

# انتخاب زیرمجموعه بهینه از ویژگی‌های استخراج شده توسط عملگر بهینه شده LBP بر مبنای CLA-EC در سیستم بازشناسی چهره

اختر حضرتی بی‌شک، کریم فائز، حسین برقی جند و سجاد قطعی

تشخیص از شدت روشنایی پیکسل‌ها به عنوان داده‌های ورودی استفاده می‌کنند. داده‌های شدت روشنایی چهره، تحت تأثیر چرخش چهره و تغییر شدت روشنایی محیط قرار می‌گیرند. اخیراً تحقیقات در زمینه بازشناسی چهره روی نمایشی از چهره متمرکز شده که نسبت به تغییرات روشنایی و حالت چهره مقاوم باشد که این کار سبب ایجاد یک توصیفگر قدرتمند بافت موسوم به الگوی باینری محلی<sup>۲</sup> (LBP) شده است [۸]. آهون و همکارانش در سال ۲۰۰۴ میلادی ایده توصیف چهره با استفاده از ویژگی‌های LBP را مطرح نمودند [۹]. از آن سال به بعد محققین زیادی بر روی LBP کار کرده‌اند [۱۰] تا [۱۴].

در این مقاله ما روشی ساده اما قوی را برای استخراج ویژگی‌ها به نام الگوی باینری میانگین محلی LABP معرفی کردیم که ویژگی عمده آن استفاده از نقاط نمونه بیشتری برای استخراج الگوهای مقاوم‌تر در برابر تغییرات محلی می‌باشد. ما برای پیدا کردن بهترین زیرمجموعه از الگوها از یک مکانیزم جدید بر مبنای الگوریتم آتاماتای یادگیری سلولی مبتنی بر محاسبات تکاملی (CLA-EC) استفاده کردیم. الگوریتم پیشنهادی در سیستم شناسایی چهره به کار گرفته شد و دقت طبقه‌بندی و تعداد ویژگی‌های انتخاب نشده (zeros) به عنوان معیار ارزیابی در نظر گرفته شد. گروهی از طبقه‌بندهای ماشین بردار پشتیبان<sup>۳</sup> (SVM) با ناظر با استفاده از هیستوگرام بهترین زیرمجموعه انتخاب شده از الگوها آموزش دیدند.

ادامه مقاله به این صورت سازماندهی شده است: استخراج ویژگی در بخش ۲ آمده است. در بخش ۳ سیستم انتخاب ویژگی بر مبنای الگوریتم CLA-EC توضیح داده شده و طبقه‌بند ماشین بردار پشتیبان در بخش ۴ معرفی شده است. نتایج حاصل از پیاده‌سازی در بخش ۵ آورده شده و بخش نهایی مقاله نتیجه‌گیری می‌باشد.

## ۲- استخراج ویژگی

### ۱-۲ الگوی باینری محلی

عملگر الگوی دودویی محلی که روشی قوی برای آنالیز بافت می‌باشد اولین بار توسط اوجالا و همکارانش [۸] به صورت یک عملگر مربعی  $3 \times 3$  مطرح شد. طرز کار این روش بدین صورت است که ۸ همسایگی روی عملگر را با پیکسل مرکزی مقایسه می‌کنند. هر یک از این هشت پیکسل همسایه اگر مقدارش از مقدار پیکسل مرکزی بزرگ‌تر یا مساوی باشد با ۱ جایگزین می‌شوند و در غیر این صورت مقدار آنها صفر خواهد بود. در پایان پیکسل مرکزی با جمع کردن وزن‌دار باینری پیکسل‌های همسایه جایگزین می‌شود (معادله (۱))

چکیده: ما در این مقاله روش کارآمد جدیدی را مبتنی بر توصیفگر الگوی باینری محلی برای بازشناسی چهره معرفی کردیم. چون محاسبات داخل الگوی باینری محلی بین مقادیر دو پیکسل انجام می‌شود، حتی تغییرات کوچک در الگوی باینری عملکرد آن را تحت تأثیر قرار می‌دهد. در این مقاله یک روش جدید بازشناسی چهره برای انتخاب الگوهای باینری میانگین محلی (LABP) بر مبنای آتاماتای یادگیر سلولی مبتنی بر محاسبات تکاملی ارائه شده است. در روش پیشنهادی، ابتدا الگوهای باینری یکنواخت محلی توسط LABP از تصاویر چهره استخراج می‌شود. در LABP جهت به دست آوردن نمایش ویژگی مقاوم‌تر، نقاط نمونه زیادی مورد استفاده قرار گرفته است، سپس بهترین زیرمجموعه از این الگوها بدون داشتن اطلاعات اولیه از آنها توسط روش CLA-EC پیدا شده و از آنها هیستوگرام گرفته می‌شود و در نهایت از ماشین بردار پشتیبان برای طبقه‌بندی استفاده می‌شود. نتیجه به دست آمده از شبیه‌سازی سیستم‌های بازشناسی چهره روی مجموعه داده FERET، برتری الگوریتم پیشنهادی را نسبت به الگوریتم‌های دیگر نشان داد.

کلیدواژه: آتاماتای یادگیر سلولی، الگوی باینری محلی، ماشین بردار پشتیبان، محاسبات تکاملی.

## ۱- مقدمه

بررسی هویت و بازشناسی چهره به دلیل مقبولیت بالا، در دسترس بودن، دقت نسبتاً بالا و سادگی اخذ آن از موفق‌ترین و متداول‌ترین روش‌های بیومتریک به شمار می‌رود که در مقایسه با سایر مؤلفه‌های بیومتریکی، باعث متمایز شدن آن در کاربردهای امنیتی شده است [۱]. به همین دلیل تحقیقات زیادی بر روی انواع روش‌های بازشناسی چهره در سه دهه اخیر انجام گرفته است. یک مؤلفه کلیدی برای سیستم‌های بازشناسی چهره، استخراج ویژگی‌های متمایزکننده از یک تصویر است. الگوریتم‌های مختلفی وجود دارند که در گذشته جهت استخراج ویژگی بیان شده‌اند، مانند آنالیز مؤلفه‌های اصلی (PCA) [۲]، آنالیز متمایزکننده خطی (LDA) [۳]، رمزگذاری فاز گابور [۴] و روش‌های مبتنی بر هسته همچون KPCA [۵]. خواننده علاقمند را جهت مطالعات بیشتر در مورد آشنایی با الگوریتم‌ها به [۲] تا [۸] ارجاع می‌دهیم. بیشتر ماشین‌های

این مقاله در تاریخ ۲۴ مهر ماه ۱۳۹۱ دریافت و در تاریخ ۱ مرداد ماه ۱۳۹۲ بازنگری شد.

اختر حضرتی بی‌شک، گروه کامپیوتر واحد اهر، دانشگاه آزاد اسلامی، اهر، (email: a-hazrati@iau-ahar.ac.ir).

کریم فائز، استاد دانشکده مهندسی برق، دانشگاه صنعتی امیرکبیر، تهران، (email: kfaez@aut.ac.ir).

حسین برقی جند، گروه کامپیوتر واحد اهر، دانشگاه آزاد اسلامی، اهر، (email: h-barghi@iau-ahar.ac.ir).

