تحلیل عملکرد یادگیرنده‌های بانظارت جهت استخراج دانش مربوط به زاویه نورپردازی در تصاویر تمام‌رخ چهره

شقایق نادری، نصرالله مقدم چرکری و احسان‌اله کبیر

چکیده: تغییرات شدت و جهت تابش نور یکی از مهم‌ترین چالش‌های مطرح در سیستم‌های شناسایی چهره است که منجر به ایجاد سایه‌های عادی و غیر عادی متفاوتی در تصویر چهره می‌شود. امروزه روش‌های مختلفی برای بازشناسی چهره تحت شرایط نوری متفاوت ارائه شده‌اند که بسیاری از آنها نیاز به دانش قبلی در مورد منبع نور و زاویه تابش دارند. در این مقاله رویکردی مبتنی بر روش‌های یادگیری برای استخراج دانش مربوط به زاویه نورپردازی در تصاویر چهره پیشنهاد شده است. ابتدا ویژگی‌های DCT مؤثر در تغییرات نور از تصویر استخراج شده و پس از نرمال‌سازی، جهت تعیین کلاس‌های نوری مورد استفاده قرار می‌گیرند. برای یادگیری کلاس‌های نوری از سه الگوریتم درخت تصمیم، SVM[1] و الگوریتم مبتنی بر بیز WAODE[2] استفاده شده و عملکرد آنها ارزیابی شده است. نتایج به‌دست آمده روی پایگاه‌های تصویری YaleB و ExtendedYale نشان می‌دهد که SVM بهترین متوسط دقت را برای طبقه‌بندی تصاویر چهره در نورپردازی‌های مختلف ارائه می‌دهد. در حالی که طبقه‌بند بیزی WAODE به دلیل مقاومت بهتر در برابر فقدان داده، برای کلاس‌های نوری با زاویه تابش زیاد نتایج بهتری را ارائه می‌دهد.

کلید واژه: **تبدیل DCT، زاویه نورپردازی، یادگیرنده‌های بانظارت درخت تصمیم، بیز و SVM.**

۱- مقدمه

مسأله تغییرات نور یکی از مشکلات اصلی در سیستم‌های بازشناسی چهره است. تصویر یک فرد تحت شرایط نوری مختلف، الگوهای کاملاً متفاوتی ایجاد می‌کند و دقیق‌ترین سیستم‌های بازشناسی چهره به شدت حساس به تغییرات نور هستند. روش‌های مختلفی برای حل مسأله بازشناسی چهره تحت شرایط نوری متفاوت پیشنهاد شده‌اند که با مدل‌سازی تغییرات نور و یا استفاده از ویژگی‌های پایای تصویر به حل مسأله می‌پردازند [۱].

علاوه بر این که دقت این روش‌ها هنوز تأمین‌کننده انتظارات نیست، بسیاری از آنها نیاز به دانش قبلی درباره منبع نور و یا حجم زیادی از داده‌های آموزشی دارند. در این بین روش‌های مبتنی بر ویژگی‌های پایای تصویر، به‌دلیل استفاده از پیش‌پردازش‌های ساده و عدم نیاز به دانش قبلی، مورد توجه بسیاری از محققین می‌باشند [۲]. برخی از این روش‌ها با استخراج ویژگی‌های پایای نوری (که در تغییرات نورپردازی پایدارند) به شناسایی چهره پرداخته [۳] و برخی با ارائه تکنیک‌های حذف سایه به اصلاح نورپردازی در تصویر چهره می‌پردازند [۴] و [۵]. برخی دیگر هم برای بهبود نرخ شناسایی در تغییرات نور از ترکیب روش‌های مختلف استفاده می‌نمایند [۶]. مطالعات نشان می‌دهد که اکثر روش‌های شناسایی چهره که در نورپردازی‌های شدید خوب عمل می‌کنند، دقت شناسایی در نورپردازی‌های عادی را کاهش می‌دهند.

از آنجا که زاویه‌های نورپردازی مختلف سبب ایجاد سایه‌های متفاوتی در تصویر می‌شوند که با یک روش واحد قابل اصلاح نیستند، می‌توان با اطلاع از زاویه نورپردازی برای نورپردازی‌های متفاوت از روش‌های مختلفی استفاده کرد و سرعت و دقت شناسایی در نورپردازی‌های مختلف را بهبود داد.

در این مقاله راهکاری مبتنی بر الگوریتم‌های یادگیری جهت استخراج دانش مربوط به زاویه نورپردازی در تصاویر چهره ارائه می‌شود. در ادامه شرایط مسأله و جریان کلی روش پیشنهادی را در بخش ۲ ارائه می‌کنیم و در بخش‌های ۳ و ۴ به جزئیات روش پیشنهادی می‌پردازیم. نتایج ارزیابی در بخش ۵ مطرح شده و در زیربخش ۵-۴ به تحلیل نتایج می‌پردازیم. در نهایت جمع‌بندی مقاله را در بخش ۶ ارائه می‌دهیم.

۲- تعریف مسأله

شکل ۱ تصویر فردی از پایگاه YaleB تحت نورپردازی‌های متفاوت را نشان می‌دهد. YaleB [۷] یکی از غنی‌ترین پایگاه‌های تصویری چهره است که برای مسأله تغییرات نور در ۶۴ حالت نوری مختلف (با ذکر جهت و زاویه تابش نور) به‌کار برده می‌شود.

تصاویر این پایگاه بر اساس زاویه بین منبع نور و محور دوربین (که زاویه نورپردازی نامیده می‌شود)، مطابق شکل ۱ به ۵ زیرمجموعه تقسیم شده‌اند. تصاویر زیرمجموعه ۱ (با زاویه نورپردازی کمتر از ۱۲ درجه) دارای نورپردازی تقریباً عادی بوده و هرچه به زیرمجموعه ۵ نزدیک می‌شویم، زاویه نورپردازی و سایه‌های به‌وجود آمده بیشتر می‌شود. در این مقاله به هر زیرمجموعه نوری، یک کلاس نوری اطلاق شده است.

