

رویکرد ترکیبی ژنتیک در انتخاب ویژگی‌های صورت برای بازشناسی خودکار چهره*

ندا پورقنبر کلیبر¹

دانشجوی کارشناسی ارشد مهندسی برق - مخابرات، دانشکده مهندسی برق و مخابرات، دانشگاه آزاد اسلامی اهر، اهر

N-pourghanbarkalaibar@iau-ahar.ac.ir

سعید مشگینی²

استادیار، دانشکده مهندسی برق - مخابرات، دانشگاه تبریز، تبریز

meshgini@tabrizu.ac.ir

چکیده

موضوع بازشناسی چهره اساساً یکی از مسائل چالش برانگیز در حوزه مباحث مرتبط با پردازش تصویر و بینایی کامپیوتر در عصر حاضر بوده است و کاربردهای فراوان و کلیدی آن در حوزه‌های مختلف باعث توجه بیش از پیش به این موضوع در سالهای اخیر گردیده است. در این مقاله، تکنیک انتخاب و ادغام ویژگی جدیدی برای تشخیص چهره ارائه شده است. در تکنیک پیشنهادی از الگوریتم ژنتیک برای انتخاب ویژگی و از شبکه عصبی مصنوعی برای طبقه‌بندی استفاده شد. تکنیک ارائه شده در یک مجموعه ویژگی جداگانه از هر منطقه صورت و مقایسه آن با مجموعه ویژگی ترکیبی مورد آزمایش قرار گرفته است. مساله انتخاب زیرمجموعه ویژگی‌ها، به مفهوم شناسایی و انتخاب یک زیرمجموعه مفید از ویژگی‌ها از میان مجموعه داده اولیه می‌باشد. آزمایش‌ها و پیاده‌سازی روی مجموعه تصاویر پایگاه داده *FERET* و *ORL* نشان دادند که با افزایش تعداد ویژگی‌های زیرمجموعه انتخاب شده، درصد شناسایی نیز افزایش می‌یابد. با این توصیف روش پیشنهادی خیلی سریع به راه-حل‌های بهینه همگرا می‌شود و همچنین توانایی زیادی در جستجوی فضای راه‌حل‌ها دارد و می‌تواند کوچکترین زیرمجموعه از ویژگی‌ها را پیدا کند که این پروسه در نتیجه استفاده از *PCA* و ترکیب با الگوریتم ژنتیک می‌باشد که موجب بهبود نتایج شناسایی تصاویر تا بالای 98 درصد صحت داده شده است.

واژگان کلیدی: مولفه‌های اساسی، الگوریتم ژنتیک، کاهش ابعاد، بهینه‌سازی، استخراج ویژگی.

1- مقدمه

سیستم بازشناسی چهره یک برنامه کامپیوتری به صورت خودکار برای شناسایی یا تصدیق شخص از یک عکس دیجیتالی یا ویدئو از منابع ویدئویی است. یکی از راه‌های انجام این کار مقایسه ویژگی‌های انتخاب شده از تصویر چهره با پایگاه داده موجود می‌باشد. این روش به طور معمول در سیستم‌های امنیتی استفاده می‌شود و می‌تواند با زیست‌سنج‌های شناخته شده دیگر مانند اثر انگشت یا عنبیه چشم ترکیب شود. انسان معمولاً از چهره برای شناسایی اشخاص استفاده می‌کند. پیشرفت در توانایی محاسباتی در دهه‌های گذشته این امکان را بوجود آورده است که بازشناسی چهره به صورت خودکار انجام شود. الگوریتم‌های

ابتدایی بازشناسی چهره از مدل‌های هندسی استفاده می‌کردند، اما امروزه فرآیندهای بازشناسی از مدل‌های پیچیده ریاضی برای استخراج ویژگی و انطباق استفاده می‌کنند. پیشرفت‌های عمده در ده تا پانزده سال گذشته باعث پیشرفت تکنولوژی بازشناسی چهره شده‌اند. الگوریتم‌های بازشناسی چهره می‌تواند برای تصدیق و یا شناسایی چهره استفاده شود (Etemad and Chellappa, 1997). هدف اصلی این پژوهش ارائه یک سیستم شناسایی مبتنی بر روش **PCA** به کمک الگوریتم ژنتیک برای تشخیص بازشناسی چهره است. یکی از موفق‌ترین تکنیک‌ها که در تشخیص چهره مورد استفاده قرار گرفته تحلیل مولفه‌های اصلی^۱ می‌باشد. از جمله مزایای این روش سادگی اعمال و استفاده از آن، سطح کارایی قابل قبول و تاثیر مثبت آن در پایگاه-های داده‌های بزرگ می‌باشد. بنابراین، بسیاری از محققان بر روی بهبود این روش متمرکز شده‌اند. برخی از مطالعات نیز به مساله انتخاب بهترین بردارهای ویژه پرداخته‌اند که کارایی **PCA** را با حذف بردارهای ویژه نویزها و نیز کاهش زمان (با استفاده از فشرده‌سازی تصویر) افزایش داده و بهبود می‌بخشند. با بازبینی داده‌های آموزش با استفاده از روش **PCA** می‌توان جهات مختلفی را برای بردارهای ویژه به دست آورد. سپس از روی این بردارهای ویژه متفاوت می‌توان بردارهایی را که دارای فضای مجازی بهینه هستند برای شناسایی انتخاب نمود. در نتیجه با مستثنی کردن برخی از تصاویر داده‌های آموزش موجود می‌توان سیستم تشخیص چهره را بهبود بخشید. لذا در پژوهش حاضر متدی معرفی می‌کنیم که در آن از الگوریتم ژنتیک در بهینه‌سازی مولفه‌های اساسی به منظور جستجوی مناسب‌ترین داده برای آموزش الگوریتم از میان داده‌های موجود در امر بازشناسی چهره استفاده شده است. در این پژوهش، تکنیک انتخاب و ادغام ویژگی جدیدی برای تشخیص چهره ارائه شده است. در تکنیک پیشنهادی از الگوریتم ژنتیک (**GA**) برای انتخاب ویژگی و از شبکه عصبی مصنوعی^۲ برای طبقه‌بندی استفاده شد. تکنیک ارائه شده در یک مجموعه ویژگی جداگانه از هر منطقه صورت و مقایسه آن با مجموعه ویژگی ترکیبی مورد آزمایش قرار می‌گیرد. دو زیر مجموعه از مجموعه داده‌های پایگاه داده **FERET** و **ORI** نیز برای آزمون مورد استفاده قرار خواهند گرفت.