سجاد قطعی، دستیار علمی، گروه مهندسی کامپیوتر، دانشگاه پیام نور، تبریز، (email: s.gatei@pnu.ac.ir).

2. Local Binary Pattern  
3. Support Vector Machine

1. Feature Extraction

خاص به دست می‌آورد برای تشخیص بافت کلی تصویر مناسب نمی‌باشد و با این روش بسیاری الگوهای تفکیک‌کننده، جهت تهیه ویژگی‌های مفید کنار گذاشته می‌شوند. چون روش چندمقیاسه می‌تواند ویژگی‌ها و الگوهای تفکیک‌کننده بیشتری را تحت تنظیمات متفاوت ارائه دهد. بنابراین ما در روش خود، اندازه پنجره را به عنوان پارامتر  $(n)$  در نظر می‌گیریم به طوری که  $n \times n$  مقیاس عملگر الگوی باینری محلی می‌باشد و از (۲) برای محاسبه مقدار میانگین جایگزین برای هر پیکسل  $(M_{ij})$  در تصویر  $I$  استفاده می‌کنیم

$$M_{ij}(n \times n) = \frac{\sum_{k=1}^{n \times n} g_{ijk}}{n \times n} \quad (2)$$

به طوری که برای  $k = \{1 \dots n \times n\}$ ،  $g_{ijk}$  پیکسل‌هایی از تصویر هستند که در پنجره با اندازه  $n \times n$  واقع شده‌اند. چون در یک تصویر چهره، اغلب بلوک‌های پنجره‌ای با اندازه‌های متفاوت، دارای اطلاعات مفید متفاوتی هستند، به عبارتی در هر بلوک اطلاعات مشابهی از ویژگی‌ها وجود ندارد. بنابراین ما در الگوریتم خود از پنجره‌هایی با اندازه‌های مختلف  $(3 \times 3, 5 \times 5, 7 \times 7, 9 \times 9, 11 \times 11)$  استفاده کردیم. سپس عملگر LBP را روی تصویر اصلی  $I$  و تصاویر دیگری که از تصویر اصلی با اعمال عملگر میانگین به دست آورده‌ایم  $(M(n \times n))$ ، اعمال می‌کنیم

$$LABP_{p,R}(x,y) = \sum_{p=0}^{P-1} s(M_p - M_c) 2^p \quad (3)$$

به طوری که  $M_p$  و  $M_c$  به ترتیب مقدار سطوح خاکستری پیکسل مرکزی و پیکسل‌های همسایه که داخل پنجره به اندازه  $3 \times 3$  قرار گرفته‌اند، هستند. همچنین  $2^p$  ضریب مورد نظر برای هر همسایه و  $s$  بیانگر تابع علامت می‌باشد


$$s(x) = \begin{cases} 1 & \text{if } x \geq \theta \\ 0 & \text{if } x < \theta \end{cases} \quad (4)$$

$$\theta = \sigma \times \alpha, \quad 0 < \alpha \leq 1$$

به جای استفاده از حد آستانه ثابت  $\theta$ ، مقدار آن را بر حسب مقدار انحراف استاندارد همه پیکسل‌های موجود در پنجره با اندازه  $n \times n$ ، (یعنی  $\sigma$ ) و یک ضریب مقیاس  $(\alpha)$  در نظر گرفته‌ایم. از بین مقادیر مختلفی که برای پارامترهای ضریب مقیاس  $(\alpha)$  آزمایش شدند، نتایج نشان داد که با مقدار  $\alpha = 0.1$  بیشترین کارایی برای روش پیشنهادی به دست می‌آید. در نهایت برای استخراج ویژگی‌های نماینده، فقط الگوهای یکنواخت LABP را در نظر می‌گیریم [۱۶]. در شکل ۲ نتایج حاصل از اعمال عملگر LABP با پارامترهای  $n$  متفاوت بر روی تصاویر نرمال شده چهره آورده شده است.

### ۳- انتخاب ویژگی

انتخاب ویژگی یکی از مهم‌ترین مراحل است که باعث افزایش کارایی سیستم‌های شناسایی الگو می‌شود. مسأله انتخاب ویژگی، انتخاب یک زیرمجموعه بهینه از ویژگی‌ها به اندازه  $m$  از یک مجموعه ویژگی‌ها با اندازه  $n$  ( $n > m$ ) می‌باشد [۱۸]. هدف از انتخاب ویژگی، کاهش اندازه مسأله و کاهش فضای جستجوی نتایج برای الگوریتم‌های یادگیری است. در طراحی طبقه‌بند برای شناسایی الگو، انتخاب ویژگی می‌تواند دقت و سرعت طبقه‌بندی کننده را افزایش دهد [۱۹]. در این مقاله یک روش



شکل ۱: عملگر LBP برای توصیف بافت تصاویر.

$$LBP_{p,R}(x,y) = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (1)$$

$$s(x) = \begin{cases} 1 & \text{if } x \geq 0 \\ 0 & \text{if } x < 0 \end{cases}$$

که  $s$  بیانگر تابع علامت،  $g_p$  و  $g_c$  مقدار سطوح خاکستری همسایه و پیکسل مرکزی و  $2^p$  ضریب مورد نظر برای هر همسایه می‌باشد. شکل ۱ عملگر الگوی دودویی محلی را نشان می‌دهد. دو تعمیم از عملگر اصلی در [۱۵] آورده شده که در اولی برای این که روش LBP، بافت‌های با نسبت متفاوت را نیز در بر بگیرد، این روش با استفاده از همسایگی‌هایی با سایزهای متفاوت توسعه یافت. اوجالا و همکارانش [۱۶] روش خودشان را به صورت عملگری با همسایه‌های دایره‌ای با شعاع‌های مختلف توسعه دادند. نمادگذاری این عملگر به صورت  $LBP_{p,R}$  می‌باشد که  $P$  بیانگر تعداد همسایه‌ها بر روی محیط دایره به شعاع  $R$  می‌باشد.

دومین تعمیم که الگوهای یکنواخت نامیده می‌شود، حداکثر شامل ۲ گذار بیتی از ۰ به ۱ و یا برعکس می‌باشد. به عنوان مثال الگوهای ۰۰۰۰۰۰۰۰ (با گذار ۰) و ۱۱۰۰۱۰۰۱ (با گذار ۴) به ترتیب یکنواخت و غیر یکنواخت می‌باشند. نشان داده شده که با استفاده از همسایگی  $(8,1)$  و  $(16,2)$  به ترتیب در حدود ۷۰٪ و ۹۰٪ از کل الگوها یکنواخت خواهند بود. به طور کلی الگوی باینری با  $p$  بیت شامل  $(p-1)p+2$  الگوی یکنواخت می‌باشد. از نمادگذاری  $LBP_{p,R}^{uv}$  برای  $LBP$  یکنواخت استفاده می‌شود که زیرنویس استفاده از همسایگی  $(P,R)$  را بیان می‌کند. بالانویس نیز بیانگر استفاده از الگوهای یکنواخت می‌باشد. تعمیم‌ها و بهبودهای زیادی از نسخه اولیه الگوی باینری محلی که اولین بار توسط اوجالا و همکارانش معرفی شده، به وجود آمده است. یک مرجع خوب را می‌توان در [۱۷] یافت.