همان‌طور که در شکل دیده می‌شود، در نورپردازی‌های شدید عمل بازشناسی چهره بسیار مشکل است. با این وجود روش‌های مختلفی برای بازشناسی چهره تحت نورپردازی‌های مختلف ارائه شده‌اند که هر کدام نقاط قوت و ضعف مخصوص به خود را دارند. مقایسه نتایج ارائه‌شده روی پایگاه تصویری YaleB نشان می‌دهد که عمده روش‌ها برای نورپردازی‌های خیلی شدید (مانند کلاس نوری ۵) راهکاری را ارائه نمی‌دهند. از طرف دیگر برخی روش‌ها روی زیرمجموعه‌های نوری خاصی بهتر جواب می‌دهند و مهم‌تر از همه این که بسیاری از روش‌هایی که دقت خوبی را در نورپردازی‌های شدید (کلاس‌های ۴ و ۵) ارائه

این مقاله در تاریخ ۱۲ خرداد ماه ۱۳۸۹ دریافت و در تاریخ ۱۲ خرداد ماه ۱۳۹۰ بازنگری شد.

شقایق نادری، دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس، تهران، ایران (email: naderi@modares.ac.ir).

نصرالله مقدم چرکری، دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس، تهران، ایران (email: charkari@modares.ac.ir).

احسان‌اله کبیر، دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس، تهران، ایران (email: kabir@modares.ac.ir).

1. Support Vector Machine
2. Weightily Averaged One-Dependence Estimators

Archive of SID

www.SID.ir

شکل ۱: نمونه تصاویر فردی از پایگاه تصویری YaleB که بر اساس زاویه تابش نور در ۵ زیرمجموعه مستقل طبقه‌بندی شده است، (الف) زیرمجموعه ۱: زاویه نورپردازی ۰ تا ۱۲ درجه، (ب) زیرمجموعه ۲: زاویه نورپردازی ۱۳ تا ۲۵ درجه، (ج) زیرمجموعه ۳: زاویه نورپردازی ۲۶ تا ۵۰ درجه، (د) زیرمجموعه ۴: زاویه نورپردازی ۵۱ تا ۷۷ درجه و (ها) زیرمجموعه ۵: زاویه نورپردازی بیشتر از ۷۷ درجه.

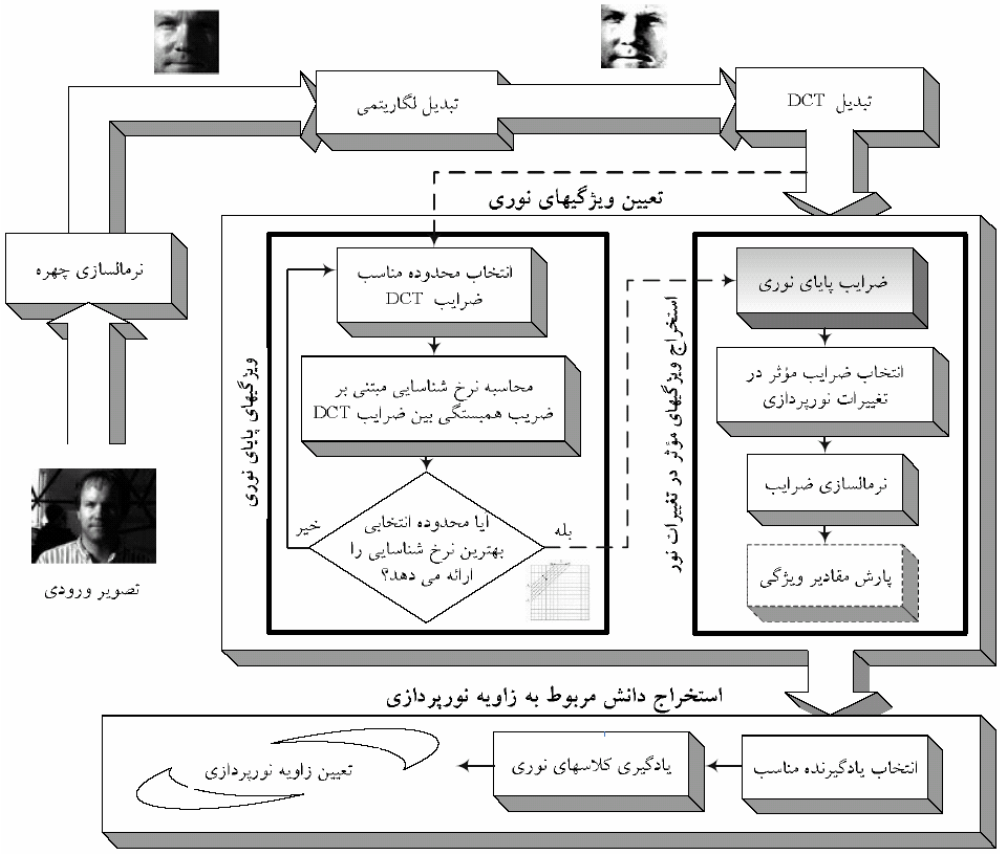

شکل ۲: بلوک دیاگرام روش پیشنهادی.

می‌دهند، باعث افت دقت شناسایی در نورپردازی‌های عادی (کلاس‌های ۱ و ۲) می‌شوند.

در این راستا، مشکل اصلی عدم وجود دانش قبلی درباره منبع نور و زاویه نورپردازی است. با کسب این دانش، علاوه بر تعیین کلاس‌های نوریِ تصاویر چهره می‌توان در هر کلاس نوری از روش خاصی برای بازشناسی چهره استفاده کرد و سرعت و دقت بازشناسی چهره تحت تغییرات نورپردازی را بهبود بخشید. هدف اصلی در این مقاله کسب دانش مربوط به زاویه نورپردازی جهت تعیین کلاس نوریِ مربوط به تصویر چهره در نورپردازی‌های نامشخص است.