2- مروری بر پیشینه تحقیق

در دهه گذشته، تشخیص چهره به یکی از فعال‌ترین زمینه‌های پژوهشی الگوی شناختی تبدیل شده است. رایج‌ترین روش‌های تشخیص چهره را می‌توان به سادگی در سه دسته تطبیق مبتنی بر ویژگی‌های همه جانبه^۳، روش تطبیق مبتنی بر ویژگی‌های موضعی^۴ و روش تطبیق چندگانه^۵ طبقه‌بندی کرد (Gumus et al, 2010). در روش تطبیق مبتنی بر ویژگی‌های همه جانبه، از کل منطقه صورت به عنوان ورودی خام به سیستم تشخیص استفاده می‌شود، مانند روش آنالیز اجزای اصلی^۶. همچنین اخیراً روش **IGF**^۷ یا روش مبتنی بر مدل **KAM**^۸ نیز جهت تشخیص چهره استفاده شده است (Fang et al, 2002). در روش تطبیق مبتنی بر ویژگی‌های موضعی، ابتدا ویژگی‌های محلی مانند چشم‌ها، بینی و دهان استخراج شده و سپس موقعیت و آمار مکانی آنها (از نظر هندسی یا ظاهری) به درون طبقه‌کننده ساختاری وارد

¹ Principal Component Analysis

² Artificial Neural Network

³ holistic

⁴ local

⁵ hybrid

⁶ PCA

⁷ Independent Gabor Features

⁸ kernel Associative Memory

می‌شود. روش اشکال هندسی⁹ و روش $EBGM$ ¹⁰ به این دسته تعلق می‌گیرند. در روش تطبیق ترکیبی، هر دو ویژگی‌های کلی و محلی برای تشخیص چهره استفاده می‌شود. طرح ترکیبی از ویژگی‌های تشخیص چهره به وسیله ادغام ویژگی‌های کلی و محلی توسط فنگ¹¹ در سال 2002 ارائه گردید. الگوریتم ژنتیک¹² می‌تواند جهت انتخاب مجموعه ویژگی‌های مطلوب برای مشکلات طبقه‌بندی الگو مورد استفاده قرار گیرد. برخی از محققان از الگوریتم ژنتیک برای تشخیص چهره استفاده کرده‌اند (Bala et al, 2012). روش یادگیری درخت تصمیم‌گیری¹³ را برای پیدا کردن زیرمجموعه مناسبی از ویژگی‌های تبعیض آمیز برای طبقه‌بندی الگو ارائه کرده‌اند. الگوریتم ژنتیک برای جستجوی زیرمجموعه بهینه ممکن از ویژگی‌های استخراج شده مورد استفاده قرار گرفته است. در مطالعه سان و یین¹⁴ در سال 2005، از الگوریتم ژنتیک برای انتخاب تشخیص چهره 3 بعدی استفاده شد (Sun and yin, 2005). روش ارائه شده در (Satone and Kharate, 2010) سعی دارد که ویژگی‌ها را با گرفتن ویژگی‌های خوبی که بتواند فاصله درون طبقه‌ای را به حداقل رسانده و فاصله بین طبقه‌ای را به حداکثر برساند، بهینه‌سازی کند. در مطالعه لیو¹⁵ و همکاران در سال 2000، از روش پیگیری تکاملی¹⁶ بر اساس الگوریتم ژنتیک برای تشخیص چهره استفاده شد. ایده روش ارائه شده این است که اساس چهره از طریق چرخاندن محورهای تعریف شده در فضای PCA بررسی شود (Liu an Wechsler, 2000). نوع طبقه‌بندی کلی به دست آمده توسط تکنیک‌های موجود رضایت بخش نیست، بنابراین نیاز به یک تکنیک بهتر انتخابی و ادغامی ویژگی که بتواند دقت و صحت طبقه‌بندی کلی تشخیص چهره را بهبود ببخشد، وجود دارد. اگرچه ارائه تعریفی جامع و روشن از روش‌های تشخیص و شناسایی اجسام بحث مفصلی را می‌طلبد، اما به زبانی ساده، روشهای مدل‌گرا سعی در توصیف اجسام به صورت سه بعدی دارند. به این منظور معمولاً یک جسم را با استفاده از ارتباط‌های سه‌بعدی و حجم‌های ساده هندسی (مکعب‌ها، مخروط‌ها، کره‌ها) و روابط فیزیکی بین آنها توصیف می‌کنند. در مقابل، روش‌های ظاهرگرا از شکل ظاهری اجسام برای توصیف آنها استفاده می‌کنند. ورودی سیستم‌های ظاهرگرا تصاویر و توصیف‌های دوبعدی اجسام است. هم‌اکنون گرایش قالب در میان جامعه بینایی ماشین استفاده از روش‌های ظاهرگرا برای حل مسائل شناسایی است. شناسایی چهره نیز از این گرایش مستثنی نیست و حجم مطالعات و پژوهش‌های انجام شده در توسعه روشهای ظاهرگرا بسیار بیشتر از روش‌های مدل‌گرا است (Etemad and chellappa, 1997). روش PCA در سال 1991 توسط ترک¹⁷ و پنتلند¹⁸ پیشنهاد شد که از تحلیل المانهای اصلی برای کاهش بعد استفاده کرده تا بتواند زیرفضایی با بردارهای متعامد پیدا کند که در آن زیرفضا پراکندگی داده‌ها را به بهترین حالت نشان دهد. این زیرفضا را هنگامی که بر روی داده‌های چهره اعمال شوند، فضای چهره می‌گویند. پس از مشخص شدن بردارها تمامی تصاویر به این زیر فضا منتقل می‌شوند تا وزن‌هایی که بیانگر تصویر در آن زیرفضا هستند بدست آیند. با مقایسه شباهت وزن‌های موجود با وزن تصویر جدیدی که به این زیرفضا منتقل شده می‌توان تصویر ورودی را شناسایی کرد. با نمایش برداری چهره انسان که توسط کنار هم قرار دادن سطرهای ماتریس تصویر حاصل می‌شود می‌توان چهره انسان را برداری در فضایی با ابعاد بالا در نظر گرفت. با توجه به خصوصیات

⁹ Geometrical features

¹⁰ Elastic Bunch Graph Matching

¹¹ Fang

¹² GAs

¹³ GA-ID3

¹⁴ Sun & Yin

¹⁵ Liu & Wechsler

¹⁶ evolutionary pursuit (EP)

¹⁷ Turk

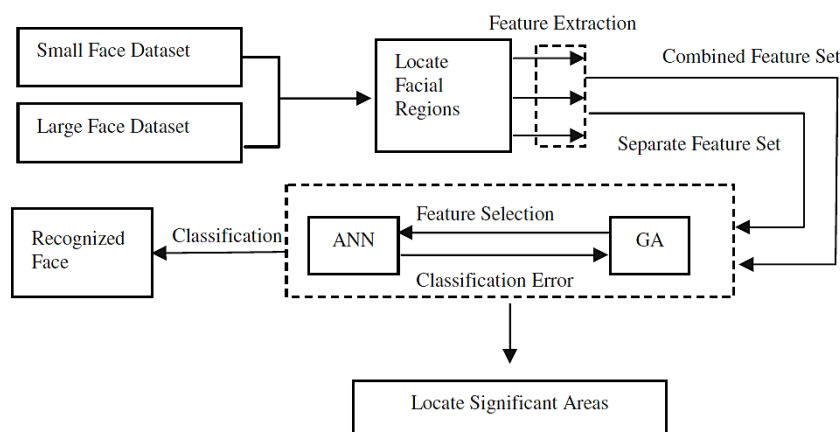
¹⁸ Pent land

مشابه چهره ها، می توان نتیجه گرفت که بردار چهره ها در زیرفضایی با ابعاد پایین تر واقع شده اند (Turk and Pent land, 1991).

