

بهبود کارایی روش سنتی آشکارسازی چهره مبتنی بر ماشین بردار پشتیبان

مجید روحی، قاسم میرجلیلی و محمدتقی صادقی

می‌باشد. برای داشتن یک سیستم آشکارسازی دقیق و مطلوب نیاز به طبقه‌بندی کننده‌ای است که بتواند یک مجموعه وسیع از داده‌های آموزشی با ابعاد بزرگ را حمایت کند. یک گزینه مناسب برای تحقق این هدف، ماشین بردار پشتیبان² (SVM) می‌باشد. ماشین بردار پشتیبان یک روش برای طبقه‌بندی الگو است که برای اولین بار توسط Vapnik معرفی شد [2] و [3]. هدف ما در این مقاله، بهبود روش سنتی آشکارسازی چهره مبتنی بر ماشین بردار پشتیبان می‌باشد. ساختار این مقاله بدین صورت است: در بخش دوم، اصول ماشین بردار پشتیبان به‌طور خلاصه بیان می‌شود. در بخش سوم، روش سنتی آشکارسازی چهره با استفاده از ماشین بردار پشتیبان معرفی می‌شود. در بخش چهارم روش پیشنهادی مطرح گردیده و در نهایت در بخش آخر، نتایج شبیه‌سازی ارائه می‌شود.

2- ماشین بردار پشتیبان

در این بخش به‌طور خلاصه، ماشین بردار پشتیبان (SVM) به‌عنوان یک طبقه‌بندی کننده معرفی می‌شود [2] تا [5].

ابتدا ساده‌ترین حالت که در آن داده‌ها به‌طور خطی جداپذیر هستند را در نظر بگیرید. فرض کنید $D = \{(X_i, y_i)\}_{i=1}^l$ یک مجموعه داده شامل l نمونه X_i با برچسب‌های $y_i \in \{-1, 1\}$ از دو کلاس (چهره و غیر چهره) باشد. حال می‌خواهیم این دو کلاس را به‌طور خطی از هم جدا کنیم. در نگاه اول می‌توان تعداد زیادی فوق صفحه برای جداکردن این دو مجموعه در نظر گرفت. حال این سؤال پیش می‌آید که کدام یک از این فوق صفحات جداکننده بهینه می‌باشد و کمترین خطا را برای جداسازی ایجاد می‌کند؟ به‌طور حسی می‌توان گفت که مناسب‌ترین انتخاب، صفحه‌ای است که بیشترین حاشیه را بین دو کلاس ایجاد کند. بنا به تعریف، حاشیه مجموع فاصله نزدیک‌ترین نقطه از هر دو کلاس تا صفحه جداکننده می‌باشد (شکل 2).

حال فرض کنید داده‌ها به‌طور خطی جداپذیر نباشند. باز هم می‌توان مانند حالت قبل، فوق صفحه‌ای را تعیین کرد که دو کلاس را به‌طور خطی با بیشترین حاشیه و کمترین خطا از هم جدا کند. تعادل بین حاشیه و خطای نمونه‌های غلط طبقه‌بندی شده را می‌توان توسط مقدار مثبت C که از قبل تعیین می‌شود کنترل کرد. در این حالت می‌توان نشان داد که تابع تصمیم‌گیری $f(x)$ به فرم زیر بیان می‌شود

$$f(x) = \text{sign}\left(\sum_{i=1}^l \lambda_i y_i X_i^T X + b\right) \quad (1)$$

که λ_i ها ضرایب لاگرانژ حاصل از حل معادله زیر می‌باشند

چکیده: در این مقاله ایده‌هایی برای بهبود کارایی روش سنتی آشکارسازی چهره با استفاده از ماشین بردار پشتیبان، پیشنهاد شده است. در روش سنتی، ابتدا تصویر ورودی به پنجره‌هایی همپوشان با ابعاد ثابت تقسیم و در نهایت برای هر پنجره در مورد این که حاوی چهره هست یا نه، تصمیم‌گیری می‌شود. نرخ آشکارسازی و خطای هشدار غلط این روش خیلی مطلوب نیست. در این مقاله برای بهبود کارایی، به‌جای استفاده از پنجره با ابعاد ثابت از پنجره‌هایی با اندازه‌های مختلف استفاده می‌شود. هر پنجره دارای دقت خاصی در آشکارسازی است. در این روش، تصمیمات حاصل از به‌کارگیری پنجره‌های مختلف روی یک ناحیه از تصویر، با هم ادغام می‌شوند. همچنین در این مقاله از یک سطح تصمیم‌گیری وفقی برای تصمیم‌گیری در خروجی طبقه‌بندی کننده استفاده شده است. از طرفی به‌جای این که تصمیم‌گیری برای هر پنجره فقط متکی بر خروجی ماشین بردار پشتیبان باشد، از معیارهای شباهت‌سنجی بین پنجره مربوطه با مدلی از چهره برای تصمیم‌گیری نهایی استفاده می‌گردد. نتیجه به‌کارگیری اینترفندها، افزایش نرخ آشکارسازی و همچنین کاهش خطای هشدار غلط است. نتایج شبیه‌سازی با استفاده از مجموعه داده استاندارد، این مسئله را تأیید می‌کند.

کلیدواژه: آشکارسازی چهره، ادغام تصمیمات، ماشین بردار پشتیبان.

1- مقدمه


مسأله آشکارسازی چهره در دو دهه اخیر به‌طور خاص مورد توجه محققین قرار گرفته است. این توجه به علت کاربردهای فراوان آن در سیستم‌های بازشناسی چهره، طراحی رابط‌های بین انسان و ماشین، سیستم‌های نظارتی و امنیتی و ... است. آشکارسازی چهره در واقع مشخص کردن محل قرارگرفتن چهره انسان در یک تصویر داده‌شده صرف نظر از تغییرات حالت صورت، تغییرات وضع قرارگرفتن صورت (نیم‌رخ، تمام‌رخ و ...) و تغییرات روشنایی تصویر است. برای این کار نیاز به تابعی برای تفکیک کردن الگوهای چهره از سایر الگوها می‌باشد [1]. هر سیستم آشکارسازی چهره شامل چهار بخش اصلی است که هر کدام به سهم خود دارای اهمیت است (شکل 1). این بخش‌ها شامل پیش‌پردازش، استخراج ویژگی‌ها، طبقه‌بندی کننده و پس‌پردازش¹ می‌باشد. یکی از مشکلات سیستم‌های آشکارسازی چهره از یک طرف نیاز به تعداد زیاد نمونه‌ها برای آموزش و از طرف دیگر زیادبودن تعداد ویژگی‌ها برای بیان هر نمونه یا به‌عبارت دیگر بزرگ‌بودن بعد داده

این مقاله در تاریخ 3 اردیبهشت ماه 1387 دریافت و در تاریخ 8 دی ماه 1387 بازنگری شد. این تحقیق توسط مرکز تحقیقات مخابرات ایران پشتیبانی شده است. مجید روحی، قاسم میرجلیلی و محمدتقی صادقی، دانشکده مهندسی برق و کامپیوتر، دانشگاه یزد.