شکل ۲ بلوک دیاگرام روش پیشنهادی را نشان می‌دهد. تصاویر ورودی، ابتدا بر اساس فاصله بین چشم‌ها نرمال شده و بخش اصلی چهره از تصاویر استخراج می‌شود، سپس از تبدیل لگاریتمی برای بهبود قسمت‌های تاریک تصویر استفاده می‌گردد [۸] تا [۱۰].

روش پیشنهادی از دو گام کلی تعیین ویژگی‌های نوری و استخراج دانش مربوط به زاویه نورپردازی تشکیل شده است.

در گام اول هدف تعیین ویژگی‌های نوری تصویر است که حاوی اطلاعات مربوط به زاویه نورپردازی می‌باشند. برای تعیین این ویژگی‌ها از اطلاعات روش‌های شناسایی چهره موجود تحت شرایط نوری متفاوت استفاده می‌کنیم و با تکیه بر این حقیقت که ویژگی‌های حذف‌شده در روش‌های شناسایی چهره تحت شرایط نوری متفاوت اطلاعات مفیدی

www.SID.ir

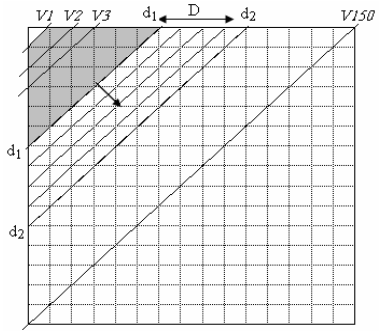

شکل ۳: نحوه انتخاب ضرایب DCT.

را مربوط به زاویه نورپردازی در بردارند، به استخراج ویژگی‌های نوری می‌پردازیم. ویژگی‌های مورد استفاده در این مقاله ضرایب DCT تصویر می‌باشند.

در گام دوم هدف استخراج دانش مربوط به زاویه نورپردازی (یا تعیین کلاس نوری) با استفاده از ویژگی‌های نوری به‌دست آمده است. یک مرحله مهم در این بخش، انتخاب روش مناسب جهت استخراج دانش مربوط به زاویه نورپردازی است. هیچ الگوریتم یادگیری خاصی نیست که در تمام موارد بهتر از سایر الگوریتم‌ها عمل کند. در نتیجه بهترین راه انتخاب تعدادی از الگوریتم‌ها بسته به نوع مسأله، تخمین دقت آنها و در نهایت انتخاب دقیق‌ترین الگوریتم است.

۳- تعیین ویژگی‌های نوری

همان‌طور که در دیاگرام روش پیشنهادی (شکل ۲) دیده می‌شود، تعیین ویژگی‌های نوری از دو بخش کلی تشکیل شده است. در بخش اول (بخش ۳-۱) ویژگی‌های پایای نوری[۱] تعیین می‌گردد و در بخش دوم (بخش ۳-۲) بر اساس اطلاعات به‌دست آمده از مرحله اول ویژگی‌های مؤثر در تغییرات نور (ویژگی‌های نوری[۲]) استخراج و برای یادگیری مورد استفاده قرار می‌گیرد.

از آنجا که ویژگی‌های مورد استفاده در این تحقیق، ضرایب DCT می‌باشند، در ابتدا تصویر به‌دست آمده با استفاده از تبدیل DCT به حوزه فرکانس نگاشت می‌شود. تبدیل کسینوسی گسسته یا DCT یکی از تبدیل‌های حوزه فرکانس است که در کاربردهای استخراج ویژگی بسیار مورد استفاده قرار می‌گیرد. ضرایب اولیه DCT حاوی اطلاعات فرکانس پایین تصویر می‌باشند که معمولاً ویژگی‌های باارزشی از تصویر را ارائه می‌دهند، ضرایب میانی شامل اطلاعات فرکانس میانی تصویر و ضرایب انتهایی حاوی اطلاعات فرکانس بالا یا همان اطلاعات نویزی تصویر می‌باشد.

از آنجا که مؤلفه‌های متأثر از تغییرات شدید نور عموماً در باند فرکانس پایین تصویر قرار دارند، ضرایب ابتدایی DCT می‌توانند نشان‌دهنده تغییرات نورپردازی بوده و حاوی اطلاعات باارزشی درباره منبع نور و زاویه تابش باشند. از طرفی از آنجا که اطلاعات اصلی تصویر هم در باند فرکانس پایین تصویر قرار دارند، تعیین دقیق ضرایب مؤثر در تغییرات نور و تفکیک آنها از اطلاعات اصلی تصویر می‌تواند تأثیر مستقیمی در دقت دانش استخراجی داشته باشد.

۱. ویژگی‌هایی که اطلاعات پایدار تصویر چهره در نورپردازی‌های مختلف را در بردارد و برای شناسایی چهره تحت شرایط نوری مختلف مورد استفاده قرار می‌گیرد.

۲. ویژگی‌هایی که با تغییرات نورپردازی تغییر می‌کنند و در شناسایی چهره تحت شرایط نوری مختلف حذف می‌شوند. این ویژگی‌ها حاوی اطلاعات مربوط به نورپردازی می‌باشند.

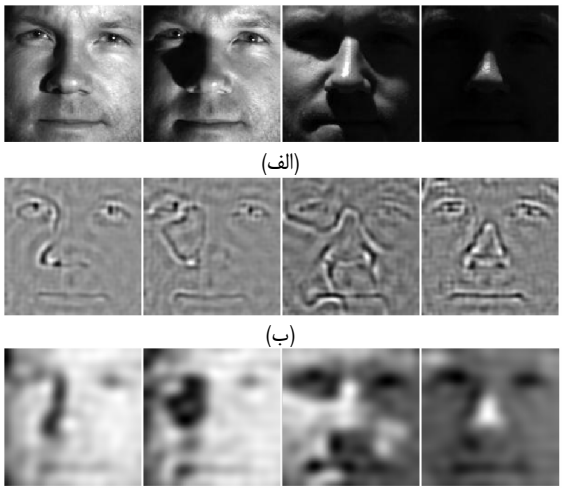

(الف)

(ب)

(ج)

شکل ۴: (الف) تصاویر یک فرد در نورپردازی‌های مختلف، (ب) تصاویر حاصل از ضرایب پایای نوری و (ج) تصاویر حاصل از ویژگی‌های نوری.