### ۲-۲ الگوهای باینری میانگین محلی (LABP)

چون محاسبات در الگوهای باینری محلی، بین مقادیر دو پیکسل انجام می‌شود و به صورت محلی عمل می‌کند، بنابراین با تغییر کوچکی در الگو بسیار مورد تأثیر قرار می‌گیرد و زیاد مقاوم نخواهد بود. در روش پیشنهادی جهت به دست آوردن نمایش ویژگی مقاوم‌تر در LABP نقاط نمونه زیادی را مورد استفاده قرار دادیم؛ ابتدا به جای هر پیکسل در تصویر اصلی  $(I)$ ، میانگین مقادیر خاکستری از پیکسل‌هایی در تصویر اصلی که در پنجره‌ای با اندازه  $n \times n$  و به مرکزیت همان پیکسل قرار گرفته را قرار می‌دهیم. به علاوه بیشتر سیستم‌های بازشناسایی چهره موجود بر مبنای الگوی باینری فقط از نوع یکنواخت LABP، آن هم تنها در یک مقیاس خاص جهت شناسایی استفاده می‌کنند. ویژگی‌های به دست آمده با استفاده از روش‌های LBP تک‌مقیاسه که ساختار تصویر را در یک مقیاس

1. Sign Function
2. Uniform Patterns
3. Local Average Binary Pattern Operators

```

Initialize.
While not done do
  For each cell  $i$  in CLA do in parallel
    Generate a new string genome
    Evaluate the new string genome
    If  $f(\text{new string genome}) > f(\text{old string genome})$  then
      Accept the new string genome
    End if
    Select  $S_e$  cells from neighbors of cell  $i$ 
    Generate the reinforcement signal vector
    Update Las of cell  $i$ 
  End parallel for
End while

```

شکل ۳: شبه‌کد الگوریتم CLA-EC.

زمانی که یک معیار از پیش تعیین شده ارضا نشود تکرار می‌گردد. در این مقاله برای ساده کردن ارائه عملکرد CLA-EC، فرض می‌کنیم فضای جستجوی مورد نظر یک فضای متناهی دودویی باشد.

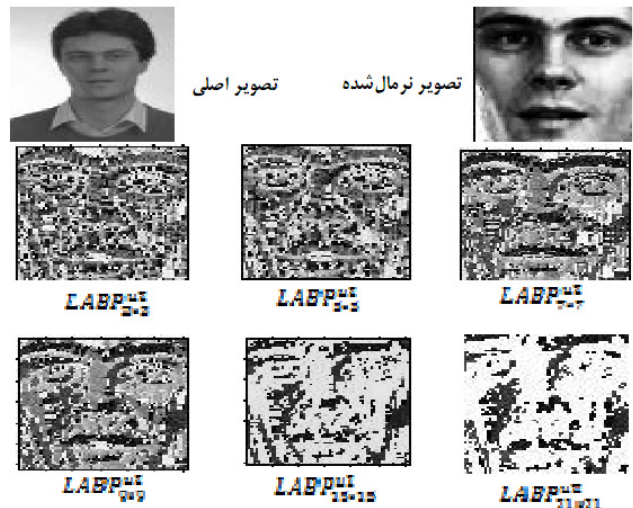
### ۳-۲ انتخاب ویژگی با CLA-EC

در این مقاله از ایده باینری CLA-EC برای حل مسأله انتخاب ویژگی استفاده شده است. در یک فضای بزرگ از ویژگی‌ها که هر بعد یک نوع ویژگی را نشان می‌دهد، یک مجموعه از ویژگی‌ها می‌تواند یک نقطه در این فضا باشد. اگر تعداد کل ویژگی‌ها  $n$  باشد در این صورت  $2^n$  زیرمجموعه از ویژگی‌ها وجود دارد که هر کدام از این زیرمجموعه‌ها از لحاظ اندازه و محتوای ویژگی‌ها با هم فرق دارند. بهترین نقاط، زیرمجموعه‌هایی هستند که کمترین طول (که در اینجا معادل با بیشترین تعداد Zeroها در کروموزوم می‌باشد) با بیشترین دقت طبقه‌بندی را داشته باشد. در طرح پیشنهادی، ژنوم یک رشته بیتی با طول  $n$  است که  $n$ ، تعداد الگوهای یکنواخت LABP می‌باشد. هر الگوی یکنواخت استخراج شده توسط عملگر LABP متناظر با یک بیت در رشته می‌باشد. اگر  $i$  امین بیت یک باشد، بنابراین  $i$  امین الگو انتخاب شده و در غیر این صورت آن ضریب چشم‌پوشی میشود. هر ژنوم یک زیرمجموعه متفاوت از الگوها می‌باشد.

فرض می‌کنیم که فضای جستجو یک فضای متناهی دودویی است، بنابراین می‌توان مسأله بهینه‌سازی را به صورت زیر ارائه داد: فرض کنید  $\mathcal{R} \rightarrow \{0,1\}^m : f$  یک تابع حقیقی باشد که باید مینیمم شود. به منظور استفاده از CLA-EC برای بهینه‌سازی تابع  $f$ ، ابتدا یک مجموعه از اتوماتای یادگیر به هر سلول CLA-EC تخصیص داده می‌شود که تعدادشان برابر با تعداد بیت‌ها در یک رشته ژنومی می‌باشد که هر ژنوم متناظر با یک نقطه از فضای جستجوی  $f$  است. ژنوم یک رشته بیتی است که هر الگوی یکنواخت استخراج شده توسط عملگر LABP متناظر با یک بیت در رشته می‌باشد. هر اتوماتا دارای دو عمل اصلی به نام عمل ۰ و ۱ است و عملیات کلی الگوریتم CLA-EC در شکل ۳ آمده است.

### ۳-۳ تابع ارزیابی<sup>۲</sup>

هدف از انتخاب زیرمجموعه‌ای از ویژگی‌ها، استفاده از ویژگی‌های کمتر جهت به دست آوردن عملکرد بهتر یا عملکردی همسان در مقایسه با استفاده از کل ویژگی‌ها می‌باشد. بنابراین توابع ارزیابی باید شامل دو شرط (۱) دقت<sup>۳</sup> و (۲) تعداد ویژگی‌های انتخاب شده باشند. هر زیرمجموعه از ویژگی‌ها شامل یک تعداد خاص از الگوهای یکنواخت می‌باشد. اگر دو زیرمجموعه عملکرد یکسانی داشته باشند، در حالی که تعداد متفاوتی



شکل ۲: اعمال عملگرهای LABP با پارامترهای  $n$  متفاوت (۳×۳، ۵×۵، ۷×۷، ۹×۹، ۲۱×۲۱) بر روی تصویر نرمال شده پایگاه داده FERT.

جدید بر مبنای اتوماتای یادگیر سلولی مبتنی بر محاسبات تکاملی (CLA-EC) برای حل مسأله انتخاب ویژگی ارائه شده است. الگوریتم CLA-EC، یک الگوریتم تکاملی است که از ترکیب اتوماتای یادگیر سلولی (CLA) و مفاهیم محاسبات تکاملی (EC) به دست آمده و در روش پیشنهادی دقت طبقه‌بندی و تعداد ویژگی‌های انتخاب نشده (Zeroها) به عنوان معیار ارزیابی در نظر گرفته شده است. روش پیشنهادی بدون داشتن اطلاعات اولیه از ویژگی‌ها می‌تواند بهترین زیرمجموعه از ویژگی‌ها را انتخاب کند.