3- روش پیشنهادی

تاکنون روش های زیادی برای بازشناسی چهره ارائه شده است که هر یک به طریقی متفاوت، سعی در بازشناسی چهره دارند. همچنین مقالات زیادی از نتایج مقایسه این روش ها ارائه شده است. از آنجا که این روش ها بر روی شرایط متفاوت، کارایی متفاوت دارند، هیچ کدام از آن ها نمی توانند ادعا نمایند که تحت همه شرایط از بقیه برتر هستند. به نظر می رسد که یک روش ترکیبی بتواند جواب خوبی داشته باشد. به شرط آنکه بتواند نقاط قوت و ضعف هر روش را در جواب نهایی تاثیر دهد. ولی نکته حایز اهمیت در چگونگی ترکیب کردن این روش ها با یکدیگر می باشد. ما در این مقاله روشی را ارائه می دهیم که بهینه ترین ویژگی های مربوط به صورت را استخراج کرده و در امر بازشناسی چهره مورد استفاده قرار می دهد.

در روش پیشنهادی، ما بهترین و بهینه ترین ویژگی های مربوط به صورت را استخراج می کنیم و با استفاده از روشی، مناسب ترین ویژگی ها را با هم ترکیب می نماییم تا به جوابی مناسب دست پیدا کنیم. بهترین نواحی صورت برای استخراج ویژگی چشم چپ، چشم راست، بینی و دهان می باشند. این نواحی دارای بهترین ویژگی های جداکننده مربوط به چهره در صورت انسان می باشند. یکی از مهمترین موارد، از بین بردن اثرات نویز و همچنین تصحیح عوامل مخرب نظیر گردش سر و تغییرات روشنایی می باشد. اگر ویژگی ها بهینه شوند و طول بردار ویژگی کوتاهتر شود سرعت طبقه بندی افزایش می یابد. اولین قدم در روش پیشنهادی، یافتن نواحی خاص مربوط به چهره در تصاویر حاوی صورت می باشد. سپس باید ویژگی های مورد نظر را از این نواحی استخراج کنیم. پس از استخراج ویژگی، ویژگی ها انتخاب می شوند و با هم ترکیب می شوند و در نهایت طبقه بندی می شوند. با استفاده از نتایج حاصله بهترین نواحی احتمال حضور چهره استخراج می شوند و سپس چهره مورد نظر طبقه بندی می شود. بلوک دیاگرام روش پیشنهادی در شکل 1 نشان داده شده است.



شکل 1) بلوک دیاگرام روش پیشنهادی

در این پژوهش، الگوریتم ژنتیک برای پیدا کردن ویژگی های مهم بالقوه ای که شناخت بیشتری را ایجاد کند استفاده می شود. مناطقی که حاوی این ویژگی های مهم هستند به عنوان نواحی مهم در نظر گرفته شدند. کروموزوم ها نشان دهنده ویژگی های مهم قابل انتخاب هستند. کدگذاری باینری که برای کروموزوم ها استفاده می شود به شکلی است که اگر 1 باشد به مفهوم انتخاب ویژگی و اگر 0 باشد به مفهوم عدم انتخاب ویژگی تلقی می شود. در یک نسل هر کروموزوم همراه با مجموعه ویژگی ورودی تکثیر شده و بردار ویژگی ورودی به شبکه عصبی مصنوعی داده می شود. بردار ویژگی ورودی F را می توان به صورت رابطه 1 نمایش داد.

$$F = CP, C = (c_1, c_2, \dots, c_l), c_i \in \{0,1\}, P = L + R + N + M \quad (1)$$

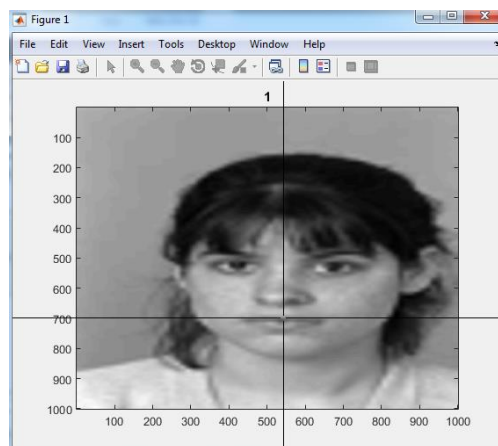
که در آن C یک کروموزوم تک است و C_i یک ژن در کروموزوم است. L طول کروموزوم می‌باشد که به همان اندازه مجموعه ورودی P است. R زمان آزمایش بر روی مجموعه ویژگی‌های جداگانه از هر منطقه صورت، و P نشان دهنده مجموعه‌ای از ویژگی‌های جداگانه است. بردار ویژگی ورودی F برای طبقه بندی به شبکه عصبی انتقال داده می‌شود. از شبکه عصبی با تنها یک لایه مخفی و یک الگوریتم پس انتشار اعطاف پذیر برای راه‌اندازی شبکه در این تکنیک بهره می‌گیریم. برای محاسبه تناسب فرد مربوطه در الگوریتم ژنتیک از خطای طبقه بندی آزمون استفاده می‌کنیم. در نمونه برداری مناسب‌ترین فردی که به بهترین میزان طبقه بندی آزمون دست یافته باشد مجدداً تولید می‌شود. کروموزوم‌های هر نسلی از الگوریتم ژنتیک که به بهترین میزان طبقه بندی رسیدند ضبط می‌گردند. این کروموزوم‌ها نشان می‌دهند که کدام ویژگی انتخاب شده و کدام یک انتخاب نشده است. پس از همه تولید نسل‌ها کل تعداد دفعاتی که هر ویژگی انتخاب شده برای بهترین میزان طبقه بندی محاسبه می‌شود. همه ویژگی‌ها بر اساس تعداد دفعاتی که انتخاب شدند رتبه بندی می‌گردند. این نکته را یادآوری می‌کنیم که این روش مبتنی بر نظریه تکامل می‌باشد، بدین گونه که در نسل‌های متوالی جمعیت‌هایی باقی می‌مانند که شایسته‌تر از بقیه باشند. همچنین بر روی جمعیت یک نسل، عملگرهایی جهت ایجاد تنوع مانند باز ترکیبی و جهش اعمال می‌شوند. به عبارت دیگر، بدنبال بهترین جواب با استفاده از تکامل جمعیت و انتخاب بهترین‌ها هستیم. در این تحقیق، شبکه عصبی مصنوعی به عنوان تابع دسته بندی کننده برای ارزیابی جمعیت تولید شده توسط الگوریتم ژنتیک، استفاده می‌شود. مجموعه داده اصلی S شامل N عدد ویژگی است که به زیر مجموعه‌های مختلف S_1, S_2, S_3, \dots با n_1, n_2, n_3, \dots برای استفاده در الگوریتم ژنتیک تقسیم می‌شوند. سپس این زیرمجموعه‌ها به شبکه عصبی المن با تعداد ثابتی از نرون‌ها در لایه مخفی جهت آموزش می‌روند. تعداد نرون‌های لایه ورودی به تعداد ویژگی‌های زیرمجموعه مورد نظر بستگی دارد. هر زیرمجموعه‌ای از داده‌ها به دو قسمت آموزشی و تست تقسیم شده‌اند. پس از آموزش، شبکه را با استفاده از یک سری داده‌های جدید (مجموعه داده‌های تست)، تست می‌نماییم. تعداد نمونه‌های دسته بندی شده اشتباه به عنوان خطای زیرمجموعه مربوطه محسوب می‌شود. عکس خطا به عنوان معیاری از شایستگی آن زیرمجموعه (فرد از جمعیت) در نظر گرفته می‌شود. بنابراین، هر زیرمجموعه‌ای از ویژگی‌ها دارای یک خطای تخمین می‌باشند که برای تعیین بهترین زیرمجموعه کمک خواهد کرد. پس شبکه عصبی افراد جمعیت ژنتیک را در یافتن بهینه‌ترین راه‌حل سوق می‌دهد. آخرین زیرمجموعه بدست آمده با GA (که بهینه‌ترین می‌باشد) دوباره با یک شبکه عصبی برای تعداد بیشتری آموزش داده می‌شود.