۳-۱ ویژگی‌های پایای نوری

همان‌طور که گفته شد ضرایب فرکانس پایین DCT کاملاً وابسته به تغییرات نور هستند. از طرفی ضرایب فرکانس بالای DCT نیز فاقد اطلاعات مهم بوده و اغلب اطلاعات نویزی تصویر را در بر می‌گیرند. بنابراین محدوده مناسبی از ضرایب میانی DCT که علاوه بر حفظ اطلاعات مهم تصویر نسبت به تغییرات نور نیز پایدار هستند، ویژگی‌های پایای نوری را تشکیل می‌دهند.

در تحقیقات انجام‌گرفته توسط نادری و همکارانش [۱۱] برای تعیین ضرایب پایای نوری در تصاویر چهره، تعدادی از ضرایب اول و آخر DCT به ترتیب با هدف کاهش تأثیرات نور و کاهش نویز حذف شده‌اند. نحوه انتخاب ضرایب DCT در شکل ۳ نشان داده شده است. متغیر D تعداد ردیف‌های مورب مورد استفاده از ضرایب DCT را نشان می‌دهد. ضرایب قبل از d_1 جهت کاهش تغییرات نور و ضرایب بعد از d_2 جهت کاهش نویز از تصویر حذف می‌شوند. در نهایت، ضرایب DCT ردیف‌های مورب d_1 تا d_2 به‌عنوان ویژگی‌های پایای نوری جهت بازشناسی چهره در نورپردازی‌های مختلف تعیین می‌شوند. نتایج به‌دست آمده توسط نادری و همکارانش [۱۱] نشان می‌دهد که ضرایب ردیف‌های ۲۰ تا ۵۵ بهترین نرخ شناسایی در نورپردازی‌های مختلف را ارائه می‌دهند.

شکل ۴ پایابودن ضرایب انتخابی در تغییرات نورپردازی را نشان می‌دهد. ردیف اول نمونه‌هایی از تصاویر چهره یک فرد تحت شرایط نوری مختلف و ردیف دوم تصاویر حاصل از ضرایب پایای نوری (که بهترین نرخ شناسایی در تغییرات نورپردازی را ارائه می‌دهند) را نشان می‌دهد [۹]. همان‌طور که در شکل ۴-ب دیده می‌شود، در ویژگی‌های پایای نوری تا حد زیادی اثرات نامطلوب نور و سایه‌ها حذف شده و ویژگی‌های مهم چهره حفظ گردیده است.

شکل ۴-ج تصاویر حاصل از ویژگی‌های حذف‌شده DCT (ردیف‌های مورب قبل از d_1) را نشان می‌دهد. همان‌طور که در شکل دیده می‌شود این ویژگی‌ها اطلاعات مربوط به تغییرات نور و سایه‌ها در تصویر چهره را ارائه می‌دهند و کاندید مناسبی برای استخراج دانش مربوط به زاویه نورپردازی می‌باشند.

۳-۲ استخراج ویژگی‌های مؤثر در تغییرات نور

پس از تفکیک ضرایب پایای نوری، ویژگی‌های مؤثر در تغییرات نور از

Archive of SID

www.SID.ir

جدول ۱: مقایسه روش‌های یادگیری بانظارت بر اساس معیارهای مختلف.

روش / معیار	شبکه عصبی	k همسایه نزدیک‌تر	درخت تصمیم	بیز	SVM
سرعت یادگیری با استفاده از داده‌های محدود	*	–	***	****	*
مقاومت در برابر فقدان داده	*	*	***	****	**
مقاومت در برابر نویز	**	*	**	***	**
توانایی مقابله با Over fitting	*	–	**	***	**
قابلیت توسعه	***	–	**	****	**
شفافیت توصیف دانش	*	**	****	****	*

بین سایر ضرایب DCT انتخاب و برای یادگیری دانش مورد نیاز درباره زاویه نورپردازی استفاده می‌شوند. بر این اساس مراحل انجام کار به صورت زیر است:

۱) **انتخاب ویژگی‌های نوری:** همان‌طور که در بخش قبل اشاره شد، ضرایب ابتدایی DCT یعنی مؤلفه‌های قبل از $d_{۱۰}$ در شکل ۳ (که با رنگ خاکستری مشخص شده‌اند) مؤلفه‌های مناسبی جهت تعیین کلاس نوری تصویر می‌باشند. از این رو ضرایب ردیف‌های مورب ۲ تا ۱۹ DCT به‌عنوان ویژگی‌های مؤثر در نورپردازی‌های متفاوت انتخاب شده‌اند (ضریب اول DCT نشان‌دهنده روشنایی کلی تصویر است که در نظر گرفته نشده است).