### ۳-۱ مفاهیم CLA-EC

یادگیری به عنوان یک پدیده تطبیقی در طول مدت بقای یک موجودیت زنده و تکامل یک فرایند بلندمدت در طی چند نسل می‌باشد. پاسخ به این سؤال که یادگیری و تکامل تا چه حد بر یکدیگر اثرگذارند، هنوز به عنوان یک مسأله باز تحقیقاتی است. تئوری‌های متفاوتی در این باره ارائه شده‌اند که دو مورد از مهم‌ترین آنها تئوری لامارکین و بالدوین می‌باشد. بر اساس تئوری لامارکین، محیط در طول زندگی جاندار بر آن تأثیر می‌گذارد و این تأثیرات بر روی ساختار ژنتیکی جاندار منعکس شده و به فرزندان منتقل می‌شود. در مقابل از دیدگاه تئوری بالدوین، یادگیری با تشویق موفقیت‌هایی که در فرایند تکامل به صورت جزئی صورت می‌پذیرند، سبب هدایت و تسریع تکامل می‌گردد [۲۰]. اگرچه نادرستی بعضی از این تئوری‌ها در حال حاضر به طور کامل از سوی محققین علوم طبیعی مورد قبول است، اما منشأ کارهایی در زمینه محاسبات، ملهم از طبیعت می‌باشد [۲۱] و [۲۲]. یکی از مدل‌هایی که از ترکیب مفاهیم تکامل و یادگیری به دست آمده، مدل CLA-EC می‌باشد که ترکیبی از مدل CLA [۲۳] و [۲۴] و محاسبات تکاملی (EC) است [۲۵]. در این مدل هر ژنوم به یکی از سلول‌های اتوماتای یادگیر سلولی اختصاص می‌یابد و مجموعه اعمال انتخاب شده توسط اتوماتاهای هر سلول به رشته ژنومی آن سلول اختصاص می‌یابد. بر اساس قانون محلی، یک بردار سیگنال تقویتی ایجاد می‌گردد و به مجموعه اتوماتاهای یادگیر مستقر در آن سلول اختصاص می‌یابد. هر یک از اتوماتاهای یادگیر بر اساس سیگنال دریافت شده و الگوریتم یادگیری، ساختار داخلی خود را به هنگام می‌کنند. فرایند انتخاب عمل‌ها و به هنگام درآوردن ساختار داخلی تا


2. Fitness Function

3. Accuracy

1. Cellular Learning Automata - Computing Evolutionary

جدول ۱: مشخصات ۵ افزاز استاندارد پایگاه داده FERET.

بخش بندی	تعداد	توضیحات
(fa) Gallery	۱۱۹۶	تصاویر با حالات عادی و خندان چهره
مجموعه fb	۱۱۹۵	تصاویر با سایر حالات چهره (غیر از خندان و عادی)
مجموعه fc	۱۹۴	تصاویر تحت نورپردازی‌های متفاوت
مجموعه Dup1	۷۲۲	تصاویر یک روز و ۱۰۳۱ روز بعد از ورودی‌های گالری
مجموعه Dup2	۲۳۴	تصاویر حداقل ۱۸ ماه بعد از ورودی‌های گالری



شکل ۴: مرزهای جداکننده دو کلاس.

فرم  $K(x_i, x_j) = (\phi(x_i) \cdot \phi(x_j))$  می‌باشند. SVM یک فوق صفحه جداکننده خطی را پیدا می‌کند که بیشترین حاشیه را برای جداکردن داده‌های آموزشی دو کلاس در فضای ویژگی ایجاد کند. بنا به تعریف، حاشیه، مجموع فاصله نزدیک‌ترین نقطه از هر دو کلاس تا صفحه جداکننده می‌باشد (شکل ۴) و  $b$  پارامتر فوق صفحه بهینه است.

SVM امکان انتخاب دامنه خاصی از توابع کرنل را می‌دهد. اگرچه کرنل‌های جدیدی پیشنهاد شده‌اند ولی تابع‌های کرنل که به طور متداول استفاده می‌شوند، کرنل‌های خطی، چندجمله‌ای و RBF هستند. ما از SVM با سه تابع کرنل متفاوت برای کلاس‌بندی استفاده کرده‌ایم و آنها را با تعدادی از تصاویر موجود از هر نفر آموزش داده‌ایم و با برخی دیگر که باقی مانده‌اند آزمایش می‌کنیم. همان طور که می‌دانیم، SVM برای جداسازی تنها دو کلاس آموزش می‌بیند. برای داشتن یک طبقه‌بندی کننده چندکلاسه، می‌توان SVM‌های دو کلاسه را با یکدیگر ترکیب کرد. دو استراتژی برای این منظور وجود دارد، استراتژی "یک مقابل یک" و استراتژی "یک مقابل همه" که استراتژی اول کارایی بهتری دارد [۲۷] و ما این استراتژی را برای آموزش به کار می‌بریم.

## ۵- آزمایش‌ها و پیاده‌سازی‌ها

شایان ذکر است که تمامی آزمایش‌ها با نرم‌افزار Matlab ۲۰۱۰ با سیستم عامل Windows ۷ Professional توسط سیستمی با مشخصات Core i3، ۲/۱۳ MHz، به همراه ۴ GB RAM انجام گرفته و برای آموزش و آزمایش از تصاویر پایگاه داده چهره FERET و AR استفاده شده است. پایگاه داده FERET توسط آزمایشگاه تحقیقات ارتش ایالات متحده<sup>۱</sup> و دانشگاه جرج میسون<sup>۲</sup> جمع‌آوری شده که به عنوان یک پایگاه محک مناسب جهت ارزیابی الگوریتم‌های شناسایی چهره شناخته شده [۲۸] و [۲۹] و تصاویر در سایز  $۳۸۴ \times ۲۵۶$  تهیه شده‌اند. تصاویر با تغییر در روشنایی، حالات چهره، زاویه سر و غیره گرفته شده‌اند. در پایگاه داده FERET کل تصاویر روبه‌روی چهره به ۵ گروه تقسیم شده (جدول ۱) و گالری یک مجموعه از تصاویر برچسب‌دار از اشخاص می‌باشد. از تصاویر گالری (fa) به عنوان تصاویر آموزشی خود استفاده کردیم. یک تصویر از چهره ناشناس که به الگوریتم بازشناس ارائه می‌شود تصویر کاوش نامیده می‌شود. ما از چهار بخش دیگر (fb, fc, dup1, dup2) به عنوان تصاویر کاوش خود استفاده کردیم. الگوریتم، تصویر کاوش را با کل نمونه‌های موجود در گالری مقایسه می‌کند.