(emails: majid_roohi@yahoo.com, mirjalily@yazduni.ac.ir, m.sadeghi@yazduni.ac.ir).

1. Post Processing


2. Support Vector Machine



شکل 1: شمای کلی یک سیستم آشکارسازی چهره.

جدول 1: توابع کرنل معروف [3].

نوع طبقه بندی کننده	تابع کرنل
Gaussian RBF	$K(X, X_i) = \exp(-\ X - X_i\ ^2)$
Polynomial of degree d	$K(X, X_i) = (X^T X_i + 1)^d$
Multi Layer Perceptron	$K(X, X_i) = \tanh(X^T X_i - \theta)$



شکل 2: مرزهای جداکننده دو کلاس [2].

λ_i ها از حل معادله‌ای مشابه با (2) به دست می‌آیند با این تفاوت که $D_{ij} = y_i y_j K(X_i, X_j)$ در نظر گرفته می‌شود. جدول 1، تعدادی از توابع کرنل معروف که معمولاً در آموزش ماشین بردار پشتیبان از آنها استفاده می‌شود را نشان می‌دهد.

نکته دیگری که باید در اینجا به آن توجه کرد روشی است که برای حل (2) یا به عبارتی برای آموزش ماشین بردار پشتیبان استفاده می‌شود. این روش اولاً باید قابل استفاده برای چنین مسأله‌ای با تعداد داده‌های زیاد و ابعاد بزرگ باشد، دوم این که از سرعت خوبی برخوردار باشد و در نهایت به یک جواب بهینه همگرا شود. تاکنون روش‌های مختلفی برای آموزش ماشین بردار پشتیبان مطرح شده است [6]. در این مقاله از روش معروف SVM^{light} [7] که سرعت بالایی دارد، استفاده شده است.

$$\begin{aligned} & \text{Minimize}_{\Lambda} \quad W(\Lambda) = -\Lambda^T I + \frac{1}{2} \Lambda^T D \Lambda \\ & \text{subject to} \quad \Lambda^T y = 0 \\ & \quad \Lambda - C I \leq 0 \\ & \quad -\Lambda \leq 0 \end{aligned} \quad (2)$$

و $(\Lambda)_i = \lambda_i$ ، $(I)_i = 1$ و $D_{ij} = y_i y_j X_i^T X_j$. با حل معادله بالا به یک سری ضرایب لاگرانژ غیر صفر می‌رسیم که متناظر با تعدادی از داده‌های آموزشی هستند. البته تعدادشان نسبت به تعداد کل داده‌های موجود در پایگاه داده آموزشی کم می‌باشد. بقیه ضرایب هم که متناسب با دیگر داده‌ها هستند، صفر می‌شوند. به داده‌هایی که ضریب لاگرانژ متناظر با آنها غیر صفر می‌باشد، بردار پشتیبان می‌گویند. بردارهای پشتیبان روی مرز بین دو کلاس قرار می‌گیرند [2].

در عمل استفاده از طبقه بندی کننده خطی جهت جدا کردن داده‌های غیر خطی، سبب کاهش چشم‌گیر کارایی می‌شود. لذا بهتر است از طبقه بندی کننده غیر خطی استفاده شود. این کار به راحتی با تصویر کردن داده‌ها به یک فضای ویژگی با ابعاد بالاتر امکان پذیر می‌باشد

$$X \in R^d \Rightarrow Z(X) \equiv (\phi_1(X), \dots, \phi_n(X)) \in R^n \quad (3)$$

حال می‌توان روابط مربوط به طبقه بندی کننده خطی را در این فضای جدید نوشت. در نتیجه، تابع تصمیم‌گیری مربوط به این حالت به فرم زیر تبدیل می‌شود

$$f(x) = \text{sign}\left(\sum_{i=1}^l \lambda_i y_i Z^T(X) Z(X_i) + b\right) \quad (4)$$

نکته کلیدی درباره ماشین بردار پشتیبان این است که برای محاسبه توابع تصمیم‌گیری، تنها مقداری که باید محاسبه شود حاصل ضرب نقطه‌ای $Z^T(X) Z(X_i)$ می‌باشد. برای راحتی کار، تابع کرنل K معرفی می‌شود

$$Z^T(X) Z(Y) = \sum_{i=1}^{\infty} \alpha_i \phi_i(X) \phi_i(Y) = K(X, Y) \quad (5)$$

که $\{\alpha_i\}_{i=1}^{\infty}$ و $\{\phi_i\}_{i=1}^{\infty}$ به ترتیب یک سری اعداد و توابع حقیقی می‌باشند. به این ترتیب، تابع تصمیم‌گیری به فرم زیر تبدیل می‌شود

$$f(x) = \text{sign}\left(\sum_{i=1}^l \lambda_i y_i K(X, X_i) + b\right) \quad (6)$$

3- روش سنتی آشکارسازی چهره با استفاده از ماشین بردار پشتیبان

روش‌های مختلفی برای پیاده‌سازی الگوریتم آشکارسازی چهره بر اساس ماشین بردار پشتیبان مطرح شده است. معروف‌ترین این روش‌ها روشی است که توسط Osuna بیان شد [4]. این روش، اساس روش‌های ابداعی دیگر قرار گرفت. در اکثر کارهای جدید از ایده به کارگیری روش‌های سلسله مراتبی برای کاهش پیچیدگی و استفاده از توابع کرنل و پیش‌پردازش‌های مختلف برای بهبود سیستم استفاده شده است [8] تا [13]. ما در این مقاله از ایده جدید ادغام تصمیمات و استفاده از روش‌های وفقی برای افزایش کارایی استفاده کرده‌ایم. الگوریتم پایه Osuna برای آموزش ماشین بردار پشتیبان به شرح زیر می‌باشد:

ابتدا سیستم با یک پایگاه داده از الگوهای 19×19 پیکسلی چهره و غیره چهره، آموزش داده می‌شود. این فرایند از یک تابع کرنل چندجمله‌ای درجه دوم با حد بالایی $C = 200$ برای داشتن یک خطای آموزشی مناسب استفاده می‌کند. لازم به ذکر است که به منظور تطبیق با تغییرات موجود در تصاویر از یک سری پیش‌پردازش‌ها استفاده می‌شود. این پیش‌پردازش‌ها شامل ماسک کردن¹، اصلاح نور و همسان‌سازی هسیتوگرام می‌باشد. بعد از آموزش ماشین بردار پشتیبان، می‌توان از آن به عنوان یک طبقه بندی کننده به صورت زیر استفاده کرد:

- انجام مقیاس بندی² مکرر روی تصویر ورودی با ضریب مقیاس $1/2$.
- انتخاب الگوهایی به ابعاد 19×19 پیکسلی از تصویر مقیاس بندی شده به کمک یک پنجره لغزنده با ابعاد ثابت.

1. Masking
2. Scaling

علت انتخاب پنجره‌هایی با این ابعاد، این است که این پنجره‌ها هر یک به تنهایی توسط سایر محققان در کاربردهای مرتبط با پردازش چهره مورد استفاده قرار گرفته است. ما در این مقاله از ادغام تصمیمات حاصل از به کارگیری پنجره‌های مختلف استفاده کرده‌ایم.