۲) **نرمال‌سازی:** نتایج به‌دست آمده در ارزیابی‌های صورت‌گرفته روی ضرایب خام DCT و ضرایب نرمال‌شده DCT نشان می‌دهد که ضرایب DCT نرمال‌شده نسبت به ضرایب خام در یادگیری کلاس‌های نوری به‌طور مؤثرتری عمل می‌کند. در این تحقیق نرمال‌سازی ویژگی‌ها با محاسبه نرم اقلیدسی ضرایب DCT مربوط به ردیف‌های ۲ تا ۱۹ مطابق (۱) به‌دست می‌آید. c_i نشان‌دهنده ضرایب DCT و m تعداد ضرایب انتخابی است

$$nc_i = \frac{c_i}{\sum_{k=۱:m} c_k^۲} \quad , \quad \text{for } i = ۱:m \qquad (۱)$$

۳) **بخش‌بندی[1] مقادیر ویژگی:** با توجه به این که برخی از روش‌های یادگیری از جمله روش‌های مبتنی بر بیز نیاز به داده‌هایی با مقادیر ویژگی گسسته دارند، با بخش‌بندی مقادیر ویژگی‌ها (که دارای مقادیر پیوسته هستند) به‌وسیله روشی غیر نظارتی، ویژگی‌هایی با مقادیر گسسته ایجاد می‌شود. به این صورت که تعداد کلاس‌ها برای هر ویژگی با هدف حداکثرشدن فاصله بین مرکز کلاس‌ها و حداقل‌نمودن واریانس هر کلاس طبق (۲) تعیین می‌شود

$$S = \frac{\max_{i=۱}^{\text{max.No.cluster}} (\text{Variance } x_i)}{\min_{i,j \in \{۱,\ldots,\text{max.No.cluster}\}} (\text{dist}(x_i, x_j))} = \frac{\max \text{ Scattering of clusters}}{\min \text{ dist. between cluster centers}} \qquad (۲)$$

که x_i نشان‌دهنده مرکز کلاس iام است. به‌ازای هر ویژگی مقدار S متناظر با تعداد کلاس‌های مختلف محاسبه می‌شود. کم‌ترین مقدار S بهترین تعداد کلاس‌ها برای آن ویژگی را مشخص می‌کند.

ضرایب انتخابی نرمال‌شده DCT پس از بخش‌بندی مقادیر به‌عنوان ویژگی‌های نوری جهت استخراج دانش مربوط به زاویه نورپردازی توسط یادگیرنده‌های مختلف مورد استفاده قرار می‌گیرند.

٤- استخراج دانش مربوط به زاویه نورپردازی

پس از تعیین ویژگی‌های نوری تصویر، نوبت به انتخاب یادگیرنده مناسب جهت استخراج دانش مربوط به زاویه نورپردازی می‌رسد.

الگوریتم‌های یادگیری به سه گروه یادگیری بانظارت، یادگیری بدون نظارت و یادگیری تقویتی تقسیم می‌شوند. از آنجا که در مسأله ما کلاس‌های نوری (که همان خروجی مسأله هستند) از قبل مشخص شده‌اند، روش‌های یادگیری مورد استفاده در این مقاله باید از نوع بانظارت باشند.

در جدول ۱ روش‌های مختلف یادگیری بانظارت بر اساس شش معیار مهم با یکدیگر مقایسه شده‌اند. تعداد ستاره‌ها نشان‌دهنده توان روش در معیارهای مختلف است.

در میان روش‌های یادگیری بانظارت، روش k همسایه نزدیک‌تر به نویز حساس است و از آنجا که زمان پاسخ خوبی نداشته و دانشی هم یاد نمی‌گیرد، برای مسأله موجود در این تحقیق مناسب نیست. شبکه عصبی هم علاوه بر این که فاقد شفافیت لازم در قابلیت توصیف دانش است، نیاز به داده‌های آموزشی زیادی دارد و داده‌های بی‌ربط می‌تواند باعث آموزش بی‌حاصل و غیر عملی در شبکه عصبی شود. علاوه بر این k همسایه نزدیک‌تر و شبکه‌های عصبی به مجموعه داده‌ای کامل نیاز دارند و در صورت نقص داده ورودی کارایی مناسبی نخواهند داشت [۱۲] تا [۱۴].

روش‌های یادگیری SVM، درخت تصمیم و بیز با توجه به مقاومت در برابر نویز و فقدان داده، از قابلیت اطمینان بهتری برخوردارند. روش SVM یکی از محبوب‌ترین روش‌های یادگیری است که دقت خوبی در کاربردهای مختلف طبقه‌بندی ارائه می‌دهد. روش‌های مبتنی بر بیز با استفاده از یک مجموعه داده کوچک آموزش دیده و می‌توانند به‌عنوان یادگیرنده‌های قابل توسعه مورد استفاده قرار گیرند. شفافیت[2] یا قابلیت توصیف دانش (توصیف کلاس‌بندی) یکی از ویژگی‌های مطلوب الگوریتم‌های یادگیری است که درک عملیات انجام‌گرفته توسط روش یادگیری را آسان می‌کند. در میان روش‌های یادگیری بانظارت، بیز ساده و درخت تصمیم از شفافیت لازم برای توصیف دانش برخوردارند [۱۵].

٤-۱ انتخاب یادگیرنده مناسب

با توجه به مسأله طبقه‌بندی کلاس‌های نوری، پس از تحلیل و مقایسه روش‌های مختلف یادگیری بانظارت از دیدگاه‌های گوناگون، سه روش درخت تصمیم، SVM و بیز برای یادگیری کلاس‌های نوری در این تحقیق انتخاب و مورد ارزیابی قرار گرفته‌اند. درخت تصمیم و SVM هر دو توانایی مدل‌کردن تغییرات داده و ایجاد مدل‌های پیچیده را دارند و هر یک با ارائه رویکردی برای مقابله با Overfitting (هرس‌کردن درخت تصمیم و بیشینه‌کردن حاشیه در SVM) نسبت به نویز مقاوم هستند. علاوه بر این درخت تصمیم قابلیت توصیف دانش را به‌صورت مطلوبی فراهم می‌کند. از جمله ویژگی‌های برجسته روش‌های بیزی هم می‌توان به آموزش سریع، حساسیت کم به مفقودشدن داده‌ها، قابلیت توسعه روش و شفافیت توصیف دانش در آنها اشاره کرد. در ادامه این روش‌ها را به‌طور

1. Partitioning

2. Transparency

Archive of SID
www.SID.ir

مختصر معرفی می‌کنیم.

