱۱	۸۳,۳۳	۸۰,۰۰	۷۶,۶۷	۷۷,۷۸	۸۱,۱۱
۱۶	۳۶,۶۷	۶۳,۳۳	۶۷,۷۸	۷۷,۷۸	۷۳,۳۳	۷۷,۷۸	۷۸,۸۹	۸۱,۱۱	۷۸,۸۹	۸۳,۳۳	۸۰,۰۰	۸۵,۵۶	۷۸,۸۹	۸۱,۱۱
۲۲	۳۵,۵۸	۶۵,۵۶	۶۳,۳۳	۷۴,۴۲	۷۱,۱۱	۷۸,۸۹	۷۸,۸۹	۸۳,۳۳	۷۶,۶۷	۸۰,۰۰	۸۰,۰۰	۸۵,۵۶	۷۷,۷۸	۸۰,۰۰
۳۲	۳۷,۷۸	۶۳,۳۳	۶۱,۱۱	۷۴,۴۴	۷۰,۰۰	۷۷,۷۸	۷۷,۷۸	۸۳,۳۳	۸۰,۰۰	۸۰,۰۰	۸۳,۳۳	۸۳,۳۳	۷۷,۷۸	۸۱,۱۱

جدول ۲: نرخ بازشناسی توسط آلوگوریتیم B2DPCA بر روی مجموعه داده Yale (اندازه تصاویر برش داده شده به صورت خودکار کوچکتر از برش داده شده به صورت دستی)


RD	۲		۴		۶		۸		۱۶		۲۲		۳۲	
LD	برش دستی	برش خودکار	برش دستی	برش خودکار	برش دستی	برش خودکار	برش دستی	برش خودکار	برش دستی	برش خودکار	برش دستی	برش خودکار	برش دستی	برش خودکار
۲	۴۰,۰۰	۵۳,۳۳	۵۳,۳۳	۶۴,۴۴	۴۵,۵۶	۶۳,۳۳	۴۴,۴۴	۶۱,۱۱	۴۶,۶۷	۶۱,۱۱	۴۷,۸۸	۶۱,۱۱	۴۳,۳۳	۶۱,۱۱
۴	۴۱,۱۱	۶۲,۲۲	۶۲,۲۲	۷۴,۴۴	۶۵,۵۸	۷۳,۳۳	۶۸,۸۹	۷۳,۳۳	۷۱,۱۱	۷۳,۳۳	۶۷,۷۸	۷۴,۴۴	۶۷,۷۷	۷۴,۴۴
۶	۳۷,۷۸	۶۱,۱۱	۶۶,۶۷	۷۴,۴۴	۶۸,۸۹	۷۶,۶۷	۷۱,۱۱	۸۰,۰۰	۷۲,۲۲	۸۱,۱۱	۷۴,۴۴	۷۳,۳۳	۷۴,۴۴	۷۶,۶۶
۸	۳۶,۶۷	۵۸,۵۹	۶۵,۵۶	۸۰,۰۰	۸۰,۰۰	۷۸,۸۹	۷۵,۵۶	۸۱,۱۱	۸۱,۱۱	۸۱,۱۱	۸۰,۰۰	۷۵,۵۶	۷۷,۷۸	۷۶,۶۶
۱۶	۳۶,۶۷	۵۸,۵۹	۶۷,۷۸	۷۴,۴۴	۷۳,۳۳	۷۸,۸۹	۷۸,۸۹	۸۱,۱۱	۷۸,۸۹	۸۰,۰۰	۸۰,۰۰	۸۱,۱۱	۷۸,۸۹	۸۰,۰۰
۲۲	۳۵,۵۸	۶۰,۰۰	۶۳,۳۳	۷۴,۴۴	۷۱,۱۱	۸۰,۰۰	۷۸,۸۹	۸۳,۳۳	۷۶,۶۷	۷۸,۸۹	۸۰,۰۰	۸۲,۲۲	۷۷,۷۸	۷۸,۸۹
۳۲	۳۷,۷۸	۶۱,۱۱	۶۱,۱۱	۷۳,۳۳	۷۰,۰۰	۸۱,۱۱	۸۰,۰۰	۸۳,۳۳	۷۷,۷۸	۷۷,۷۸	۸۳,۳۳	۸۲,۲۲	۷۷,۷۸	۷۸,۸۹




شکل ۴: مجموعه داده های استفاده شده: سطر اول) مجموعه داده Yale، سطر دوم) مجموعه داده ORL، سطر سوم و چهارم) مجموعه داده COIL20

تمامی آزمایشات نشانگر آن است که الگوریتم ارائه شده توانایی برش و حذف افزونگی داده‌های خام را از مکان‌های مختلف تصویر به خوبی دارا بوده و توانایی بازشناسی را به خوبی برآورده می‌سازد. همچنین به دلیل کاهش حجم داده‌های موجود، توانایی بازشناسی حتی دقیق‌تر و با استفاده از تعداد کمتر بردارهای ویژگی و در نتیجه حجم محاسبات کمتر صورت می‌گیرد.