برای اعمال تصاویر به الگوریتم نیاز به نرمال‌سازی تصاویر می‌باشد. همراه با تصاویر پایگاه داده FERET اطلاعاتی در مورد محل قرارگرفتن چشم، بینی و دهان افراد در پایگاه داده قرار داده شده است. ابتدا با توجه به مکان‌های چشم افراد، زاویه سر افراد تشخیص داده شده و با عمل

از ویژگی‌ها را شامل می‌شوند، زیرمجموعه‌ای که کمترین تعداد ضرایب را داشته باشد انتخاب می‌شود. بین دقت و اندازه زیرمجموعه‌های ویژگی، دقت بیشتر مد نظر است. ما از تابع ارزیابی که در زیر آمده است استفاده کرده‌ایم

$$\text{Fitness} = ۱۰ \cdot \text{Accuracy} + ۰.۵ \cdot \text{Zeros} \quad (۵)$$

به طوری که این تابع دقت، متناظر با دقت طبقه‌بندی برای یک زیرمجموعه خاص از ویژگی‌هاست و Zeros متناظر با تعداد الگوهای است که انتخاب نشده‌اند (به عبارت دیگر متناظر با تعداد صفرهای ژنوم). دامنه شرط دقت تقریباً بین [۰.۵, ۰.۹۹] است و دامنه شرط صفرها بین [۰, n-1] می‌باشد که  $n$  طول ژنوم می‌باشد. بر مبنای وزن‌هایی که ما به هر شرط نسبت داده‌ایم، شرط دقت در تابع ارزیابی غالب است که مبین این است که ژنوم‌هایی که دقت طبقه‌بندی کننده بالاتری دارند در مقایسه با ژنوم‌هایی که دقت طبقه‌بندی کننده پایینی دارند، بدون آن که تعداد ویژگی‌های انتخاب‌شده توسط ژنوم‌ها مد نظر قرار بگیرد برای نسل بعدی انتخاب می‌شوند (به عبارت دیگر دقت بالا، مقدار شایستگی بالاتری را نشان می‌دهد).

## ۴- بازشناسی چهره

پس از انتخاب زیرمجموعه‌های بهینه از هر گروه و ویژگی‌های استخراج‌شده توسط عملگر LABP برای هر زیرمجموعه، هیستوگرام مربوط به آن را به دست می‌آوریم و از هیستوگرام‌های به دست آمده برای آموزش ماشین بردار پشتیبان استفاده می‌کنیم. نحوه محاسبه هیستوگرام از ماتریس LABP به صورت زیر می‌باشد

$$H(k) = \sum_{i=1}^N \sum_{j=1}^M f(LABP_{p,r}(i, j), k) \quad , \quad k = [0, k] \quad (۶)$$

$$f(x, y) = \begin{cases} ۱ & x = y \\ ۰ & \text{otherwise} \end{cases}$$

ماشین بردار پشتیبان یک روش متداول برای طبقه‌بندی داده‌ها و اطلاعات است [۲۶]. SVM به طور ضمنی داده‌ها را از فضای ورودی به یک فضای ویژگی با ابعاد بالاتر نگاشت می‌دهد که در آن می‌توان از جبر خطی و هندسه برای جداکردن داده‌هایی که در فضای ورودی، تنها با قوانین غیر خطی از هم جدا می‌شوند، استفاده کرد. با در دست داشتن یک مجموعه از نمونه‌های برچسب خورده  $T = \{(x_i, y_i), i = 1, \dots, l\}$  که در آن  $x_i \in R^n$  و  $y_i \in \{1, -1\}$  می‌باشد، داده آزمایشی جدید  $x$  با استفاده از تابع زیر طبقه‌بندی می‌شود

$$f(x) = \text{sgn} \left( \sum_{i=1}^l \alpha_i y_i k(x_i, x) + b \right) \quad (۷)$$

به طوری که  $\alpha_i$  ضرایب لاگرانژ یک مسأله بهینه‌سازی دوگانه و  $K(x_i, x)$  تابع کرنل می‌باشد. با توجه به یک نگاشت غیر خطی  $\phi$  که داده‌های ورودی را به فضای ویژگی تعبیه می‌کند، کرنل‌ها به

1. U. S. Army Research Laboratory

2. George Mason

جدول ۲: اطلاعات عمومی پایگاه داده AR.

تعداد افراد	شرایط تصویربرداری	ابعاد تصویر	تعداد تصاویر
۱۱۶	حالت چهره	۴	۳۱۲۰
	روشنایی	۴	
	پوشیدگی	۲	
	زمان	۲	

جدول ۳: پارامترهای الگوریتم CLA-EC.

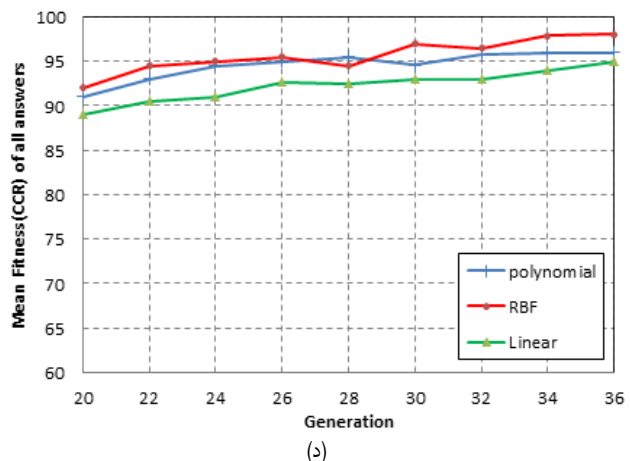



پارامترها	الگوریتم CLA-EC
اندازه جمعیت (تعداد سلول‌ها)	۷۵
تعداد تکرار	۱۰۰
شعاع همسایگی ( $r$ )	۱
تعداد سلول انتخاب شده در هر همسایگی ( $Se$ )	۲
نرخ پاداش ( $a$ )	۰٫۰۱
نرخ جزا ( $b$ )	۰٫۰۱
ضریب مقیاس ( $\alpha$ )	۰٫۱

چرخش، زاویه سر را از بین می‌بریم. سپس مقیاس بزرگ‌نمایی تصویر را تغییر داده تا فاصله مابین چشم‌ها بین تمامی تصاویر مقادیر ثابتی شود و پس از آن تصویر را با سایز  $۱۲۸ \times ۱۲۸$  برش می‌دهیم تا فقط چهره به دست آید. در مرحله آخر هموارسازی هیستوگرام بر روی تصویر اعمال می‌شود تا توزیع سطوح خاکستری هموار شود.


پایگاه داده AR در سال ۱۹۹۸ میلادی و توسط گروه بینایی ماشین شهر بارسلونا در اسپانیا تهیه شده [۳۰] و از تصاویر ۱۲۰ مرد و زن (۶۵ مرد و ۵۵ زن) تشکیل شده است. تصاویر در شرایط تصویربرداری (پارامترهای دوربین، فاصله و زاویه آن و ...) کاملاً کنترل شده اخذ شده و به صورت رنگی و با اندازه  $۷۶۸ \times ۵۷۶$  تهیه شده‌اند. از تمامی افراد در دو نوبت و به فاصله دو هفته تصویربرداری صورت پذیرفته و در هر نوبت سیزده تصویر از هر فرد تهیه شده است. این بانک داده توسط بیش از ۲۰۰ گروه تحقیقاتی مورد استفاده قرار گرفته است. در جدول ۲ اطلاعات عمومی این بانک داده شامل تعداد افراد، شرایط تصویربرداری، ابعاد و تعداد تصاویر آورده شده است. در اینجا نیز با استفاده از مختصات چشم تصاویر را نرمال کرده و آنها را به اندازه  $۱۲۸ \times ۱۲۸$  برش می‌دهیم و سپس هموارسازی هیستوگرام بر روی تصویر اعمال می‌شود. برای هر فرد ۱۴ تصویر با حالات چهره و شدت روشنایی متفاوت انتخاب کردیم، ۷ تصویر نوبت اول به عنوان تصاویر آزمایشی و ۷ تصویر نوبت دوم را به عنوان تصاویر تست استفاده کردیم.