٤-۲ درخت تصمیم

اغلب الگوریتم‌های یادگیری درخت تصمیم بر پایه یک عمل جستجوی حریصانه بالا به پایین در فضای درخت‌های موجود عمل می‌کنند. این روش نسبت به نویز داده‌ها مقاوم بوده و قادر است ترکیب فصلی گزاره‌های عطفی را یاد بگیرد. درخت تصمیم در زمینه کلاس‌بندی دارای کاربردهای فراوانی بوده و به همین جهت به آن درخت کلاس‌بندی یا درخت رگرسیون هم می‌گویند. ایده اصلی درخت تصمیم مبتنی بر این حقیقت است که هر ویژگی داده ورودی می‌تواند برای تصمیم‌گیری استفاده شده و داده‌ها را به زیرمجموعه‌های کوچک‌تری تقسیم کند. این الگوریتم از بهره اطلاعات[1] نرمال (مبتنی بر تفاوت آنتروپی) استفاده نموده، ویژگی با بالاترین بهره اطلاعاتی را برای تصمیم‌گیری انتخاب کرده و بر اساس آن داده‌های ورودی را به زیرمجموعه‌های کوچک‌تر تقسیم می‌کند.

SVM ٣-٤

SVM یکی از روش‌های مطرح در تشخیص الگو برای طبقه‌بندی دوکلاسه است که با فرض این که کلاس‌ها به‌صورت خطی جداپذیر باشند، ابرصفحه‌هایی با حداکثر حاشیه را به‌دست می‌آورد که کلاس‌ها را جدا کنند. در مسایلی که داده‌ها به‌صورت خطی جداپذیر نباشند، داده‌ها به فضایی با ابعاد بالاتر نگاشت می‌شوند تا بتوان آنها را در این فضای جدید به‌صورت خطی جدا نمود.

٤-٤ استدلال بیزی

استدلال بیزی روشی بر پایه احتمالات برای استنتاج است که در برخی کاربردها مانند طبقه‌بندی متن نتایج خوبی را ارائه می‌دهد. این روش بر این اصل استوار است که برای هر کمیتی یک توزیع احتمال وجود دارد که با مشاهده یک داده جدید و استدلال در مورد توزیع احتمال آن می‌توان تصمیمات بهینه‌ای اتخاذ کرد.

شبکه بیزی تمام وابستگی‌های شرطی بین ویژگی‌ها را در نظر می‌گیرد و در نتیجه ساختار پیچیده‌ای پیدا می‌کند که یادگیری آن بسیار مشکل است. ساده‌ترین راه، چشم‌پوشی از وابستگی‌های شرطی بین ویژگی‌ها است.

بیز ساده یک الگوریتم یادگیری ساده، مؤثر و کارا برای کاربردهای طبقه‌بندی است [۱۶] که با فرض استقلال شرطی و نادیده‌گرفتن وابستگی بین ویژگی‌ها، باعث کاهش پیچیدگی و در بسیاری موارد باعث کاهش دقت می‌شود. از این رو به نظر می‌رسد یادگیری یک ساختار محدود، عملی‌تر باشد. روش‌های توسعه‌یافته مبتنی بر بیز مانند AODE[2]، HNB[3] و WAODE به این منظور ارائه شده‌اند و تلاش می‌کنند یک ساختار محدود اما مؤثر را یاد بگیرند. AODE با متوسط‌گیری از مدل‌هایی که در آنها تمام ویژگی‌ها به کلاس و یک ویژگی دیگر وابسته هستند، یک ساختار محدود از شبکه بیزی برای حل مشکل ارائه می‌دهد [۱۷]. یک راه ساده برای توسعه AODE این است که به هر ویژگی وزن متفاوتی تخصیص داده شود. بر این اساس Jiang و همکارش مدل جدیدی را تحت عنوان WAODE معرفی کردند [۱۸]. WAODE از متوسط وزن‌دار مدل‌های ایجادشده توسط AODE استفاده می‌کند. برای تعیین وزن‌ها از معیار "اطلاعات متقابل"[4] استفاده می‌شود و در نهایت الگوریتم HNB با در نظر گرفتن یک والد مخفی برای هر ویژگی، یک مدل بیز مطلوب بدون نیاز به یادگیری ساختار ارائه می‌دهد [۱۹]. HNB با استفاده از تنها یک طبقه‌بند، در مقابلِ AODE که از مجموع طبقه‌بندها استفاده می‌کند، می‌تواند مدل قابل درکی را برای طبقه‌بندی ارائه دهد، اما WAODE به دلیل استفاده از آنتروپی یا همان "اطلاعات متقابل" با در نظر گرفتن ارزش ویژگی‌های مختلف در مسأله طبقه‌بندی، یادگیری بهتری را در مقایسه با دو روش دیگر ارائه می‌دهد.

٥- نتایج ارزیابی

در این بخش به تحلیل عملکرد یادگیرنده‌های درخت تصمیم، SVM و روش‌های مبتنی بر بیز پرداخته و توانایی این الگوریتم‌ها را در یادگیری کلاس‌های نوری برای تصاویر چهره مورد ارزیابی و مقایسه قرار داده‌ایم. لازم به ذکر است در این تحقیق از ابزار داده‌کاوی Weka [۲۰] برای پیاده‌سازی الگوریتم‌های یادگیری استفاده شده است.

پایگاه تصویری مورد استفاده در این مقاله YaleB می‌باشد که حاوی ۶۴۰ تصویر از ۱۰ فرد تحت ۶۴ حالت نوری مختلف است و در مقالات مختلف به‌عنوان پایگاه داده مرجع جهت مقایسه نتایج شناسایی در تغییرات نور مورد استفاده قرار می‌گیرد. علاوه بر پایگاه تصویری YaleB (شامل ۶۴۰ تصویر)، از پایگاه تصویری extended Yale شامل ۲۴۳۲ تصویر از ۳۸ نفر در ۶۴ حالت نوری مشابه نیز برای تأیید ارزیابی نتایج به‌دست آمده استفاده می‌گردد.