3-1 شناسایی نواحی چهره


ابتدا نواحی چهره را بر روی هر تصویر صورت شناسایی کرده و سپس ویژگی‌ها را استخراج می‌کنیم. سپس تصاویر چهره آزمایشی از پایگاه داده *FERET* استخراج می‌شوند. اطلاعات مرکز هماهنگی برای هر ناحیه صورت فراهم شده از جمله مرکز هماهنگی چشم، مرکز هماهنگی نوک بینی و مرکز هماهنگی دهان استفاده شده و روش فاصله آستانه¹⁹ برای شناسایی نواحی چهره اعمال می‌شود. روش فاصله آستانه، فاصله آستانه را در جهات افقی و عمودی برای منطقه چهره محلی تعریف می‌کند. این آستانه‌ها در مورد اندازه منطقه صورت تصمیم می‌گیرند. به وسیله اطلاعات مرکز هماهنگی، شناسایی نواحی چهره آسان

¹⁹Distance Threshold

می‌شود. در شکل‌های 2 و 3 به ترتیب علامت‌زدن روی نقاط مهم تصویر شامل (چشم‌ها، بینی و دهان) و قسمت‌های مهم جدا شده از تصویر مورد نظر، آورده شده است که با استفاده از مختصات بدست آمده از مرحله قبل، قسمت‌های مهم صورت از تصویر جدا شده و ذخیره می‌گردد.



شکل 2) علامت‌زدن روی نقاط مهم تصویر شامل (چشم‌ها، بینی و دهان)



شکل 3) نمونه‌ای از قسمت‌های مهم جدا شده از تصویر مورد نظر

مرحله مهم بعدی، استخراج ویژگی است. به منظور استخراج ویژگی ابتدا هر یک از تصاویر برش خورده با مقیاس 0.1 کوچک شده سپس پنجره 10×10 بر روی تصویر لغزنده شده و مجموع شدت پیکسل‌ها محاسبه می‌شود. برای مثال توسط روش مذکور از تصویر برش خورده چشم راست یا چپ با ابعاد 80×60 تعداد 48 ویژگی بدست می‌آید. در نهایت تعداد 189 ویژگی (48 برای چشم راست، 48 برای چشم چپ، 48 برای بینی و 45 برای دهان) از هر تصویر بدست می‌آید. در شکل 4 نمونه‌ای از ویژگی بدست آمده از چشم چپ با ابعاد 80×60 آورده شده است. حال با توجه به تعداد زیاد ویژگی‌ها از PCA مبتنی بر کرنل²⁰ برای کاهش تعداد ویژگی‌ها استفاده می‌کنیم که عملکرد بهتری نسبت به PCA دارد. تعداد 50 ویژگی برای

²⁰ Kernel PCA

اعمال مرحله بعد انتخاب می‌کنیم. در ادامه جهت انتخاب ویژگی‌های بهینه از الگوریتم ژنتیک استفاده می‌کنیم. پارامترهایی که برای تنظیم این روند تعیین و انتخاب شدند در جدول 1 بیان شده است.

-56.1717058980410	-28.7828227724044	-27.9431850215849	-
59.3658697862623	-102.217620627759	-105.224048821224	-
128.506278084109	-139.163089855844	-82.6156468432313	-
76.8596080932824	-59.5357107770595	-56.0387993791683	-
76.0102205514903	-97.0248565192930	-123.700942088792	-
142.638487208911	-117.477785862150	-97.0502736445501	-
95.6525681695105	-70.0295471678620	-66.7546359911839	-
94.8015524764669	-114.995058381225	-146.509702258594	-
118.025965416833	-105.449904355496	-132.491707360403	-
77.5495429134362	-91.2945035478459	-134.952279388952	-
134.845886289435	-150.924828195071	-153.839075590692	-
149.356557109798	-136.818641829476	-134.232616378032	-
131.767805706644	-147.043335318467	-150.128656691371	-
154.579771816136	-162.751795773061	-167.294801012624	-
172.867712071040	-176.199887151215	-174.416650606212	-
162.358848424228	-149.270174389173	-160.757307074691	-

شکل (4) 48 ویژگی بدست آمده از تنها چشم چپ با ابعاد 60 × 80

جدول (1) پارامترهای الگوریتم ژنتیک برای انتخاب بهینه ویژگی‌ها

نام پارامتر	مقدار پارامتر	توضیحات
generation	15	تعداد نسل
popusize	50	اندازه جمعیت
Xover_rate	0.9	تعدادی از این فرضیه های انتخاب شده
Mutation	0.2	میزان ضریب جهت‌گیری هر جهش به سمت بهترین انتخاب
Bit_n	50	تعداد فرضیه هایی که باید در جمعیت در نظر گرفته شوند

2-3 مقدار میانگین سطح خاکستری ویژگی

پس از تعیین مکان مناطق صورت، هر منطقه صورت به مناطق کوچک مستطیلی با همان اندازه تقسیم شده و مقدار متوسط سطح خاکستری ویژگی از این مناطق مستطیلی کوچک استخراج می‌شود. مقدار متوسط سطح خاکستری ویژگی به صورت رابطه 2 بیان می‌گردد.

$$gi = \frac{\sum p(x,y)}{w \times h \times v} \quad (2)$$

که در این رابطه gi مقدار میانگین سطح خاکستری می‌باشد که مربوط به مربع i ام است، $p(x,y)$ مقدار خاکستری پیکسل‌های موجود در مربع i ام می‌باشد. w عرض مربع، h ارتفاع آن و v ماکزیمم مقدار خاکستری موجود در مربع کوچک می‌باشد. پس از تقسیم‌بندی، مقادیر میانگین سطح خاکستری از مربع‌های کوچک موجود در نواحی به ترتیب از چپ به راست و از بالا به پایین

استخراج می‌شوند. در عمل ابعاد مربع های کوچک 6x4 انتخاب می‌شود. برای نواحی مربوط به چشم‌ها و بینی سایز ناحیه 20 و برای دهان سایز 30 انتخاب می‌شود.