نکته دوم: در ماشین بردار پشتیبان از یک سطح آستانه ثابت (T) برای تصمیم‌گیری استفاده می‌شود. اگر مقدار تابع تصمیم‌گیری $f(X)$ از مقدار آستانه کوچک‌تر بود، الگو، غیر چهره تشخیص داده می‌شود و اگر مقدار تابع تصمیم‌گیری $f(X)$ از مقدار آستانه بزرگ‌تر بود، الگو، چهره تشخیص داده می‌شود.

در مرحله آموزش اگر نمونه‌های چهره و غیر چهره به گونه‌ای باشند که یک طبقه‌بندی کننده خطی بدون خطا داشته باشیم، این سطح آستانه را می‌توان برابر صفر انتخاب کرد. در عمل، پراکندگی غیر چهره‌ها به اندازه‌ای است که یک طبقه‌بندی کننده خطی نمی‌توان طراحی کرد و باید از طبقه‌بندی کننده غیر خطی استفاده کرد. این عمل، خطای طبقه‌بندی را به دنبال دارد به گونه‌ای که ممکن است تعدادی از نمونه‌های هر طبقه در طبقه‌ای دیگر قرار گیرد. مقدار سطح آستانه برای تصمیم‌گیری در این حالت نقش مهمی در نرخ آشکارسازی و همچنین نرخ هشدار غلط دارد.

در روش پیشنهادی، از یک سطح آستانه وقتی برای تصمیم‌گیری در خروجی طبقه‌بندی کننده استفاده می‌شود. این سطح آستانه به‌ازای هر تصویر جداگانه محاسبه می‌شود. بدین منظور، ابتدا تصویر تحت آزمایش توسط پنجره مورد نظر قطعه‌بندی می‌شود. سپس هر قطعه به برداری از ویژگی‌ها (که در اینجا همان پیکسل‌های تصویر می‌باشند)، تبدیل می‌شود. در نهایت برای کل قطعه‌ها، ماتریسی از ویژگی‌ها خواهیم داشت به گونه‌ای که تعداد سطرهای این ماتریس بیانگر تعداد قطعه‌ها و تعداد ستون‌ها بیانگر تعداد ویژگی‌ها می‌باشد. حال برای هر قطعه، مقدار تابع تصمیم‌گیری محاسبه و تفاوت آن از سطح صفر تعیین می‌شود. از مقادیر به دست آمده به‌ازای کلیه قطعات، یک بردار ستونی ایجاد می‌شود. در نهایت مقادیر منفی از این بردار حذف شده، میانگین بقیه مقادیر به عنوان سطح آستانه تصمیم‌گیری انتخاب می‌شود (شکل 3).

پس از انتخاب سطح آستانه، مقدار تابع تصمیم‌گیری هر قطعه با این سطح جدید مقایسه می‌شود. اگر از این سطح بزرگ‌تر بود، قطعه معادل آن به عنوان چهره و در غیر این صورت غیر چهره تشخیص داده می‌شود. این روند برای مقیاس‌بندی‌های مختلف یک تصویر تکرار می‌شود.

نتایج بیانگر این است که انتخاب وقتی سطح آستانه باعث بهبود نرخ آشکارسازی و کاهش خطای هشدار غلط به میزان قابل قبولی می‌شود.

دلیل انتخاب شیوه فوق برای تعیین سطح آستانه را می‌توان بدین صورت بیان کرد: در یک تصویر معمولی و با تعداد چهره‌های محدود با قاطعیت می‌توان گفت که تعداد پنجره‌های مربوط به اجزای غیر چهره به مراتب بیشتر از پنجره‌های مربوط به چهره است. برای اکثر این الگوهای غیر چهره، مقدار تابع تصمیم‌گیری ماشین بردار پشتیبان کمتر از صفر است. برای تعداد محدودی از این غیر چهره‌ها، تابع تصمیم‌گیری دارای مقداری مثبت می‌باشد. اگر سطح تصمیم‌گیری را صفر در نظر بگیریم، این نمونه‌های غیر چهره، به اشتباه چهره تشخیص داده می‌شوند. بررسی‌های ما نشان داد که فاصله این نمونه‌های غلط طبقه‌بندی شده از سطح آستانه صفر بسیار کم است. از طرف دیگر مقدار تابع تصمیم‌گیری برای نمونه‌های چهره بزرگ‌تر از صفر بوده و اکثرشان فاصله قابل قبولی از سطح صفر دارند. همچنین فاصله بین نمونه‌های چهره و نمونه‌های غیر چهره‌ای که بزرگ‌تر از صفر هستند قابل ملاحظه است، ولی مرز مشترک بین این دو دقیقاً قابل محاسبه نیست. با استفاده از این روش

- انجام پیش‌پردازش‌های اولیه از قبیل ماسک‌کردن، اصلاح نور و همسان‌سازی هیستوگرام روی الگوهای 19×19 پیکسلی.
- طبقه‌بندی الگوی آماده‌شده با ماشین بردار پشتیبان (رابطه 6).
- اگر الگو چهره بود، کشیدن یک مستطیل با ابعاد 19×19 در محل قرار گرفتن الگو.

در سال‌های اخیر تلاش‌هایی برای بهبود این روش صورت گرفته است. ایده‌های جدید، یا مبتنی بر تغییر در ساختار ماشین بردار پشتیبان و نحوه آموزش آن و یا بر اساس تغییر در نحوه استخراج ویژگی‌ها و انجام پیش‌پردازش می‌باشند. باید توجه کرد که هدف از به کارگیری این ایده‌ها، یا افزایش سرعت در رسیدن به جواب و یا رسیدن به نرخ آشکارسازی بالاتر و خطای هشدار غلط کمتر می‌باشد. از ایده‌های مهمی که برای استفاده مؤثر از ماشین بردار پشتیبان در آشکارسازی چهره در سال‌های اخیر مطرح شده، می‌توان به استفاده از روش‌های ICA^2 ، PCA^1 و DFA^3 [9] و [10] اشاره کرد. همچنین از هیستوگرام طیف [11] برای استخراج ویژگی‌ها و طبقه‌بندی کننده‌های سلسله مراتبی [12] و [13] برای افزایش سرعت نیز استفاده شده است. در این تحقیق، روشی جدید بر پایه تغییر در قسمت‌های مختلف یک سیستم آشکارسازی چهره پیشنهاد شده است [14] تا [16].