٥-۱ معیار ارزیابی

روش ارزیابی مورد استفاده در این تحقیق "ارزیابی متقابل k تایی"[5] است. به این صورت که مجموعه داده‌ها (در هر یک از ۵ زیرمجموعه نوری) به‌صورت تصادفی به k قسمت تقسیم و یادگیری k مرتبه تکرار می‌گردد. در هر مرتبه $k-۱$ قسمت برای آموزش و یک قسمت برای آزمایش استفاده می‌شود و میانگین نتایج به‌دست آمده، به‌عنوان نتیجه ارزیابی ارائه می‌گردد. در این مقاله ما k را ۱۰ در نظر گرفته‌ایم.

دقت[6] و صحت فراخوانی[7] دو معیار متعارف برای ارزیابی روش‌های مختلف یادگیری می‌باشند که به‌ترتیب نشان‌دهنده دقت و صحت طبقه‌بند برای هر کلاس هستند. دقت نمایانگر تعداد نمونه‌های درست تخصیص داده شده به یک کلاس نسبت به کل نمونه‌های تخصیص داده شده به آن کلاس می‌باشد. در حالی که صحت فراخوانی نسبت نمونه‌های درست تخصیص داده شده به یک کلاس به کل نمونه‌های مربوط به آن کلاس را نشان می‌دهد.

از آنجا که هر دو معیار دقت و صحت طبقه‌بندی دارای اهمیت هستند، در این مقاله برای ارزیابی نتایج کار طبق (۳) از معیار $F۱$ استفاده می‌شود و متوسط مقدار $F۱$ در ۵ کلاس نوری به‌عنوان معیاری برای مقایسه نتایج در نظر گرفته شده است

$$F۱ = ۲\times\frac{\text{precision}\times\text{recall}}{\text{precision}+\text{recall}} \qquad (۳)$$

1. Information Gain
2. Averaged One-Dependence Estimators
3. Hidden Naive Bayes
4. Mutual Information
5. K-Fold Cross Validation
6. Precision
7. Recall

Archive of SID

www.SID.ir

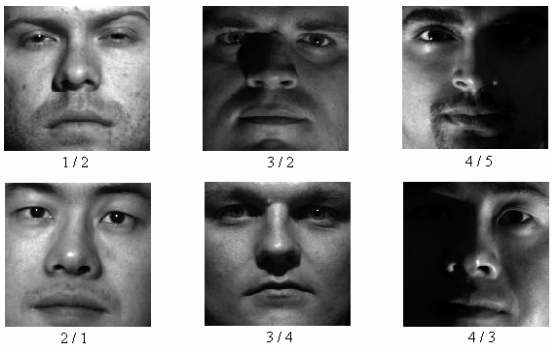

شکل ۵: نمونه خطاهای روش WAODE که در روش SVM بهبود یافته و درست طبقه‌بندی می‌شوند (x/y: x کلاس نمونه و y نتیجه طبقه‌بندی توسط روش WAODE را نشان می‌دهد).

۵-۲ نتایج یادگیری کلاس‌های نوری با درخت تصمیم

درخت تصمیم یکی از روش‌های شناخته‌شده یادگیری است که در ابزارهای مختلف از جمله ID۳ [۲۱]، J۴٫۸ [۲۲]، RIPPER [۲۳] و C۴٫۵ [۲۴] با معیارهای متفاوت پیاده‌سازی شده است. در نسخه J۴٫۸ درخت تصمیم از تکنیک‌هایی برای هرس‌کردن درخت همراه با بهبود خطای طبقه‌بندی و اجتناب از برازش بیش از حد استفاده می‌شود. نتایج به‌دست آمده از درخت تصمیم J۴٫۸ جهت یادگیری کلاس‌های نوری و کسب دانش مربوطه در جدول ۲ نشان داده شده است.

برای بررسی خطای طبقه‌بندی، ماتریس سردرگمی به‌دست آمده در روش J۴٫۸ در (۴) مورد بررسی قرار گرفته است

$$C_{J۴٫۸}=\begin{array}{|c|ccccc|}\hline \text{Class} & ۱ & ۲ & ۳ & ۴ & ۵ \\ \hline ۱ & ۴۸ & ۲۰ & ۲ & ۰ & ۰ \\ ۲ & ۱۵ & ۹۳ & ۱۱ & ۱ & ۰ \\ ۳ & ۱ & ۱۲ & ۸۹ & ۱۸ & ۰ \\ ۴ & ۰ & ۰ & ۱۵ & ۱۱۱ & ۱۴ \\ ۵ & ۰ & ۰ & ۲ & ۹ & ۱۷۹ \\ \hline \end{array} \qquad (۴)$$

همان‌طور که مشاهده می‌شود، بیشترین خطای طبقه‌بندی در کلاس‌های مجاور اتفاق افتاده است. با توجه به این که تفکیک کلاس‌های نوری مطابق شکل ۱ بر اساس زاویه نورپردازی انجام شده و فاصله اطمینان مشخصی بین زاویه نورپردازی کلاس‌های مجاور در نظر گرفته نشده است، این نتیجه منطقی به نظر می‌رسد.

۵-۳ نتایج یادگیری کلاس‌های نوری مبتنی بر SVM و بیز

جدول ۳ نتایج به‌دست آمده از دو روش SVM و WAODE برای یادگیری کلاس‌های نوری را نشان می‌دهد.

همان‌طور که دیده می‌شود WAODE نتایج به مراتب بهتری را (با متوسط دقت ۹۲٫۷۴٪) نسبت به درخت تصمیم ارائه داده است. روش WAODE علاوه بر این که از شفافیت توصیف دانش خوبی برخوردار است و به مفقودشدن داده‌ها نیز حساس نمی‌باشد، به‌دلیل استفاده از معیار اطلاعات متقابل که نوعی آنتروپی محسوب می‌شود، مشابه درخت تصمیم قابلیت اولویت‌بندی ویژگی‌ها بر اساس اهمیت آنها را هم دارد.