در شکل ۱۷ نتایج بازشناسی تصاویر ORL که با استفاده از الگوریتم برش خودکار و دستی در اندازه‌های یکسان برش خورده و سپس به بردار تبدیل شده‌اند، و سپس با الگوریتم کاهش ابعاد SLE و طبقه‌بندی KNN بازشناسی شده‌اند، نشان داده شده است. در این آزمایش تعداد بردارهای ویژگی مورد استفاده، تعداد ۴۵ در همه موارد ثابت نگاه داشته شده است. مشاهده می‌شود که نرخ بازشناسی در تصاویر با اندازه‌های مختلف بهبود یافته است. البته واضح است که در اندازه‌هایی که به تصویر اصلی نزدیک می‌شود نرخ بازشناسی به اشباع و بالاترین حد ممکن رسیده و در دو حالت برهم منطبق می‌شود.




در ادامه به منظور ارزیابی بیشتر، ابتدا تصاویر به صورت دستی و سپس توسط سیستم برش اتوماتیک سطر و ستون (مطابق ایده بخش ۳-۲) برش می‌یابند. بعد از چیدمان به صورت برداری به عنوان ورودی الگوریتم SLE قرار گرفته و نرخ بازشناسی به ازای تعداد مختلف بردارهای ویژگی با الگوریتم KNN مقایسه شده‌اند. نتایج شبیه سازی در شکل‌های ۱۴، ۱۵ و ۱۶ آورده شده است.



شکل ۱۴: بازشناسی توسط الگوریتم SLE، در مجموعه Yale اندازه تصاویر برش‌یافته به صورت دستی از 100×100 به صورت اتوماتیک به 70×70 ، رسانده شده است. هفت تصویر به عنوان داده آموزشی مورد استفاده قرار گرفته است.



شکل ۱۶: بازشناسی توسط الگوریتم SLE، در مجموعه COIL20 اندازه تصاویر برش‌یافته به صورت دستی از 128×128 به صورت اتوماتیک به 90×90 رسانده شده است. ده تصویر به عنوان داده آموزشی مورد استفاده قرار گرفته است.



شکل ۱۷: نرخ بازشناسی توسط الگوریتم SLE به ازای ۴۵ بردار ویژگی ثابت، تصاویر به صورت دستی و خودکار در اندازه‌های یکسان برش خورده‌اند. شش تصویر از مجموعه ORL به عنوان داده آموزشی استفاده شده است.

شکل ۱۵: بازشناسی توسط الگوریتم SLE، در مجموعه ORL اندازه تصاویر برش‌یافته به صورت دستی از 112×92 به صورت اتوماتیک به 80×70 رسانده شده است. شش تصویر به عنوان داده آموزشی مورد استفاده قرار گرفته است.

در برش تصاویر به صورت دستی تنها نواحی اطراف تصاویر حذف می‌شوند و همچنین امکان خطای انسانی نیز وجود دارد ولی با استفاده از الگوریتم برش خودکار، امکان بروز خطای انسانی کاهش یافته و این قابلیت وجود دارد که نواحی با اهمیت کمتر را در مکان‌های مختلف تصویر تشخیص و حذف کرده و در نتیجه به نرخ بازشناسی بهتر دست پیدا خواهیم کرد.

در آزمایش‌های انجام شده برای محاسبه نرخ بازشناسی، داده‌های آموزشی به صورت تصادفی انتخاب و آزمایش‌ها ده بار تکرار شده است و متوسط نرخ بازشناسی بیان شده است.