مقادیر مختلفی برای پارامترهای روش انتخاب ویژگی توسط الگوریتم CLA-EC و ضریب مقیاس ( $\alpha$ ) آزمایش شدند و نتایج نشان داد که با مقادیر جدول ۳ بیشترین کارایی برای روش پیشنهادی به دست می‌آید. عملکرد الگوریتم پیشنهادی بر حسب تعداد ویژگی‌های انتخاب شده توسط الگوریتم CLA-EC در شکل ۵ و بر حسب نحوه تغییر میزان متوسط برازش، جواب‌های هر نسل در شکل ۶ نشان داده شده است.


از آنجا که تعداد ویژگی‌ها زیاد است، لازم است برای کارایی بالاتر طبقه‌بندی کننده، ویژگی‌های مؤثر انتخاب و بقیه حذف شوند. همان طور که مشاهده می‌شود روش پیشنهادی تنها با انتخاب ۳۶ ویژگی و بعد از ۱۰۰ نسل به دقت شناسایی بالایی رسیده است. ما منحنی ROC را بر حسب ویژگی‌های انتخاب شده توسط الگوریتم پیشنهادی CLA-EC و الگوریتم ژنتیک در شکل ۷ ترسیم نمودیم. منحنی ROC حاصل، ترسیم



شکل ۵: عملکرد سیستم بازشناسی چهره پیشنهادی بر حسب تعداد ویژگی‌های انتخاب شده توسط الگوریتم CLA-EC. (الف)  $Dup_2$ ، (ب)  $Dup_1$ ، (ج)  $fc$  و (د)  $fb$ .



(الف)



(ب)


شکل ۷: منحنی ROC با استفاده از ویژگی‌های انتخاب شده توسط (الف) الگوریتم CLA-EC و (ب) الگوریتم ژنتیک.

جدول ۴: بررسی عملکرد روش پیشنهادی با استفاده از طبقه‌بند SVM با سه کرنل متفاوت بر روی پایگاه داده FERET.

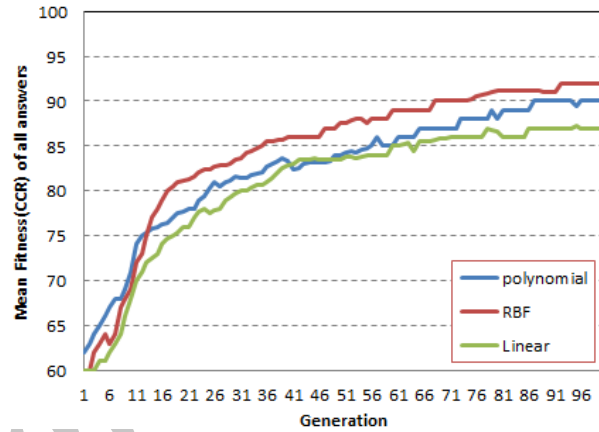
SVM with different kernels			افزایها	پایگاه داده
RBF	Polynomial	Linear		
۸۷	۸۴	۸۰	<i>Dup2</i>	FERET
۹۲	۹۰	۸۷	<i>Dup1</i>	
۹۷	۹۵	۹۳	<i>fc</i>	
۹۸	۹۶	۹۵	<i>fb</i>	

درصد تشخیص درست مثبت بر حسب درصد تشخیص اشتباه مثبت می‌باشد و هر چه مساحت زیر منحنی ROC به یک نزدیک‌تر باشد الگوریتم موفق‌تر است. همان طور که از منحنی‌های به دست آمده مشهود است، انتخاب ویژگی‌ها با استفاده از الگوریتم CLA-EC بازدهی را تا حد خوبی افزایش داده است.


عملکرد روش پیشنهادی خود را در بهترین حالت با استفاده از طبقه‌بند ماشین بردار پشتیبان با کرنل‌های متفاوت بر روی پایگاه داده FERET مورد بررسی قرار دادیم و نتایج حاصل از آن در جدول ۴ آورده شده و همچنین در جدول ۵ نتایج حاصل از مقایسه الگوریتم پیشنهادیمان با الگوریتم‌های مختلف روی پایگاه داده FERET آمده است. همچنین جهت مقایسه بیشتر در جدول ۶ نتایج حاصل از مقایسه الگوریتم پیشنهادی با دو الگوریتم دیگر که بر پایه الگوریتم LBP بودند روی پایگاه داده AR آورده شده است. در شکل ۸ برخی از تصاویری که توسط الگوریتم پیشنهادی به اشتباه تشخیص داده شده، آورده شده است. علت تشخیص نادرست در این الگوریتم را می‌توان این گونه توجیه




(الف)



(ب)



(ج)



(د)

شکل ۶: تغییرات مقدار متوسط براز دقت تشخیص چهره بر روی افزایش‌های مختلف پایگاه داده FERET (جواب‌ها در هر نسل، (الف) *Dup2*، (ب) *Dup1*، (ج) *fc* و (د) *fb*)

جدول ۵: مقایسه عملکرد روش پیشنهادی با الگوریتم‌های دیگر بر روی پایگاه داده FERET.

نوع روش شناسایی		پایگاه داده			
		انوارها	LDA	Gabor	Hierarchical Multi-scale LBP [۱۱]
FERET	Dup2	۳۱	۵۳	۶۷	۸۷
	Dup1	۵۵	۶۸	۸۳	۹۰
	fc	۷۳	۷۴	۸۸	۹۴
	fb	۹۱	۹۴	۹۱	۹۷
	Proposed Method (with RBF)				
	Multi-scale Block LBP [۱۴]				

جدول ۶: مقایسه عملکرد روش پیشنهادی با الگوریتم‌های دیگر بر روی پایگاه داده AR.

نوع روش شناسایی			
پایگاه داده AR	Hierarchical Multi-scale LBP [۱۱]	Multi-scale Block LBP [۱۴]	Proposed Method (with RBF)
۹۷٫۴۸	۹۹٫۱۵	۹۹٫۵۳	

## ۶- نتیجه گیری

در این مقاله، یک سیستم بازشناسی چهره جدید بر مبنای الگوی باینری محلی ارائه شده است. در روش پیشنهادی، جهت به دست آوردن نمایش ویژگی مقاوم‌تر، در LBP نقاط نمونه زیادی را مورد استفاده قرار دادیم و محاسبات بر حسب میانگین مقادیر خاکستری به جای مقادیر پیکسل انجام گرفت. به علاوه چون روش‌های چندمقیاسه می‌تواند ویژگی‌ها و الگوهای تفکیک‌کننده بیشتری را تحت تنظیمات متفاوت ارائه دهد، در نتیجه در روش خود، اندازه پنجره‌ای را که در آن مقادیر میانگین پیکسل‌های موجود محاسبه می‌شوند را به عنوان پارامتر  $(n)$  در نظر گرفتیم، به طوری که  $n \times n$  مقیاس عملگر الگوی باینری محلی می‌باشد. همچنین به جای استفاده از حد آستانه ثابت  $\theta$ ، مقدار آن را بر حسب مقدار انحراف استاندارد  $P$ ، مقدار همسایه از پیکسل مرکزی در تصویر اصلی  $(\sigma)$  و یک ضریب مقیاس  $(\alpha)$  در نظر گرفته‌ایم.