3-3 ویژگی PCA

روش طرح ریزی PCA برای تشخیص چهره، که روش *eigenface* هم نامیده می‌شود، یک روش کلاسیک برای تشخیص چهره است. ایده ساده در روش *eigenface* گرفتن بزرگترین واریانس از بین مجموعه تصاویر صورت و سپس استفاده از این اطلاعات برای کدگذاری و مقایسه تصاویر چهره است. فایده روش *eigenface* کاهش ابعاد پراکندگی نمونه‌های طرح می‌باشد. فرض کنیم مجموعه $\{X_1, X_2, \dots, X_N\}$ به عنوان مجموعه‌ای از تصاویر نمونه N باشد که مقادیر فضای تصویر n بعدی را به خود می‌گیرد و هر تصویر متعلق به یکی از کلاس‌های c می‌باشد $\{X_1, X_2, \dots, X_C\}$. برای تبدیل خطی بر روی نقشه باید تصویر n بعدی اصلی به تصویر ویژگی m بعدی منتقل شود، به طوریکه m کوچکتر از n باشد. بردار ویژگی جدید $y_{k \in R^m}$ توسط رابطه 3 تعریف می‌شود.

$$y_k = W^T X_k \quad (3)$$

که در آن $W \in R^{n \times m}$ یک ماتریس با ستون‌های متعامد نرمال می‌باشد. W به نحوی انتخاب می‌شود که دترمینال ماتریس S را ماکزیمم نماید. ماتریس S به صورت رابطه 4 بیان می‌شود.

$$S = \sum_{k=1}^N (X_k - \mu)(X_k - \mu)^T \quad (4)$$

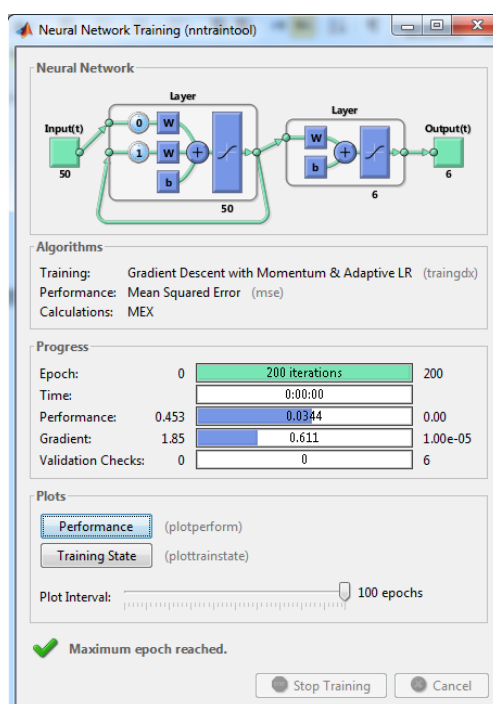
$$W_{opt} = \operatorname{argmax}_W |W^T S W| = (w_1, w_2, \dots, w_m)$$

که در رابطه بالا N تعداد تصاویر نمونه و μ میانگین تصویر همه نمونه‌ها می‌باشد. $\{w_i | i = 1, 2, \dots, m\}$ مجموعه بردارهای ویژه مربوط به m تا بزرگترین مقادیر ویژه می‌باشد. در آزمایشاتی که کاربرد ویژگی‌های استخراج شده از طریق کرنل PCA را در بازشناخت الگو و با استفاده از کلاسبندهای خطی بررسی می‌کنیم دو مزیت اصلی *Kernel PCA* غیرخطی چنین به چشم می‌خورد که اولاً اینکه مولفه‌های اصلی غیرخطی در مقایسه با همان تعداد مولفه‌های خطی نتایج کلاسیک‌تری بدست می‌دهند و دوم اینکه عملکرد مولفه‌های غیرخطی را می‌توان با بکارگیری مولفه‌های بیشتر از آنچه که در حالت خطی امکان‌پذیر است، بهبود بخشید. در واقع بر خلاف PCA خطی، روش پیشنهاد شده می‌تواند تعداد مولفه‌های اصلی بیشتر از ابعاد داده ورودی استخراج کند. اگر ابعاد فضای ورودی کوچکتر از تعداد نمونه‌ها باشد استفاده از روش *KPCA* از نظر محاسباتی نسبت به روش PCA هزینه بیشتری دارد، زیرا نیاز به محاسبه مقادیر ویژه ماتریسی با ابعاد L در L هستیم، که L تعداد داده‌ها می‌باشد ولی این محاسبات اضافی می‌تواند مفید باشد زیرا در بازشناخت الگو نشان داده می‌شود که در صورتی که ویژگی‌های استخراج شده غیرخطی باشند استفاده از یک کلاسبند خطی کارایی خوبی خواهد داشت. البته PCA استاندارد امکان بازسازی الگوهای اصلی از مجموعه کامل مولفه‌های اصلی استخراج شده از طریق بسط در پایه‌های بردار ویژه می‌دهد اما در *KPCA* چنین کاری ممکن نیست. با بکارگیری توابع کرنل می‌توان مولفه‌های اصلی را در فضاهایی با ابعاد ویژگی بالا به خوبی محاسبه کرد که این فضاهای ویژگی توسط یک نگاشت غیرخطی به فضای ورودی مرتبط می‌شود.

ما در این پیاده‌سازی از هر کلاس 3 داده برای آموزش و 1 داده برای آزمون در نظر گرفته‌ایم. شبکه عصبی انتخابی ما شبکه عصبی المن²¹ نام دارد. شبکه عصبی عموماً دو لایه با یک فیدبک از خروجی لایه اول (مخفی) به ورودی لایه اول می‌باشند. این اتصال برگشتی به شبکه در تشخیص و تولید الگوهای *time-varying* کمک می‌کند. در شبکه المن نرون‌های تابع

²¹Elman

tansig در لایه پنهان و نرون های تابع *purelin* در لایه خروجی قرار دارد. این ترکیب مخصوص شبکه‌های دو لایه با توابع انتقالی است که می‌توانند هر تابع با دقت دلخواه را تقریب بزنند. تنها چیز مورد نیاز این است که لایه پنهان باید نرون‌های کافی داشته باشد. توجه کنیم که شبکه المن با قراردادهای شبکه‌های دو لایه این تفاوت را دارد که لایه اول یک اتصال بازگشتی دارد. تاخیر در این اتصال مقادیر مرحله زمان قبلی را ذخیره می‌کند که می‌تواند در مرحله زمان جاری استفاده شود. بنابراین حتی اگر دو شبکه المن با وزن‌ها و بایاس مشابه داشته باشیم و ورودی‌های کاملاً برابر در یک مرحله زمانی، خروجی‌های آنها می‌توانند به خاطر حالت‌های فیدبک مختلف کاملاً متفاوت باشند، چون این شبکه می‌تواند اطلاعات را برای مراجع بعدی ذخیره کند، مناسب است. در شکل 5 اجرای شبکه عصبی نشان داده شده است. در این شکل، ساختار کلی شبکه عصبی نظیر تعداد لایه‌ها، ورودی و خروجی و همچنین تعداد *Epoch* های لازم جهت آموزش را می‌توان مشاهده کرد.