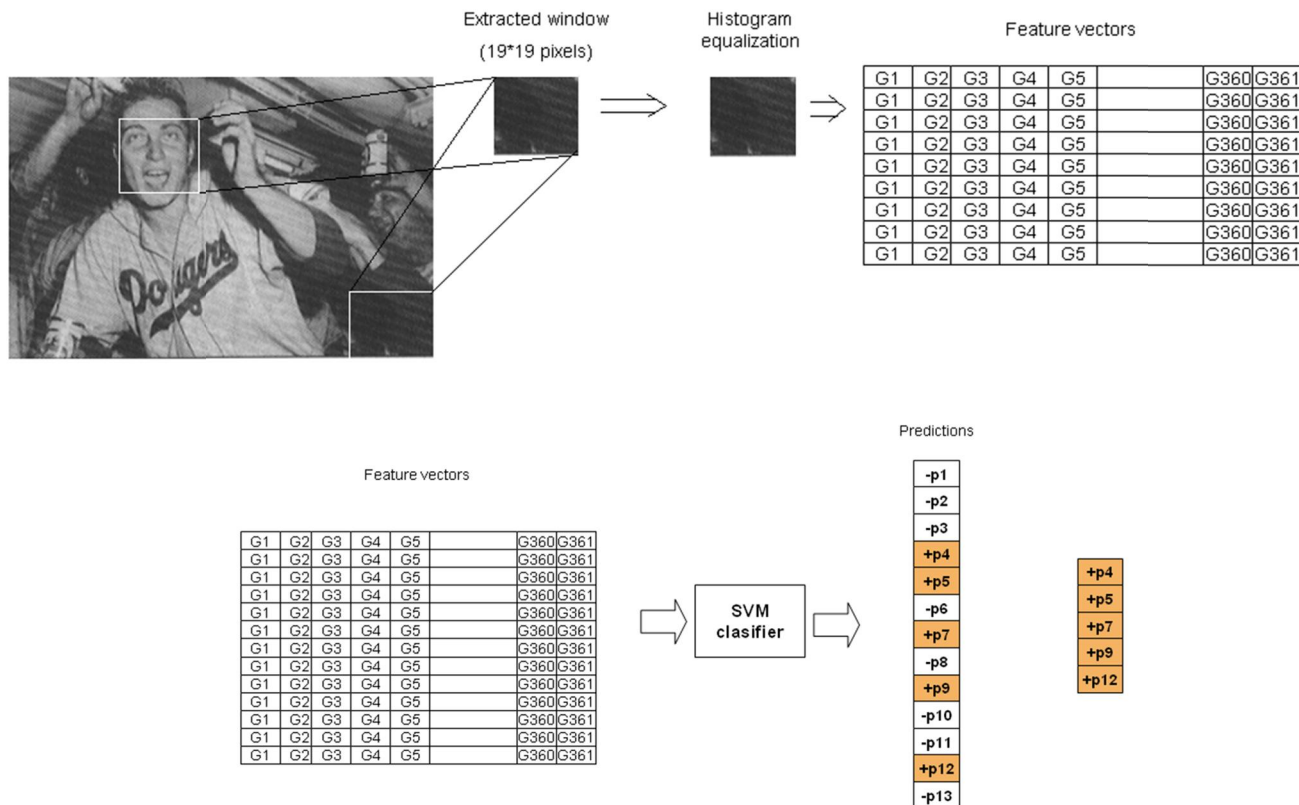
4- روش پیشنهادی

با بررسی کارهای انجام‌شده به سه نکته قابل توجه می‌رسیم که محققین کمتر به آن پرداخته‌اند.

نکته اول: در تمام روش‌های موجود، برای آشکارسازی چهره با استفاده از ماشین بردار پشتیبان از پنجره‌ای با ابعاد ثابت برای قطعه‌قطعه کردن تصویر ورودی استفاده می‌شود (همانند الگوریتم Osuna که ابعاد پنجره 19×19 است). استفاده از پنجره ثابت 19×19 برای تصاویری که شامل چهره‌های بزرگ می‌باشند، مناسب نیست. در چنین تصاویری، چهره در مرحله مقیاس‌بندی مکرر باید به اندازه‌ای کوچک شود که داخل پنجره استفاده‌شده قرار گیرد. در چنین حالتی کیفیت و دقت⁴ چهره خیلی کم شده و ممکن است طبقه‌بندی کننده آن پنجره را به عنوان چهره تشخیص ندهد. بنابراین برای این که کیفیت چهره از بین نرود، بهتر است از پنجره‌هایی با ابعاد بزرگ‌تر از 19×19 استفاده شود. از طرفی گاهی شکل چهره به گونه‌ای است که در یک قاب مربعی جا نمی‌گیرد. لذا استفاده از یک پنجره مربعی ممکن است باعث شود بخشی از چهره حذف شود و در نتیجه چهره آشکار نشود. بنابراین استفاده از پنجره‌های مستطیلی می‌تواند به بهبود آشکارسازی چهره کمک کند.

با توجه به دلایل فوق، اساس کار روش پیشنهادی، استفاده از پنجره‌هایی با ابعاد گوناگون می‌باشد. به این ترتیب که بعد از آموزش سیستم و در مرحله آشکارسازی، علاوه بر این که در مقیاس‌های متفاوت از پنجره‌ای با ابعاد 19×19 استفاده می‌شود، از پنجره‌هایی با ابعاد 64×49 ، 50×50 و 27×20 نیز استفاده می‌شود (این عمل به صورت موازی انجام می‌گیرد). هر پنجره دارای دقتی خاص در آشکارسازی است. در نهایت، تصمیمات حاصل از به کارگیری پنجره‌های مختلف با هم OR می‌شوند. این کار نرخ آشکارسازی را افزایش می‌دهد.

1. Principal Component Analysis
2. Independent Component Analysis
3. Discriminating Feature Analysis
4. Resolution



$$T = \frac{p_4 + p_5 + p_7 + p_9 + p_{12}}{5}$$

شکل 3: شیوه تعیین سطح وقتی.

تصمیم‌گیری فقط بر اساس خروجی ماشین بردار پشتیبان می‌باشد. این کار باعث می‌شود تا روش سنتی Osuna دارای نرخ آشکارسازی کم و خطای هشدار غلط زیاد باشد.

در روش پیشنهادی، اساس کار استفاده از پنجره‌هایی با ابعاد گوناگون، استفاده از یک سطح آستانه وقتی برای تصمیم‌گیری و همچنین استفاده از معیارهای شباهت‌سنجی در خروجی طبقه‌بندی کننده می‌باشد.

نکته قابل ذکر این که الگوریتم SVM^{light} که در این تحقیق از آن استفاده شده است به‌ازای هر قطعه ورودی (منظور بردار ویژگی معادل می‌باشد)، در خروجی مقدار انحراف از سطح صفر را تعیین می‌کند.

نکته مهمی که باید بدان اشاره کرد این است که پس از اتمام مراحل آشکارسازی یک تصویر، به‌دلیل استفاده از پنجره‌هایی با ابعاد مختلف ممکن است که اطراف یک چهره، مستطیل‌هایی با اندازه‌های گوناگون کشیده شود. همچنین قسمت‌هایی وجود دارد که غیر چهره می‌باشند ولی به اشتباه چهره تشخیص داده شده و خطا محسوب می‌شوند. برای کاهش خطا و معلوم کردن هر چهره با یک مستطیل، باید از روش شمارش مستطیل‌ها در یک ناحیه خاص استفاده نمود. بدین منظور با شمارش مستطیل‌ها، محلی که تعداد مستطیل‌های آن از حد معلومی بیشتر بود را چهره در نظر گرفته و با یک مستطیل مناسب مشخص می‌کنیم. جایی که تعداد مستطیل‌های آن از این حد کمتر بود، غیر چهره است و لذا مستطیل‌های کشیده‌شده را حذف می‌کنیم. دلیل استفاده از این روش به خاطر این است که در اکثر موارد، تعداد مستطیل‌های اطراف ناحیه چهره بیشتر از تعداد مستطیل‌های کشیده‌شده اطراف نواحی غیر چهره (که به اشتباه چهره تشخیص داده شده‌اند) می‌باشد.