در روش پیشنهادی، ابتدا الگوهای یکنواخت از تصویر بر مبنای عملگر LBP بهینه شده استخراج شده و سپس از هیستوگرام بهترین زیرمجموعه از الگوهای انتخاب شده توسط الگوریتم بهینه‌ساز CLA-EC برای آموزش طبقه‌بند SVM استفاده می‌شود. الگوریتم CLA-EC خیلی سریع به راه حل‌های بهینه همگرا می‌شود و همچنین این الگوریتم توانایی زیادی در جستجوی فضای راه حل‌ها دارد و می‌تواند کوچک‌ترین زیرمجموعه از ویژگی‌ها را پیدا کند. در آن دقت طبقه‌بندی و تعداد ویژگی‌های انتخاب نشده (zeroها) به عنوان معیار تابع ارزیابی در نظر گرفته شده‌اند. از طرفی نتایج نشان می‌دهد با تعداد نسبتاً کمی از ژنومها (سلول‌ها یا جمعیت)، مسایلی با تعداد ویژگی‌های زیاد قابل بهینه‌سازی می‌باشند. نتایج به دست آمده از آزمایش روش جدید روی مجموعه داده FERET، برتری روش جدید را در حل مسأله بازشناسی چهره نسبت به سایر روش‌ها نشان داد.



(الف)



(ب)

شکل ۸: برخی از تصاویر به اشتباه تشخیص داده شده توسط الگوریتم پیشنهادی، (الف) تصاویر نرمال پایگاه داده FERET و (ب) تصاویر نرمال پایگاه داده AR.

کرد که روش استخراج ویژگی در الگوریتم ما بر روی بافت کلی تصویر و بر حسب مقادیر میانگین پیکسل‌های همسایه می‌باشد، از این رو تصاویری که دارای میانگین بافتی تقریباً یکسانی می‌باشند اشتباه تشخیص داده می‌شوند.

نتایج نشان می‌دهد که روش پیشنهادی ما، عملکرد بهتری نسبت به بقیه روش‌ها داشته است به طوری که روش ما روی پایگاه داده FERET به طور متوسط دارای صحت تشخیص ۹۳/۵٪ می‌باشد در حالی که این میزان برای Hierarchical Multi-scale LBP حدود ۸۲٪ و برای Multi-scale Block LBP حدود ۸۹/۵٪ می‌باشد. همچنین روی پایگاه داده AR، روش پیشنهادی با دقت شناسایی ۹۹/۵۳٪ برتری خود را نسبت به الگوریتم دیگر نشان داده است. نکته‌ای که در این آزمایش مهم است پیچیدگی زمانی محاسبات برای روش‌های مبتنی بر الگوی باینری محلی (Multi-scale Block LBP و Hierarchical Multi-scale LBP) روش پیشنهادی در این مقاله می‌باشد. برای این منظور، زمان اجرا برای تصاویر آموزشی  $fa$  و تصاویر تست Dup2 بر روی پایگاه داده FERET محاسبه شد. محاسبات روش Hierarchical Multi-scale LBP استاندارد در زمان ۳۹۷ و روش پیشنهادی، ۳۷۰ ثانیه انجام پذیرفته است. مشاهده می‌شود با این که در [۱۱] از طبقه‌بند ساده Knn استفاده شده است زمان اجرای آن از الگوریتم پیشنهادی که از طبقه‌بند SVM استفاده کرده بیشتر شده است. دلیل بیشتر بودن زمان اجرای الگوریتم [۱۱] این است که در آن از کل ویژگی‌های مستخرج از تصویر جهت مقایسه استفاده شده و همچنین به صورت سلسله مراتبی به طور میانگین ۲ مرتبه از الگوریتم LBP که بسیار زمان‌بر است، استفاده کرده است. همان طور که مشاهده می‌شود با صرف زمان اجرایی کم روش پیشنهادی در مقایسه با روش‌های مذکور به دقت بازشناسی بالاتری دست یافته است به طوری که دقت روش ما به طور متوسط حدود ۷/۷۵٪ دقت بالاتر رفته است.

Department of Computer Science, St. Cloud State University, St. Cloud, US, 1999.

- [23] B. Masoodi, M. R. Meybodi, and M. Hashemi, "Cooperative CLA-EC," in *Proc. of 12th Annual CSI Computer Conf. of Iran, Shahid Beheshti University, Tehran, Iran*, pp. 558-559, Feb. 2007.
- [24] B. Masoodifar, M. R. Meybodi, and R. Rastegar, "Asynchronous CLA-EC," in *Proc. of 11th Annual CSI Computer Conf. of Iran*, Tehran, Iran, pp. 447-458, Jan. 2006.
- [25] R. Rastegar and M. R. Meybodi, "A new evolutionary computing model based on cellular learning automata," in *Proc. of IEEE Int. Conf. on Cybernetics and Intelligent Systems*, vol. 1, pp. 433-438 Singapore, 1-3 Dec. 2004.
- [26] V. N. Vapnik, *Statistical Learning Theory*, Wiley, New York, 1998.
- [27] M. Pontil and A. Verri, "Support vector machines for 3-d object recognition," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 20, no. 6, pp. 637-646, Jun. 1998.
- [28] P. J. Phillips, H. Moon, S. A. Rizvi, and P. J. Rauss, "The FERET evaluation methodology for face recognition algorithms," *IEEE Trans. Pattern Analysis and Machine Analysis*, vol. 22, no. 10, pp. 1090-1104, Oct. 2000.
- [29] P. J. Phillips, H. Wechsler, J. Huang, and P. Rauss, "The FERET database and evaluation procedure for face recognition algorithms," *Image Vis. Comput. J.*, vol. 16, no. 5, pp. 295-306, 1998.
- [30] A. R. Martinez and R. Benavente, *The AR Face Database*, Barcelona, Spain, 1998.

**اختر حضرتی بی‌شک** در سال ۱۳۸۵ مدرک کارشناسی مهندسی کامپیوتر خود را از دانشگاه رازی کرمانشاه و در سال ۱۳۹۰ مدرک کارشناسی ارشد هوش مصنوعی را از دانشگاه آزاد اسلامی واحد قزوین دریافت نمود. نام‌برده هم‌اکنون در دانشگاه آزاد اسلامی، واحد اهر، باشگاه پژوهشگران جوان و نخبگان، اهر مشغول به فعالیت می‌باشد. زمینه‌های علمی مورد علاقه ایشان متنوع بوده و شامل موضوعاتی مانند ایده‌های نو در بینایی ماشین، یادگیری ماشین، شناسایی آماری الگو، ریاضیات و هوش مصنوعی می‌باشد.