شکل 5) شبکه عصبی بکار گرفته شده در این پیاده‌سازی

3-4 دسته‌بندی با ANN

بردار ویژگی ورودی F بدست آمده از مرحله استخراج ویژگی‌ها، به شبکه عصبی المن^{۲۲} برای طبقه‌بندی داده می‌شود. این شبکه در حالت اول آزمایش با یک لایه مخفی و یک الگوریتم انعطاف‌پذیر پس انتشار برای آموزش شبکه تعریف می‌شود. در استفاده از شبکه عصبی ابتدا از مجموعه داده اصلی، زیر مجموعه مرتبط با کروموزم مورد نظر را یافته (بازای مقادیر 1 از کروموزم، ویژگی‌ها را برای تمامی نمونه‌ها بدست می‌آوریم) و سپس زیرمجموعه بدست آمده را پس از آموزش با قسمتی از مجموعه داده، تست می‌نماییم تا خطای دسته‌بندی مشخص شود. عکس این خطا را به عنوان شایستگی آن کروموزم در نظر می‌گیریم. این عمل را برای تمام اعضای جمعیت انجام می‌دهیم. شبکه عصبی برای ارزیابی "میزان شایستگی" زیرمجموعه‌های

توسعه یافته توسط ژنتیک در هر تکرار و همچنین برای تست زیرمجموعه نهایی بدست آمده در این پژوهش استفاده شده است.

4- بحث و نتایج

برای ارزیابی روش‌های بازشناسی چهره، بانک‌های اطلاعاتی گوناگونی تا به حال ارائه شده‌اند که هر یک شامل ویژگی‌های منحصر به خود هستند و طبیعتاً ارزیابی روش‌های گوناگون بر روی آن‌ها متفاوت است از سوی دیگر کاربردهای مختلف بازشناسی چهره ما را به ارائه و استفاده از روشی که خصوصیات آن کاربرد را لحاظ کند وادار می‌نماید. برای بررسی کارایی یک روش برای یک کاربرد خاص، می‌بایست از بانک اطلاعاتی که خصوصیات این کاربرد را در نمونه‌های خود در نظر گرفته باشد، استفاده نماییم. برای مثال چنانچه نیاز به بازشناسی چهره در سنین متفاوت داشته باشیم، می‌بایست از یک بانک اطلاعاتی که تصاویر چهره فرد در سنین مختلف در آن ذخیره شده باشد استفاده شود. در پیاده‌سازی و آزمایش‌ها از دیتابیس *FERET* استفاده شده است که جهت آزمایش‌های اولیه از یک مجموعه کوچک این دیتابیس استفاده کرده‌ایم. این زیر مجموعه 200 تایی شامل 50 کلاس (50 فرد متمایز) می‌باشد و در هر کلاس 4 چهره وجود دارد. در هر کدام از کلاس‌ها تصاویری با ژس-های مختلف یک فرد وجود دارد تا با استفاده از آن انعطاف الگوریتم را نسبت به اختلالات بوجود آمده بسنجیم. در تصویر 6 نمونه‌ای از تصاویر این بانک داده آورده شده است.



شکل 6) نمونه‌ای از بانک چهره *FERET*

آزمایش اصلی ما بر روی روش ترکیبی *PCA* با ژنتیک است و پایگاه داده شامل 50 کلاس می‌باشد که هر کلاس یک شخص متمایز را نشان می‌دهد. در این پایگاه داده، 4 تصویر صورت در هر کلاس وجود دارد. سه تا از آن‌ها به طور تصادفی برای آموزش و یکی برای تست انتخاب می‌شود. آزمایش‌ها روی موقعیت فضاهای قابل توجه با استفاده از $GA - ANN$ روی هر ناحیه مربوط به صورت به طور جداگانه انجام شده است. ویژگی‌های استفاده شده در این آزمایش‌ها، میانگین ویژگی‌های ارزش سطح خاکستری بودند. میانگین استخراج شده، ویژگی‌های ارزش سطح خاکستری از هر ناحیه مربوط به صورت بردار ویژگی ورودی برای آن ناحیه را شکل می‌دهد. سائز مجموعه ویژگی استخراج شده L از ناحیه چشم چپ 20، همان سائز برای مجموعه ویژگی استخراج شده R از ناحیه چشم راست و مجموعه ویژگی استخراج شده N از ناحیه بینی مقاردهی شد. سائز

مجموعه ویژگی استخراج شده دهان M ، 30 بدست آمد. مجموعه ویژگی استخراج شده از قسمتهای صورت شامل چشم، بینی، دهان به $GA - ANN$ به طور جداگانه برای انتخاب و طبقه بندی می روند. پارامترهای $GA - ANN$ به طور دقیق مشابه برای هر مجموعه از آزمایشها تنظیم شدند. تعداد تولید 50 و تعداد جمعیت اولیه 15 تعیین شد. نرخ عمل تقاطع با 0.9 و نرخ جهش با 0.2 تنظیم شده است واحدهای پنهان شبکه عصبی 6 مقداردهی شد و انتخابهایی که تولید شدند بهترین نرخ تشخیص ثبت شدند. تعداد اپک²³ (دوره آموزشی) برای شبکه عصبی نیز برابر با 200 تعیین شد. به دلیل اینکه ما نمی دانیم چه تعداد بردار ویژه باید برای کد کردن تصاویر صورت مناسب باشد، یک تعداد متفاوتی از بردارهای ویژه در آزمایشها ارزیابی شدند. در آزمایشهای انجام شده از 10، 14، 18، و 22 بردار ویژه استفاده کردیم. پارامترهای $GA - ANN$ به طور دقیقاً مشابه برای هر آزمایش تنظیم شدند. تعداد تولید نسل با 15 و تعداد جمعیت با 15 تعیین شدند. نرخ تقاطع 0.9 و نرخ جهش 0.2 تنظیم شدند. تعداد اپک برابر 200 تعیین شد و تعداد لایه های مخفی را از 6 به 50 افزایش دادیم. جدول 2 و 3 به ترتیب انتخاب ویژگی داده ها و نرخ طبقه بندی را نشان می دهد.