می‌توان مرز مناسبی را بین این دو دسته مشخص کرد. سطح آستانه تعیین‌شده دارای دو خصوصیت است. اولاً بزرگ‌تر از صفر است، لذا نمونه‌های با فاصله کوچک‌تر از صفر حذف می‌شوند. ثانیاً احتمال از دست‌دادن چهره‌ها به حداقل می‌رسد و همچنین میزان خطای هشدار غلط به میزان قابل قبولی کاهش می‌یابد.

نکته سوم: نداشتن پس‌پردازش در خروجی ماشین بردار پشتیبان در روش سنتی است. در واقع این خروجی مستقیماً به‌عنوان چهره یا غیر چهره در نظر گرفته می‌شود. این عمل باعث می‌شود که تصمیم‌گیری فقط بر اساس طبقه‌بندی کننده و سطح تصمیم‌گیری آن صورت گیرد. واضح است که اگر در تعیین خروجی از معیارهای متفاوتی برای تصمیم‌گیری استفاده شود، نتایج هم از نظر نرخ آشکارسازی و هم از نظر خطا بهبود خواهد یافت. در روش پیشنهادی از سه ملاک شباهت‌سنجی (فاصله اقلیدسی، همبستگی نرمالیزه¹ و ضریب همبستگی²) بین خروجی طبقه‌بندی کننده و یک مدل چهره استفاده گردید. مدل چهره از میانگین تعداد زیادی تصویر چهره به‌دست آمد. در عمل از ترکیب AND بین خروجی‌های این سه ملاک شباهت‌سنجی برای تصمیم‌گیری نهایی استفاده شده است.

همان‌طور که در روش Osuna مشاهده شد برای آشکارسازی از پنجره‌ای با ابعاد ثابت 19×19 استفاده شده است. همچنین تصمیم‌گیری نهایی بر اساس سطح آستانه ثابت صفر صورت می‌گیرد و دیگر این که

1. Normalized Correlation
2. Correlation Coefficient

جدول 2: مقادیر سطوح آستانه مربوط به معیارهای شباهت سنجی.

ضریب همبستگی	همبستگی نرمالیزه	فاصله اقلیدسی
0,1736	0,8589	1440

تصویر اولیه اعمال شد. الگوهایی که به غلط چهره تشخیص داده شدند، در مراحل بعدی آموزش به عنوان نمونه‌های منفی در نظر گرفته شدند. در نهایت تعداد غیر چهره‌های به دست آمده به 4285 نمونه رسید. این عمل علاوه بر این که باعث افزایش مجموعه داده‌های مربوط به الگوهای غیر چهره می‌گردد باعث می‌شود تا نمونه‌های غیر چهره‌ای که از نقطه نظر یادگیری مفیدند انتخاب شوند.

5-2 تعیین سطوح آستانه معیارهای شباهت سنجی


برای تعیین سطوح آستانه معیارهای شباهت سنجی از یک مدل چهره از پیش تعیین شده استفاده شد. این مدل چهره از میانگین 95 چهره تثبیت شده مجموعه آموزشی تهیه شد. برای تعیین سطوح آستانه از منحنی ROC¹ به دست آمده از فاصله بین نمونه‌های موجود در پایگاه داده چهره و معیار EER² استفاده شده است. این روند برای هر سه معیار شباهت سنجی استفاده شده در این پژوهش به کار برده شده و نتایج در جدول 2 آمده است.

5-3 تعیین سطح آستانه طبقه‌بندی کننده

همان‌طور که قبلاً بیان شد، در روش سنتی، خروجی ماشین بردار پشتیبان با سطح آستانه صفر مقایسه می‌شود. از آنجا که انتخاب مناسب سطح آستانه تأثیر به‌سزایی در نتایج دارد، می‌توان برای تعیین آن از منحنی ROC استفاده کرد. به این منظور ابتدا مجموعه آموزشی (چهره + غیر چهره) به‌طور تصادفی به 10 قسمت مساوی تقسیم شد. سپس از 9 قسمت برای آموزش سیستم و از قسمت باقیمانده برای تست سیستم استفاده شد. این روند 10 بار تکرار شد که در هر مرحله، 9 قسمت برای آموزش و یک قسمت برای تست انتخاب گردید. برای این که این سطح آستانه دقیق‌تر انتخاب شود، این مرحله 100 دفعه تکرار شد که در هر دفعه به‌طور تصادفی مجموعه آموزشی به 10 قسمت تقسیم شده و مراحل قبل تکرار شد. بعد از تمام شدن این فرایند می‌توان منحنی ROC که بیانگر خطای منفی بر حسب خطای مثبت است را رسم نمود و با استفاده از معیار EER، سطح آستانه تصمیم‌گیری را تعیین نمود. بدین منظور نقطه‌ای از منحنی که به‌ازای آن خطای منفی و مثبت با هم برابرند را تعیین و سطح آستانه متناظر با آن نقطه را انتخاب می‌کنیم. توجه کنید که این سطح آستانه نیز ثابت بوده و مشکلاتی که برای سطح آستانه ثابت در فصل قبلی بیان شد همچنان پا برجاست. این مشکلات با مطرح شدن روش پیشنهادی (استفاده از سطح آستانه وفقی) بهبود یافته است. شکل 5 منحنی ROC به دست آمده را نشان می‌دهد. از روی این منحنی با استفاده از معیار EER، سطح آستانه برابر 0,0168- می‌شود.

5-4 تفسیر نتایج شبیه‌سازی

در شبیه‌سازی‌ها از کرنل چندجمله‌ای با درجه 2 استفاده گردید و $C = 200$ انتخاب شد. برخی از نتایج شبیه‌سازی در زیر آمده است. جدول 3 نتایج حاصل از به‌کارگیری روش Osuna را با استفاده از



شکل 4: افزایش تعداد پایگاه داده توسط حالات مختلف نرمال‌سازی هندسی.