- [۳] H. Zou, T. Hastie, and R. Tibshirani, "Sparse Principal Component Analysis," *J. Comput. Graph. Stat.*, vol. 15, no. 2, pp. 265–286, 2006.
- [۴] C. Ding and Y. Jieping, "2-Dimensional Singular Value Decomposition for 2D Maps and Images," *Society Ind. Appl. Math.*, pp. 32–43, 2005.
- [۵] W. Yang, C. Sun, and K. Ricanek, "Sequential Row-Column 2DPCA for face recognition," *Neural Comput. Appl.*, vol. 21, no. 7, pp. 1729–1735, 2012.
- [۶] R. Janardan, "GPCA: An Efficient Dimension Reduction Scheme for Image Compression and Retrieval," *International Conference on Knowledge Discovery and Data Mining*, pp. 354–363, 2004.
- [۷] J. Yang, D. Zhang, A. F. Frangi, and J. Y. Yang, "Two-Dimensional PCA: A New Approach to Appearance-Based Face Representation and Recognition," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 26, no. 1, pp. 131–137, 2004.
- [۸] W. Zuo, D. Zhang, and K. Wang, "Bidirectional PCA with assembled matrix distance metric for image recognition," *IEEE Trans. Syst. Man, Cybern. Part B Cybern.*, vol. 36, no. 4, pp. 863–872, 2006.
- [۹] J. Yang and C. Liu, "Horizontal and vertical 2DPCA-based discriminant analysis for face verification on a large-scale database," *IEEE Trans. Inf. Forensics Secur.*, vol. 2, no. 4, pp. 781–792, 2007.
- [۱۰] H. Kong, L. Wang, E. K. Teoh, X. Li, J. G. Wang, and R. Venkateswarlu, "Generalized 2D principal component analysis for face image representation and recognition," *Neural Networks*, vol. 18, no. 5–6, pp. 585–594, 2005.
- [۱۱] D. Zhang and Z. H. Zhou, "(2D)2 PCA: Two-directional two-dimensional PCA for efficient face representation and recognition," *Neurocomputing*, vol. 69, no. 1–3, pp. 224–231, 2005.
- [۱۲] J. Wang, "Generalized 2-D Principal Component Analysis by Lp-Norm for Image Analysis," *IEEE Trans. Cybern.*, vol. 46, no. 3, pp. 792–803, 2016.
- [۱۳] F. Zhang, J. Yang, J. Qian, and Y. Xu, "Nuclear Norm-Based 2-DPCA for Extracting Features From Images," *IEEE Trans. Neural Networks Learn. Syst.*, vol. 26, no. 10, pp. 2247–2260, 2015.
- [۱۴] M. B. Richman, "Rotation of principal components," *J. Climatol.*, vol. 6, no. 3, pp. 293–335, 1985.
- [۱۵] H. Shen and J. Z. Huang, "Sparse principal component analysis via regularized low rank matrix approximation," *J. Multivar. Anal.*, vol. 99, no. 6, pp. 1015–1034, Jul. 2008.
- [۱۶] A. d'Aspremont, F. Bach, and L. El Ghaoui, "Optimal Solutions for Sparse Principal Component Analysis," *J. Mach. Learn. Res.*, 9, pp. 1269–1294, Jul. 2008.
- [۱۷] B. Moghaddam, Y. Weiss, and S. Avidan, "Spectral Bounds for Sparse PCA: Exact and Greedy Algorithms," in *Advances in Neural Information Processing Systems 18*, 2005, pp. 915–922.
- [۱۸] J. Cadima and I. T. Jolliffe, "Loading and correlations in the interpretation of principle components," *J. Appl. Stat.*, vol. 22, no. 2, pp. 203–214, Jan. 1995.
- [۱۹] I. T. Jolliffe, N. T. Trendafilov, and M. Uddin, "A Modified Principal Component Technique Based on

در مورد ایده پیشنهادی، زمان اجرای الگوریتم منحصر به یافتن ماتریس کوواریانس (در حالت های یک بعدی و دو بعدی) و سپس محاسبه ماتریس T_k تک پایه های انتقال می گردد. بدیهی است که هر چه تعداد مشاهدات موجود در دیتابیس بیشتر باشد و همچنین بردار یا ماتریس هر مشاهده بزرگتر باشد، زمان محاسبه بیشتری می طلبد. به طور مثال برای مجموعه تصاویر *ORL* در حالت یک بعدی که مشاهدات بردارهای با اندازه 1×10304 می باشند ابتدا ماتریس کوواریانس در اندازه 10304×10304 و سپس ماتریس انتقال با 30 بردار پایه محاسبه شدند که زمان اجرای آن $1/448$ ثانیه بود. در حالت دو بعدی دو ماتریس کوواریانس چپ و راست در اندازه های 92×92 و 112×112 و سپس دو ماتریس انتقال T_k و L در اندازه های 112×112 و 92×92 در زمان $0/8$ ثانیه اجرا گردید.

۵ - نتیجه گیری

باتوجه به این نکته که ساختار T_k مؤلفه های اصلی قابلیت توصیف متغیرها را فراهم کرده اند و همچنین بسیاری از داده ها در انتقال به فضای جدید نقشی نخواهند داشت و یا نقش کمتری دارند، یک الگوریتم برای حذف افزونگی بین پیکسل های خام مجموعه تصاویر و دیگری به منظور حذف افزونگی خام از مجموعه سطر و ستون های مجموعه تصاویر ارائه شد.