جدول 2) انتخاب ویژگی متناظر و ترکیبات به دست آمده


مناطق صورت	لایه های مخفی	انتخاب ویژگی
منطقه چشم چپ	6	$l1, l8, l9, l14, l16, l18, l20$
	50	$l1, l8, l9, l14, l18, l20$
	50	$l1, l6, l7, l9, l13, l15, l16, l19, l20$ $l1, l6, l7, l8, l9, l13, l16, l17, l18, l19, l20$
منطقه چشم راست	6	$r2, r3, r4, r6, r7, r9, r10, r11, r15, r16, r19, r20$
	50	$r2, r3, r4, r5, r7, r9, r10, r14, r16, r19$
منطقه بینی	6	$n1, n2, n4, n9, n10, n13, n16, n18, n19, n20$
	50	
منطقه دهان	6	$m2, m3, m4, m6, m10, m11, m12, m13, m15, m16,$ $m20, m21, m22, m25, m29$
	50	$m2, m3, m5, m10m, m12, m14, m16m, m18, m19, m20,$ $m22, m26, m27, m29$
	50	

²³Epoch

جدول 3) بهترین نرخ طبقه بندی تست و آموزش در یک دوره اجرای برنامه

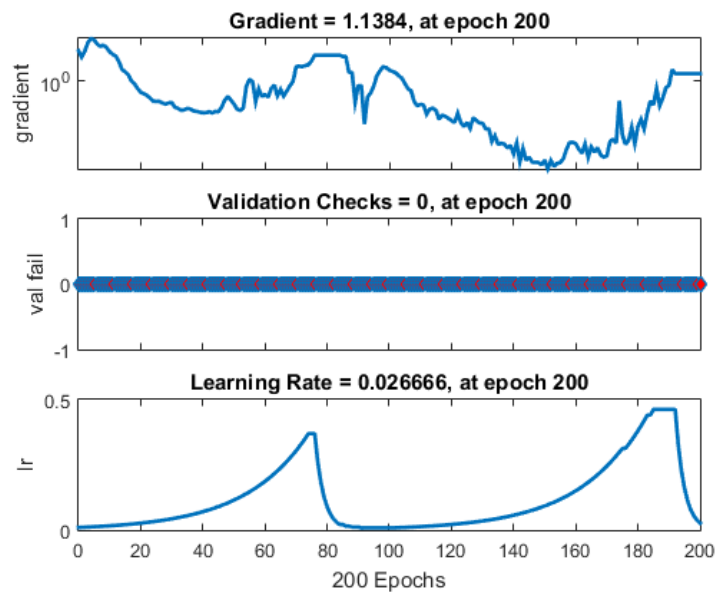
لایه‌های مخفی	انتخاب ویژگی (کروموزم‌های ژنتیک)	نرخ طبقه‌بندی		میانگین مربع خطاها MSE
		نرخ آموزش	نرخ تست	
6	1101111010110010101010111111 001000010001000110100001101101	100	78	0.026269
50	10101011101010101000100101011111000011 0110100000101100000110110011010100001	100	80	0.024114

همانطور که قبلاً بیان شد در این پیاده‌سازی از شبکه عصبی ال‌من به عنوان طبقه‌بند از آن استفاده شده است. این نوع شبکه عموماً دو لایه با یک فیدبک از خروجی لایه اول (مخفی) به ورودی لایه دوم می‌باشند. شبکه ال‌من می‌تواند برای جواب دادن و تولید کردن انواع الگوهای شبکه با استفاده از انتشار خطای بازگشتی^{۲۴} با مومنتوم و نرخ یادگیری وقتی آموزش داده شود و وزن‌ها و بایاس‌های جدید را برگشت دهد. در شکل‌های 7 و 8 نیز به ترتیب کارایی تابع شبکه عصبی به ازای هر دوره اجرایی و نیز میانگین مربع خطاها و وضعیت آموزشی نشان شده است.



شکل 7) کارایی شبکه عصبی به ازای دوره آموزشی و میانگین مربع خطاها

²⁴back propagation



شکل 8) وضعیت آموزشی شبکه عصبی استفاده شده

در ادامه با اتمام اجرای طبقه‌بندی، بهترین ویژگی‌های انتخابی به تعداد 50 ویژگی که توسط روش پیشنهادی استخراج شده- اند در شکل 9 نشان داده شده است.

```

Command Window
>> best_feature

best_feature =


Columns 1 through 17
    1    1    1    1    1    0    0    0    1    0    1    0    0    1    1    1    0

Columns 18 through 34
    1    1    1    1    0    1    1    0    0    1    0    0    1    1    0    0    1

Columns 35 through 50
    1    0    1    1    0    1    0    0    1    0    0    1    0    1    1    1
    
```

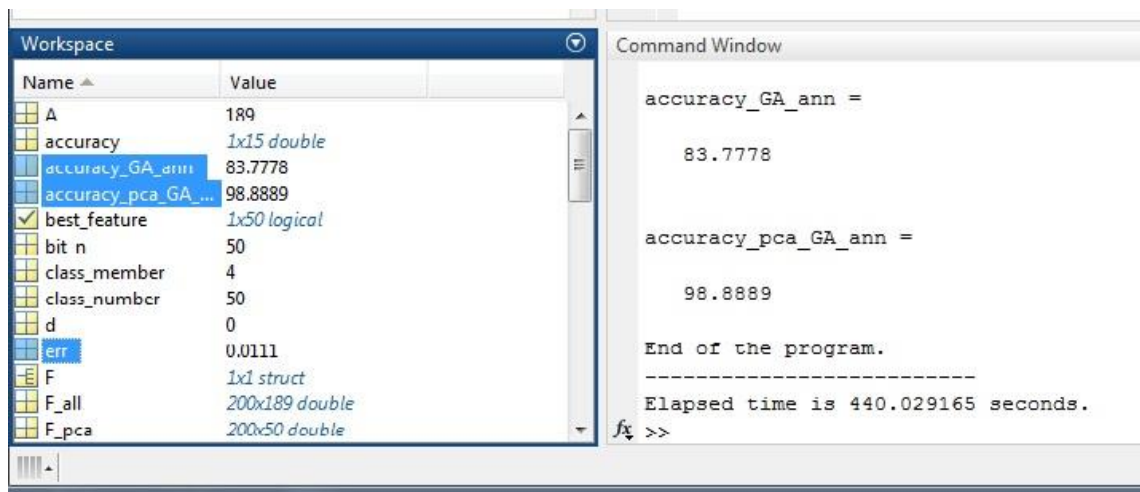
شکل 9) بهترین ویژگی‌های استخراج شده در پیاده‌سازی

در شکل‌های 10 و 11 نیز به ترتیب، خروجی تابع برازندگی بر اساس نسل‌ها، ناشی از اجرای الگوریتم ژنتیک و خروجی نهایی بدست آمده و بر حسب درصد برای روش پیشنهادی نشان داده شده است.