5- نتایج آزمایش‌ها

5-1 مجموعه داده آموزشی و آزمایشی

آزمایشات روی دو مجموعه از داده‌ها صورت گرفته است. مجموعه اول شامل 67 نمونه تصویر است که هر تصویر شامل تنها یک چهره از پایگاه داده CMU [17] می‌باشد. مجموعه دوم شامل 104 نمونه از تصاویر پایگاه داده CMU است که کلاً شامل 277 چهره می‌باشد. برای آموزش، تعداد 4285 نمونه غیر چهره و 2375 نمونه چهره استفاده شد. برای تشکیل نمونه‌های چهره برای آموزش از 95 تصویر در دسترس پایگاه داده CMU استفاده شد. در هر تصویر یک چهره با مشخص بودن محل چشم‌ها، بینی و دهان وجود دارد. با معلوم بودن محل چشم‌ها، بینی و دهان و با استفاده از نرمال‌سازی هندسی، 95 چهره استاندارد استخراج شد. این 95 چهره به‌گونه‌ای می‌باشند که ابعاد آنها برابر با 19×19 و همچنین محل چشم‌ها در تمام 95 چهره یکسان می‌باشد. از آنجا که ماشین بردار پشتیبان برای داشتن عملکرد مناسب نیاز به مجموعه آموزشی بزرگ‌تر از 95 چهره دارد، بنابراین برای تهیه چنین مجموعه‌ای، از موقعیت چشم‌ها استفاده شد. بدین منظور برای هر چشم به غیر از موقعیت مرکز آن از چهار پیکسل همسایه (همسایگی مرتبه 4) نیز استفاده شد. بنابراین برای هر چشم، 5 موقعیت و در مجموع برای دو چشم می‌توان $25 = 5 \times 5$ حالت مختلف را برای نرمال‌سازی هندسی در نظر گرفت. در هر مرحله یکی از این حالت‌ها به عنوان مرکز چشم‌ها انتخاب و تصویر تثبیت شده به دست آمد. این عمل به غیر از این که باعث افزایش تعداد چهره‌ها می‌شود، اثر اعوجاج موجود در چهره را نیز در آشکارسازی حذف می‌کند. به عنوان نمونه شکل 4 را ببینید.

واضح است که به دلیل تنوع غیر چهره‌ها، تشکیل یک مجموعه آموزشی غیر چهره کامل که تمام غیر چهره‌ها را پوشش دهد امکان‌پذیر نیست. در این پژوهش برای تشکیل مجموعه غیر چهره از زمینه همان 95 تصویری که چهره آن استخراج شد، استفاده شده است. به این ترتیب که ابتدا به‌طور تصادفی در هر زمینه، تعدادی زیر تصویر 19×19 پیکسلی به عنوان غیر چهره انتخاب شد. بعد از تهیه مجموعه غیر چهره اولیه، سیستم توسط مجموعه آموزشی به دست آمده، آموزش داده شد. بعد از آموزش اولیه سیستم، عمل طبقه‌بندی روی زمینه‌های باقیمانده از 95

1. Receiver Operating Characteristic

2. Equal Error Rate

جدول 4: نتایج روش OSUNA با به کارگیری تکنیک‌های متفاوت.

	مجموعه اول		مجموعه دوم	
	Dr	Fa	Dr	Fa
تکنیک مورد استفاده				
روش پایه با سطح آستانه صفر	%82,5	219	%88,8	496
معیارهای شباهت‌سنجی	%65,6	94	%79,8	254
سطح وقتی	%74,6	74	%79,1	154
پنجره‌های متفاوت و معیارهای شباهت‌سنجی	%100	107	%93,8	274
سطح وقتی و معیارهای شباهت‌سنجی	%58,2	22	%68,8	56
سطح وقتی و معیارهای شباهت‌سنجی و پنجره‌های متفاوت	%98,4	19	%91,2	80

جدول 5: نتایج روش پیشنهادی با سطوح آستانه تصمیم‌گیری متفاوت.

سطح آستانه تصمیم‌گیری	مجموعه اول		مجموعه دوم	
	Dr	Fa	Dr	Fa
0	%100	89	%93,9	232
0,3	%79,4	34	%84,8	95
-0,0168	%100	117	%94,2	285
سطح وقتی	%98,4	19	%91,2	80

4) استفاده از سطح وقتی همراه با استفاده از معیارهای شباهت‌سنجی با وجودی که نرخ هشدار غلط را کاهش می‌دهد ولی باعث کاهش شدید نرخ آشکارسازی نیز می‌شود.

جدول 5 نتایج حاصل از به کارگیری الگوریتم پیشنهادی را با استفاده از سطوح آستانه تصمیم‌گیری مختلف نشان می‌دهد. مشاهده می‌شود که کارایی سیستم به‌طور چشم‌گیری افزایش یافته است. تأکید این جدول بر افزایش کارایی سیستم با استفاده از معیارهای شباهت‌سنجی و پنجره‌های متفاوت در دو مورد می‌باشد:


1) اگر در آشکارسازی از سطح وقتی همراه با این معیارها استفاده شود بهترین نتایج را در پی دارد.

2) حتی اگر از سطح وقتی هم استفاده نشود چون از پنجره‌های مختلف و پس‌پردازش برای تصمیم‌نهایی استفاده می‌شود، باز هم نتایج بهبود می‌یابد.

در اینجا نیز دیده می‌شود که استفاده از سطح آستانه $-0,0168$ ، گرچه باعث بهبود قابل ملاحظه نرخ آشکارسازی می‌شود اما خطای هشدار غلط زیاد است. شکل 6 چند تصویر نمونه و نتیجه آشکارسازی نهایی را بر اساس روش پیشنهادی نشان می‌دهد.

الگوریتم پیشنهادی دارای کارایی قابل قبولی است و در مقایسه با روش Osuna نتایج به‌طور چشم‌گیری بهتر شده است. اما نباید طولانی‌تر شدن مدت زمان اجرای الگوریتم را از نظر دور داشت. به هر حال استفاده از پنجره‌ها و معیارهای شباهت‌سنجی مختلف و انتخاب سطح آستانه وقتی تا حدودی به پیچیدگی زمانی الگوریتم می‌افزاید. اگر امکان اجرای الگوریتم به‌صورت توزیعی روی چندپردازنده باشد به‌طوری که عملیات اعمال پنجره‌ها و معیارهای مختلف به‌صورت موازی انجام شود، مشکل پیچیدگی زمانی مرتفع می‌شود. به هر حال با وجود پردازنده‌های پرسرعت امروزی، جای نگرانی نیست و الگوریتم پیشنهادی در اکثر کاربردها قابل استفاده است.

همان‌طور که دیدیم تاکنون فقط بین روش پیشنهادی و روش اولیه Osuna مقایسه انجام گرفت و مقایسه‌ای با روش‌های دیگر صورت



شکل 5: منحنی ROC مربوط به ارزیابی سیستم.

جدول 3: نتایج روش OSUNA با سطوح آستانه تصمیم‌گیری متفاوت.