با استفاده از این الگوریتم ها اندازه داده های خام را کاهش داده و افزونگی بین داده ها را از بین برده و در پایان به منظور ارزیابی الگوریتم های ارائه شده با استفاده از سه مجموعه *ORL*، *Yale* و *COIL20* آزمایش هایی صورت گرفت. آزمایش ها به دو صورت مختلف انجام شد. یک) نرخ بازشناسی تصاویر بُرش یافته به صورت دستی و خودکار با ابعاد یکسان مقایسه شد. دو) نرخ بازشناسی تصاویر بُرش یافته به صورت خودکار با اندازه کوچکتر از تصاویر بُرش یافته به صورت دستی مقایسه شد. با توجه به نتایج شبیه سازی ها می توان نتیجه گرفت که الگوریتم های بیان شده به خوبی توانسته اند ویژگی های مطلوب داده های خام را حفظ و استخراج کنند همچنین هم زمان به دلیل اجتناب از محاسبات اضافی، نرخ بازشناسی بالاتر و سریعتری در اختیار می گذارند.

۶-مراجع

- [۱] H. Abdi and L. J. Williams, "Principal component analysis," *Wiley Interdiscip. Rev. Comput. Stat.*, vol. 2, no. 4, pp. 433–459, Jul. 2010.
- [۲] I. T. Jolliffe, *Principal Component Analysis, Second Edition*, vol. 30, no. 3. 2002.



علی‌اصغر شریفی نجف‌آبادی مدرک کارشناسی خود را در رشته مهندسی برق با گرایش مخابرات در سال ۱۳۹۴ از دانشگاه اراک و کارشناسی ارشد خود را در رشته مهندسی برق گرایش مخابرات - سیستم در سال ۱۳۹۶ از دانشگاه شهید بهشتی کسب نمود. ایشان از سال ۱۳۹۴ در آزمایشگاه رادیو

آگاه (Cognitive Radio) و از سال ۱۳۹۵ در آزمایشگاه پردازش سیگنال‌های دیجیتال (DiSPLaY) دانشگاه شهید بهشتی تاکنون به عنوان پژوهشگر فعالیت‌های پژوهشی دارند. علاقه‌مندی‌های علمی ایشان شامل پردازش سیگنال، پردازش تصویر و یادگیری ماشین است.



فرح ترکمنی‌آذر مدرک کارشناسی و کارشناسی ارشد خود را به ترتیب در رشته مهندسی برق گرایش الکترونیک از دانشگاه صنعتی امیرکبیر و گرایش مخابرات از دانشگاه صنعتی اصفهان دریافت نمود. سپس ایشان دکتری خود را در استرالیا در زمینه پردازش تصویر با استفاده از شبکه‌های عصبی

در سال ۱۳۷۴ از دانشگاه New South Wales اخذ کرد. از سال ۱۳۷۴ در دانشگاه صنعتی اصفهان و از سال ۱۳۸۰ در دانشگاه شهید بهشتی به عنوان عضو هیئت علمی مشغول به فعالیت می‌باشد. علاقه‌مندی‌های علمی ایشان پردازش سیگنال‌ها و تصاویر دیجیتال است.

the LASSO," J. Comput. Graph. Stat., vol. 12, no. 3, pp. 531-547, Sep. 2003.

- [۲۰] H. Zou and T. Hastie, "Regularization and variable selection via the elastic net," J. R. Stat. Soc. vol. 67, pp. 301-320, 2005.

[۲۱] یک‌کلام، زهرا، ترکمنی‌آذر، فرح. 'کاهش حجم ذخیره‌سازی تصاویر با استفاده از تحلیل مؤلفه‌های اصلی دو بعدی تُنک، مجله ماشین بینایی و پردازش تصویر، دوره ۴، شماره ۱، ص ۵۷ تا ۶۹، ۱۳۹۶.

- [۲۲] Z. Lai, W. K. Wong, Y. Xu, J. Yang, and D. Zhang, "Approximate Orthogonal Sparse Embedding for Dimensionality Reduction," IEEE Trans. Neural Networks Learn. Syst., vol. 27, no. 4, pp. 723-735, 2016.

- [۲۳] D. Donoho, V. Stodden, Y. Tsaig et al., "Sparselab," SparseLab: Seeking Sparse Solutions to Linear Systems of Equations, SparseLab toolbox shared online, <http://sparselab.stanford.edu/>, 24th August, 2007

- [۲۴] Larose, Daniel T. "K - nearest neighbor algorithm." Discovering Knowledge in Data: An Introduction to Data Mining (2005): 90-106.

- [۲۵] Available on: <http://vision.ucsd.edu/content/yale-face-database>

- [۲۶] Samaria, Ferdinando S., and Andy C. Harter. "Parameterisation of a stochastic model for human face identification." Applications of Computer Vision, 1994., Proceedings of the Second IEEE Workshop on. IEEE, 1994.

- [۲۷] Available on: <http://www.cs.columbia.edu/CAVE/software/softlib/col-20.php>.