شکل 10 نمودار تابع برازندگی (Fitness Function) بر اساس نسل‌ها (Generation) ناشی از اجرای Genetic Algorithm

در بهینه‌سازی ژنتیک مقدار تابع هدف (*fitness function*) که قرار است مینیمایز شود به ازای هر نسل (*generation*) محاسبه می‌شود. انتظار آن است که در نسل‌های بعد مقدار تابع هدف کمتر شود که در این نمودار مقدار تابع هدف به ازای هر نسل محاسبه و نمایش داده شده است. این نمودار برای هر بار تولید جمعیت سه منحنی ترسیم کرده است. منحنی اول بیشترین شایستگی شناسایی شده، منحنی دوم کمترین و منحنی وسط میانگین شایستگی‌های شناسایی شده برای هر دسته جمعیت تولیدی را نشان می‌دهد. در این نمودار اگر دقت کنیم می‌توان مشاهده کرد که الگوریتم 15 بار تولید جمعیت کرده که در هر مرحله جمعیت تولید شده یک بیشینه و یک کمینه شایستگی دارند که در نمودار بالا و پایین مشخص است. در نمودار وسط هم میانگین شایستگی‌های کل جمعیت ترسیم شده است.



شکل 11 خروجی بدست آمده بر حسب درصد برای مقایسه نرخ تشخیص در دیتابیس FERET

با توجه به مقداردهی متغیرهای محیط *Workspace* و *command window* نرم‌افزار شبیه‌سازی می‌توان بهبود نتایج از روش پیشنهادی که ترکیبی از *pca* و الگوریتم ژنتیک است را مشاهده نمود که توانسیم به نرخ تشخیص بالای 98 درصد دست بیابیم. لازم به ذکر است که مدت زمان اجرای استخراج ویژگی‌ها و شبیه‌سازی به سخت‌افزار مورد استفاده نیز بستگی دارد.

5- نتیجه‌گیری کلی

در این پژوهش، تکنیک انتخاب و ادغام ویژگی جدیدی برای بازشناسی چهره ارائه شده است. در تکنیک پیشنهادی از الگوریتم ژنتیک (*GA*) برای انتخاب ویژگی و از شبکه عصبی مصنوعی برای طبقه‌بندی استفاده شد. تکنیک ارائه شده در یک مجموعه ویژگی جداگانه از هر منطقه صورت و مقایسه آن با مجموعه ویژگی ترکیبی مورد آزمایش قرار گرفت. یک زیر مجموعه 200 تایی از تصاویر پایگاه داده معیار *FERET* برای آزمون مورد استفاده قرار گرفت. در این پژوهش، الگوریتم ژنتیک برای پیدا کردن ویژگی‌های مهم بالقوه‌ای که شناخت بیشتری را ایجاد کند استفاده شد. شناسایی مناطق موضعی چهره با استفاده از روش فاصله آستانه بر اساس مرکز هماهنگی اطلاعات هر منطقه صورت گرفت. ویژگی‌های چهره از هر یک از مناطق صورت استخراج شد. در ادامه رویکرد مبتنی بر الگوریتم ژنتیک برای انتخاب ویژگی چهره به کار گرفته شد. مناطق مهم درون هر منطقه صورت با استفاده از این رویکرد مورد توجه قرار گرفت. رویکرد مبتنی بر شبکه‌های عصبی مصنوعی برای طبقه‌بندی ویژگی‌های چهره انجام پذیرفت. ویژگی‌های چهره انتخاب شده از روش *GA* برای طبقه‌بندی نهایی به شبکه عصبی منتقل شدند. خطای طبقه‌بندی برای محاسبه تناسب هر فرد مجدداً به *GA* برگردانده شد تا مناطقی که حاوی این ویژگی‌های مهم هستند به عنوان نواحی مهم در نظر گرفته شوند. با توجه به اینکه روش پیشنهادی سعی در یافتن بهترین توزیع برای ماکزیم‌سازی محاسبات بین داده‌ای دارد با این حال تمامی خواص و ویژگی‌های مولفه‌های اصلی تصویر نیز بر جای خود باقی خواهد ماند. بنابراین نیازی به مقایسه تصویر مورد کاوش با تمامی داده‌های آموزش موجود، نخواهد بود. با این توصیف روش پیشنهادی خیلی سریع به راه‌حل‌های بهینه همگرا می‌شود و همچنین توانایی زیادی در جستجوی فضای راه‌حل‌ها دارد و می‌تواند کوچکترین زیرمجموعه ویژگی‌ها را پیدا کند. در این روش دقت طبقه‌بندی و طول بردارهای ویژگی انتخاب شده به‌عنوان معیارهای تابع ارزیابی در نظر گرفته شده‌اند. در گام آخر مقایسه‌ای بین روش پیشنهادی و سایر روش‌ها انجام شد و نتیجه حاکی از آن شد که استفاده از *PCA* به همراه *GA* موجب بهبود نرخ تشخیص صحیح تصاویر تا بالاتر از 98 درصد می‌شود.

6- منابع

- Bala, J. and Huang, J. and Vafaie, H. (2012). *Hybrid learning using genetic algorithms and decision trees for pattern classification*. Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence. 1. 719-724.
- Ergun Gumus and Niyazi Kilic and Ahmet Sertbas and Osman N. Ucan. (2010). *Evaluation of face recognition techniques using PCA, wavelets and SVM* Expert Systems with Applications 37 (2010) 6404-640.
- Fang, Y., Tan, T., & Wang, Y. (2002). *Fusion of global and local features for face verification*. IEEE International Conference on Pattern Recognition. 2. 382-385.
- K. Etemad and R. Chellappa. (1997). *Discriminant Analysis for Recognition of Human Face Images*, Journal of the Optical Society of America A, Vol. 14, No. 8, August 1997. pp. 1724-1733.
- Liu, C., & Wechsler, H. (2000) *Evolutionary pursuit and its application to face recognition*, IEEE Transactions on Pattern Analysis and Machine Intelligence. 22(6). 570-582.

M. Turk and A. Pentland. (1991). *Eigen faces for Recognition*, Journal of Cognitive Neuro science. Vol. 3, No. 1. 1991. pp. 71-86.

M.P. Satone and Dr. G.K. Kharate. (2010). *Face Recognition Based on PCA on Wavelet Sub and of Average-Half-Face*, Journal of Machine Learning Research, Vol. 3. 2010. pp. 1-4.

Sun, Y., & Yin, L. (2005). *A genetic algorithm based feature selection approach for 3D face recognition*. In Biometric consortium conference. USA.

Y .MingHsuan. (2002). *kernel fisher faces: face recognition using kernel methods*. in Fifth IEEE International Conference on Automatic Face and Gesture Recognition. pp. 215–220.

Zhang, B., Zhang, H., and G e, S. (2004). *Face recognition by applying wavelet sub and representation and kernel associative memory*. IEEE Transactions on Neural Networks. 15. 166–177.