**کریم فائز** تحصیلات خود را در مقطع کارشناسی مهندسی برق در سال ۱۳۵۲ در دانشگاه پلی‌تکنیک ایران، در مقطع کارشناسی ارشد در سال ۱۳۵۶ در دانشگاه کالیفرنیا - لوس آنجلس - آمریکا و دکتری تخصصی نرم‌افزار کامپیوتر را در دانشگاه کالیفرنیا - لوس آنجلس - آمریکا در سال ۱۳۵۹ به پایان رسانده است. پس از بازگشت به ایران ۲ سال در مرکز تحقیقات مخابرات به‌عنوان محقق مشغول به کار بوده است. از سال ۶۲ تا کنون استاد دانشکده مهندسی برق و دانشگاه صنعتی امیرکبیر می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان، شناسایی الگو و پردازش تصاویر، شبکه‌های کامپیوتری می‌باشد.

**حسین برقی چند** در سال ۱۳۸۸ کارشناسی مهندسی نرم افزار و در سال ۱۳۹۰ کارشناسی ارشد مهندسی مکترونیک را به ترتیب از دانشگاه جامع علمی کاربردی و دانشگاه آزاد اسلامی دریافت نمود. نام‌برده هم‌اکنون دانشجوی دکتری مهندسی کامپیوتر در دانشگاه فنی کارادینز کشور ترکیه می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان در زمینه مهندسی مکترونیک و ریاضیات است. به طور جزئی‌تر طرح‌ریزی خط سیر و مسیر رباتهای متحرک، بینایی کامپیوتری، یادگیری مبتنی بر شبکه عصبی، مسائل کنترل بهینه و تئوری بازی‌ها جزء زمینه‌های مطالعاتی نام‌برده می‌باشد.

**سجاد قطعی** در سال ۱۳۸۵ مدرک کارشناسی مهندسی کامپیوتر خود را از دانشگاه آزاد اسلامی واحد شبستر و در سال ۱۳۸۹ مدرک کارشناسی ارشد مهندسی هوش مصنوعی خود را از دانشگاه آزاد اسلامی واحد قزوین دریافت نمود. مهندس قطعی از سال ۱۳۸۹ در دانشگاه پیام نور استان آذربایجان شرقی مشغول به فعالیت گردید و اینک نیز عضو هیأت‌علمی این دانشگاه می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: شبکه‌های عصبی، الگوریتم‌های هوش دسته‌جمعی، پردازش تصویر و ژنتیک می‌باشد.

## مراجع

- [1] W. Zhao, R. Chellappa, P. J. Phillips, and A. Rosenfeld, "Face recognition: a literature survey," *ACM Computing Survey*, vol. 35, no. 4, pp. 399-458, Dec. 2003.
- [2] M. Turk and A. Pentland, "Face recognition using eigenfaces," in *Proc. IEEE Conf. on Computer Vision and Pattern Recognition, CVPR'91*, pp. 586-591, 3-6 Jun. 1991.
- [3] P. Belhumeur, J. Hespanha, and D. Kriegman, "Eigenfaces vs fisherfaces: recognition using class specific linear projection," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 19, no. 7, pp. 711-720, Jul. 1997.
- [4] D. Zhang, A. Kong, J. You, and M. Wong, "Online palmprint identification," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 25, no. 9, pp. 1041-1050, Sep. 2003.
- [5] R. Gross, *Handbook of Face Recognition*, Springer-Verlag, 2005.
- [6] R. Chellappa, C. L. Wilson, and S. Sirohey, "Human and machine recognition of faces: a survey," *Proceedings of the IEEE*, vol. 83, pp. 705-741, May 1995.
- [7] B. Scholkopf, A. J. Smola, and K. R. Muller, "Nonlinear component analysis as a kernel eigenvalue problem," *Neural Computation*, vol. 10, no. 5, pp. 1299-1319, Jul. 1998.
- [8] T. Ojala, M. Pietikainen, and M. Harwood, "A comparative study of texture measures with classification based on feature distributions," *Pattern Recognition*, vol. 29, no. 1, pp. 51-59, Jan. 1996.
- [9] T. Ahonen, M. Pietikainen, A. Hadid, and T. Manepa, "Face recognition based on the appearance of local regions," in *Proc. Int. Conf. on Pattern Recognition*, vol. 3, pp. 153-156, 23-26 Aug. 2004.
- [10] Z. Xie and G. Liu, "Infrared face recognition based on intensity of local micropattern-weighted local binary pattern," *Optical Engineering*, vol. 50, no. 7, Jul. 2011, doi: 10.1117/1.3594788.
- [11] Z. Guo, L. Zhang, D. Zhang, and X. Mou, "Hierarchical multiscale LBP for face and palm print recognition," in *Proc. Int. Conf. on Image Processing*, pp. 4521-4524, 26-29 Sep. 2010.
- [12] J. Shelton, et al., "Genetic based LBP feature extraction and selection for facial recognition," in *Proc. of 49th Annual Southeast Regional Conf.*, pp. 197-200, Kennesaw, GA, US, Mar. 2011.
- [13] R. Mehta, J. Yuan, and K. Egiazarian, "Local polynomial approximation-local binary pattern (LPA-LBP) based face classification," in *SPIE Proceedings, Multimedia on Mobile Devices 2011; and Multimedia Content Access: Algorithms and Systems*, vol. 7881, 8 pp. 11 Feb. 2011.
- [14] S. Liao, X. Zhu, Z. Lei, L. Zhang, and S. Li, "Learning multi-scale block local binary patterns for face recognition," in: Lee, S. W., Li, S., *Advances in Biometrics*. Springer Berlin/Heidelberg, vol. 4642 of Lecture Notes in Computer Science, pp. 828-837, 2007.
- [15] T. Ojala, M. Pietikainen, and T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 24, no. 7, pp. 971-987, Jul. 2002.
- [16] Z. Zhang, M. J. Lyons, M. Schuster, and S. Akamatsu, "Comparison between geometry-based and gabor-wavelets-based facial expression recognition using multi-layer perceptron," in *Proc. 3rd Conf. Automatic Face and Gesture Recognition*, pp. 454-459, 14-16 Apr. 1998.
- [17] [http://www.ee.oulu.fi/mvg/page/lbp\\_bibliography](http://www.ee.oulu.fi/mvg/page/lbp_bibliography).
- [18] R. Jensen, *Combining Rough and Fuzzy Sets for Feature Selection*, Ph.D. Thesis, University of Edinburgh, 2005.
- [19] M. Kudo and J. Sklansky, "Comparison of algorithms that select features for pattern classifiers," *Pattern Recognition*, vol. 33, no. 1, pp. 25-41, 2000.
- [20] T. P. Riopka and P. Bock, "Intelligent recombination using individual learning in a collective learning genetic algorithm," in *Proc. of the Genetic and Evolutionary Computation Conf., GECCO'00*, pp. 104-111, Las Vegas, Nevada, US, 10-12 Jul. 2000.
- [21] D. Whitley, V. S. Gordon, and K. Mathias, "Lamarckian evolution, the baldwin effect and function optimization," *Parallel Problem Solving from Nature III*, Springer-Verlag, 1994.
- [22] B. A. Julstrom, "Comparing darwinian, baldwinian, and lamarckian search in genetic algorithm for 4-cycle problem," Technical Report,