سطح آستانه تصمیم‌گیری	مجموعه اول		مجموعه دوم	
	Dr	Fa	Dr	Fa
0	%82,5	219	%88,8	496
0,3	%66,7	74	%77,3	166
-0,0168	%84,1	233	%90,3	507
سطح وقتی	%74,6	74	%79,1	154

سطوح آستانه تصمیم‌گیری مختلف نشان می‌دهد. گاهی برای تعیین سطح آستانه بهینه طبقه‌بندی کننده از منحنی‌های ROC استفاده می‌شود (بخش 5-3). این روش زمان زیادی را به خود اختصاص می‌دهد. همان‌طور که قبلاً دیدیم، با استفاده از منحنی ROC و معیار EER، سطح آستانه بهینه برابر با $-0,0168$ شد. همان‌طور که از جدول 3 ملاحظه می‌کنید با استفاده از این سطح آستانه، خطای هشدار غلط زیاد است. ملاحظه می‌شود که به کارگیری سطح آستانه وقتی به‌طور چشم‌گیری خطای هشدار غلط $(Fa)^1$ را نسبت به سطح ثابت $-0,0168$ کاهش می‌دهد که این امر البته باعث کاهش نرخ آشکارسازی $(Dr)^2$ نیز می‌شود. در این جدول مشاهده می‌شود که هرچه سطح آستانه تصمیم‌گیری افزایش می‌یابد، نمونه‌های بیشتری از چهره از دست می‌رود ولی خطای هشدار غلط کاهش می‌یابد. دلیل این اتفاق همان‌طور که در بخش 4 بیان شد، مشخص نبودن مرز دقیق بین نمونه‌های غیر چهره و نمونه‌های چهره می‌باشد. ولی سطح وقتی چون متناسب با نوع داده‌های تصویری، مرز را مشخص می‌کند، نسبت به انتخاب سطح ثابت دارای کارایی بهتری است. جدول 4 نتایج حاصل از به کارگیری الگوریتم Osuna را با به کارگیری تکنیک‌های مختلف نشان می‌دهد. نتایج نشان می‌دهند که:

- 1) هر چند استفاده از معیارهای شباهت‌سنجی به تنهایی باعث کاهش نرخ هشدار غلط می‌شود ولی در مقابل نرخ آشکارسازی را هم پایین می‌آورد. علت این امر استفاده از قاعده AND برای ادغام نتایج حاصل از معیارهای شباهت‌سنجی مختلف است.
- 2) استفاده از سطح وقتی در دسته‌بندی کننده باعث ایجاد تعادل بین نرخ آشکارسازی و نرخ هشدار غلط می‌شود.
- 3) استفاده از پنجره‌های با ابعاد متفاوت همراه با استفاده از معیارهای شباهت‌سنجی در عین حال که نرخ آشکارسازی را افزایش می‌دهد تأثیر کمی در افزایش نرخ هشدار غلط دارد.

1. False Alarm
2. Detection Rate



شکل 6: چند خروجی نمونه.

6- نتیجه گیری و پیشنهادها

در این مقاله، روشی جدید برای آشکارسازی چهره مبتنی بر ماشین بردار پشتیبان معرفی شد. در این روش، به جای استفاده از یک پنجره با ابعاد ثابت، از پنجره‌هایی با ابعاد مختلف برای آشکارسازی استفاده شد. این کار باعث افزایش دقت یا به عبارتی افزایش نرخ آشکارسازی و کاهش خطای هشدار غلط می‌گردد. همچنین از یک سطح آستانه وقتی برای تصمیم‌گیری و نیز از معیارهای شباهت‌سنجی استفاده شد. نتایج شبیه‌سازی، افزایش قابل قبول نرخ آشکارسازی و کاهش خطای هشدار غلط را در روش جدید نشان داد. با این وجود باید دقت کرد که اجرای الگوریتم پیشنهادی نسبت به الگوریتم Osuna مدت زمان بیشتری طول می‌کشد. البته با وجود پردازنده‌های پرسرعت امروزی، این مسئله مشکل حادی نیست که قابل حل نباشد.

در اینجا برای ادامه تحقیق چند پیشنهاد مطرح می‌کنیم:

- (1) در این پژوهش از پایگاه داده CMU استفاده شده است. برای بررسی جامع‌تر می‌توان از پایگاه داده‌های دیگر نیز استفاده کرد.
- (2) در این پژوهش از معیارهای شباهت‌سنجی فاصله اقلیدسی، همبستگی نرمالیزه، ضریب همبستگی و همچنین ترکیب آنها استفاده شده است. می‌توان عملکرد دیگر معیارهای شباهت‌سنجی را نیز بررسی کرد.
- (3) در سیستم‌های آشکارسازی چهره، روش‌های پیش‌پردازش از اهمیت ویژه‌ای برخوردار هستند. در سیستم پیشنهادی از همسان‌سازی هیستوگرام برای استانداردسازی نوری استفاده شده است. ممکن است بتوان با اعمال پیش‌پردازش‌های مناسب‌تر به کارایی بهتری دست یافت.
- (4) در سیستم‌های آشکارسازی چهره روش‌های مختلفی برای استخراج ویژگی وجود دارد. در روش ارائه شده از پیکسل‌های تصویر به‌عنوان بردار ویژگی استفاده شد. استفاده از روش‌های استخراج ویژگی برای حصول نتایج بهتر پیشنهاد می‌شود.
- (5) در روش پیشنهادی از چهار پنجره با ابعاد متفاوت استفاده شد. اگر بتوان انتخاب این پنجره‌ها را به صورت وقتی متناسب با تصویر

نگرفته است. دلیل این است که ایده‌های جدید مطرح شده در کارهای قبلی یا مبتنی بر تغییر در ساختار ماشین بردار پشتیبان و نحوه آموزش آن و یا بر اساس تغییر در نحوه استخراج ویژگی‌ها و انجام پیش‌پردازش می‌باشند. در حالی که در این مقاله بیشتر تأکید روی ادغام نتایج روش‌های مختلف شباهت‌سنجی، انتخاب وقتی سطح آستانه تصمیم‌گیری و انتخاب پنجره‌های مناسب بود. از طرفی پیاده‌سازی همه الگوریتم‌های موجود به دلیل مشخص نبودن برخی پارامترهای کلیدی امکان‌پذیر نبود. با این حال بد نیست مقایسه‌ای هرچند ابتدایی بین کارایی روش‌های معروف مبتنی بر ماشین بردار پشتیبان داشته باشیم. واضح است که برای مقایسه جامع باید کلیه الگوریتم‌ها با دقت و در شرایط یکسان پیاده‌سازی شده و با هم مقایسه شوند.

مهم‌ترین روش‌های ارائه شده در سال‌های اخیر که نتایج قابل قبولی داشته‌اند، عبارتند از:

- (1) روش استخراج ویژگی‌ها با PCA و سپس به کارگیری SVM به عنوان طبقه‌بندی کننده [9]. در این حالت، متوسط نرخ آشکارسازی 82 درصد است که در مقایسه با الگوریتم پیشنهادی خیلی کمتر است.
- (2) روش استخراج ویژگی‌ها با PCA و سپس اعمال ICA و در نهایت به کارگیری SVM به عنوان طبقه‌بندی کننده [9]. در این حالت، متوسط نرخ آشکارسازی 86 درصد است که در مقایسه با الگوریتم پیشنهادی خیلی کمتر است.
- (3) روش استخراج ویژگی‌ها با DFA و سپس به کارگیری SVM به عنوان طبقه‌بندی کننده [10]. در این حالت با به کارگیری یک الگوریتم پیچیده چندمرحله‌ای توانسته‌اند به متوسط نرخ آشکارسازی 98/2 درصد برسند که قابل مقایسه با روش پیشنهادی در این مقاله است. روش DFA دارای نرخ هشدار غلط کمتری است، ولی پیچیدگی آن از الگوریتم پیشنهادی بیشتر است.
- (4) روش استخراج ویژگی‌ها با هیستوگرام طیف و سپس به کارگیری SVM به عنوان طبقه‌بندی کننده [11]. در این حالت، متوسط نرخ آشکارسازی 96/7 درصد و تعداد هشدار غلط 67 است که در مقایسه با الگوریتم پیشنهادی کارایی کمتری دارد.

- [12] B. Heisele, T. Serre, S. Prentice, and T. Poggio, "Hierarchical classification and feature reduction for fast face detection with support vector machines," *Pattern Recognition*, vol. 36, no. 9, pp. 2007-2017, Sep. 2003.
- [13] H. Sahbi, Coarse-to-Fine Support Vector Machines for Hierarchical Face Detection, Ph.D. Thesis, Versailles University, France, 2003.
- [14] M. Roohi, G. Mirjalily, and M. T. Sadeghi, "Face detection using a modified SVM - based classifier," in *Proc. of IEEE Int. Conf. on Computational Intelligence and Multimedia Applications, ICCIMA*, vol. 2, pp. 354-360, Dec. 2007.
- [15] G. Mirjalily, M. Roohi, and M. T. Sadeghi, "A new approach for face detection using support vector machine," in *Proc. of First Joint Cogress on Fuzzy and Intelligent Systems, Ferdowsi University of Mashad*, vol. 1, pp. 435-440, Aug. 2007.
- [16] M. Roohi, *Face Detection Using Support Vector Machine*, M.Sc. Thesis, Yazd University, 2007.
- [17] http://www.vasc.ri.cmu.edu/idb/html/face/frontal_images/index.html

مجید روحي در سال 1383 مدرک کارشناسی مهندسی برق خود را از دانشگاه آزاد اسلامی و در سال 1386 مدرک کارشناسی ارشد مهندسی برق - مخابرات خود را از دانشگاه یزد دریافت نمود. او در دوره کارشناسی به عضویت باشگاه پژوهشگران جوان درآمد که تا سال 1384 ادامه داشت. وی از سال 1387 با عنوان عضو هیأت علمی همکاری خود را در گروه برق دانشگاه آزاد اسلامی واحد مهریز آغاز نمود. زمینه تحقیقاتی مورد علاقه نامبرده پردازش تصاویر دیجیتال می‌باشد.

قاسم میرجلیلی در سال 1370 مدرک کارشناسی مهندسی برق خود را از دانشگاه فردوسی مشهد و در سال 1373 مدرک کارشناسی ارشد مهندسی برق - مخابرات خود را از دانشگاه صنعتی خواجه نصیرالدین طوسی دریافت نمود. پس از آن به دوره دکترای مهندسی برق - مخابرات در دانشگاه تربیت مدرس وارد گردید و در سال 1378 موفق به اخذ درجه دکترا از دانشگاه مذکور گردید. وی از سال 1379 به عنوان عضو هیأت علمی در دانشگاه یزد مشغول خدمت است و هم اکنون دانشیار دانشکده مهندسی برق و کامپیوتر دانشگاه یزد و عضو ارشد IEEE می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: پردازش سیگنال و شبکه‌های انتقال داده.

محمدتقی صادقی در سال 1370 مدرک کارشناسی مهندسی برق خود را از دانشگاه صنعتی شریف و در سال 1373 مدرک کارشناسی ارشد مهندسی برق - مخابرات خود را از دانشگاه تربیت مدرس دریافت نمود. از سال 1374 الی 1378 نامبرده در دانشکده مهندسی برق دانشگاه یزد به کار مشغول بود و پس از آن به دوره دکترای مهندسی برق - مخابرات در دانشگاه ساری انگلستان وارد گردید و در سال 1381 موفق به اخذ درجه دکترا از دانشگاه مذکور گردید. پس از آن به مدت دو سال در مرکز تحقیقات بینایی ماشین و پردازش سیگنال همان دانشگاه، در زمینه سیستم‌های بازشناسی چهره پژوهش نموده و از آن پس تاکنون استادیار دانشکده مهندسی برق و کامپیوتر دانشگاه یزد می‌باشد. همکاری پژوهشی نامبرده با مرکز تحقیقات بینایی ماشین و پردازش سیگنال دانشگاه ساری همچنان ادامه دارد. زمینه‌های علمی مورد علاقه نامبرده عبارتند از: بازشناسی الگو، پردازش تصویر و بینایی ماشین.

ورودی انجام داد مناسب‌تر به نظر می‌رسد.

6) این پژوهش بر اساس تصاویر سطح خاکستری بود. می‌توان الگوریتم را برای تصاویر رنگی نیز بسط داده و مورد آزمایش قرار داد.

7) استفاده از یک پایگاه داده آموزشی مشخص و پیاده‌سازی دقیق روش‌هایی که تاکنون مطرح شده به منظور مقایسه جامع بین روش‌های مختلف، مناسب به نظر می‌رسد.

7- سپاس‌گزاری

این تحقیق با حمایت مالی مرکز تحقیقات مخابرات ایران به انجام رسیده است که در اینجا قدردانی خود را از مرکز نامبرده اعلام می‌داریم.

مراجع

- [1] M. Yang, D. J. Kriegman, and N. Ahuja, "Detecting faces in images: a survey," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 24, no. 1, pp. 34-58, Jan. 2002.
- [2] C. J. C. Burges, "A tutorial on support vector machines for pattern recognition," *Data Mining and Knowledge Discovery*, vol. 2, no. 2, pp. 121-158, Jun. 1998.
- [3] E. Osuna, R. Freund, and F. Girosi, "Support Vector Machines: Training and Applications," A. I. Memo, No. 1602, MIT A. I. Lab., 1997.
- [4] E. Osuna, R. Freund, and F. Girosi, "Training support vector machines: an application to face detection," in *Proc. IEEE Conf. Computer Vision and Pattern Recognition*, vol. 1, pp. 130-136, Jun. 1997.
- [5] N. Cristianini and J. Shawe - Taylor, *An Introduction to Support Vector Machines*, Cambridge University Press, 2000.
- [6] B. Murtagh and M. Saunders, "Large-scale linearly constrained optimization," *Mathematical Programming*, vol. 14, no. 1, pp. 41-72, Dec. 1978.
- [7] <http://SVMlight.joachims.org>.
- [8] C. Shavers, R. Li, and G. Leiby, "An SVM-based approach to face detection," in *Proc. of 38th Southeastern Symp. on System Theory*, vol. 1, pp. 362-366, US, Mar. 2006.
- [9] Q. Gao, Q. Pan, H. Zhang, Y. Cheng, and Q. Tlan, "Face detection using SVM trained in independent space," in *Proc. of the Third Int. Conf. on Machine Learning and Cybernetics*, vol. 6, pp. 3674-3677, Shanghai, Aug. 2004.
- [10] P. Shih and C. Liu, "Face detection using discriminating feature analysis and support vector machine," *Elsevier Pattern Recognition J.*, vol. 39, no. 2, pp. 260-276, Feb. 2006.
- [11] A. Wring and X. Liu, "Face detection using spectral histograms and SVMs," *IEEE Trans. Systems, Man, and Cybernetics - Part B: Cybernetics*, vol. 35, no. 3, pp. 467-476, Jun. 2005.