برای پیاده‌سازی SVM با هدف بیشینه‌سازی فاصله بین کلاس‌ها از نسخه Sequential Minimal Optimization استفاده شده است [۲۰]. ایده کلی این است که پس از نرمال‌سازی داده‌ها، کلاس‌ها دوبه‌دو با روشی مشابه SVM جدا می‌شوند.

جدول ۲: نتایج یادگیری کلاس‌های نوری توسط درخت تصمیم J۴٫۸.

روش / مجموعه	کلاس ۱	کلاس ۲	کلاس ۳	کلاس ۴	کلاس ۵	متوسط
J۴٫۸	۷۱٫۶	۷۵٫۹	۷۴٫۵	۷۹٫۶	۹۳٫۵	۷۹٫۰۲

جدول ۳: نتایج یادگیری کلاس‌های نوری با روش‌های یادگیری مختلف.

روش / مجموعه	کلاس ۱	کلاس ۲	کلاس ۳	کلاس ۴	کلاس ۵	متوسط
WAODE	۹۱٫۵	۹۰٫۸	۹۱٫۲	۹۳٫۱	**۹۷٫۱**	۹۲٫۷۴
SVM	**۹۵٫۲**	**۹۳٫۸**	**۹۵٫۷**	**۹۴٫۴**	۹۶٫۳	**۹۵٫۰۸**

متوسط نرخ طبقه‌بندی صحیح به‌دست آمده از این روش بر اساس معیار F۱ مطابق جدول ۳، ۹۵٫۰۸٪ می‌باشد. با توجه به عملکرد کارای SVM در یادگیری رابطه غیر خطی بین ورودی و خروجی و مقاومت آن در برابر نویز، همان‌طور که انتظار می‌رود نتایج به‌دست آمده دارای دقت بالایی هستند.

همان‌طور که دیده می‌شود در کلاس‌های ۱ تا ۴ SVM و در کلاس ۵ WAODE نتایج بهتری را ارائه داده است، ضمن آن که SVM نسبت به WAODE از متوسط دقت بالاتری برخوردار است.

٤-۵ تحلیل نتایج

در (۵) و (۶) ماتریس‌های سردرگمی به‌دست آمده برای دو روش SVM و WAODE نشان داده شده است

$$C_{SVM^P}=\begin{array}{|c|ccccc|}\hline \text{Class} & ۱ & ۲ & ۳ & ۴ & ۵ \\ \hline ۱ & ۶۹ & ۱ & ۰ & ۰ & ۰ \\ ۲ & ۶ & ۱۱۳ & ۱ & ۰ & ۰ \\ ۳ & ۰ & ۷ & ۱۱۲ & ۱ & ۰ \\ ۴ & ۰ & ۰ & ۱ & ۱۳۴ & ۵ \\ ۵ & ۰ & ۰ & ۰ & ۹ & ۱۸۱ \\ \hline \end{array} \qquad (۵)$$

$$C_{WAODE}=\begin{array}{|c|ccccc|}\hline \text{Class} & ۱ & ۲ & ۳ & ۴ & ۵ \\ \hline ۱ & ۶۵ & ۵ & ۰ & ۰ & ۰ \\ ۲ & ۷ & ۱۱۳ & ۰ & ۰ & ۰ \\ ۳ & ۰ & ۱۱ & ۱۰۳ & ۶ & ۰ \\ ۴ & ۰ & ۰ & ۳ & ۱۳۵ & ۲ \\ ۵ & ۰ & ۰ & ۰ & ۹ & ۱۸۱ \\ \hline \end{array} \qquad (۶)$$

همان‌طور که دیده می‌شود بر خلاف درخت تصمیم، خطاهای طبقه‌بندی تنها محدود به کلاس‌های نوری مجاور است که با توجه به زاویه نورپردازی نزدیک در آنها، این خطا تا حدی قابل پیش‌بینی می‌باشد. شکل ۵ نمونه خطاهای روش WAODE را نشان می‌دهد که در روش SVM درست طبقه‌بندی می‌شوند. به‌عنوان مثال اولین تصویر سمت راست در ردیف اول نمونه‌ای از کلاس نوری ۴ است که روش WAODE به اشتباه آن را در کلاس ۵ طبقه‌بندی کرده و روش SVM آن را به درستی در کلاس ۴ طبقه‌بندی می‌کند.

روش SVM نتایج بهتری را نسبت به سایر روش‌ها در مسأله یادگیری کلاس‌های نوری ارائه داده است. شکل ۶ برخی از خطاهای طبقه‌بندی کلاس‌های نوری توسط روش SVM را نشان می‌دهد.

تصویر سمت راست، نمونه‌ای از تصاویری است که توسط روش WAODE به درستی طبقه‌بندی شده و باعث بهبود دقت طبقه‌بندی در کلاس نوری ۵ توسط WAODE نسبت به SVM شده است.

Archive of SID
www.SID.ir

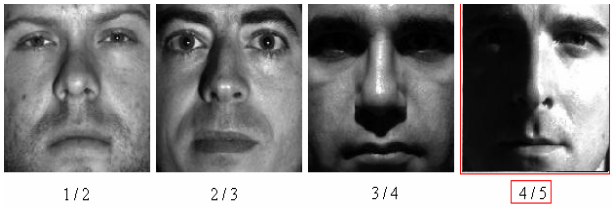

شکل ۶. نمونه تصاویر خطا در روش SVM (x/y: نمونه متعلق به کلاس x به اشتباه در کلاس y کلاس‌بندی شده است).

نتایج به‌دست آمده نشان می‌دهد که SVM بهترین متوسط دقت برای طبقه‌بندی کلاس‌های نوری بر اساس زاویه نورپردازی را ارائه می‌دهد، در حالی که برای کلاس ۵ (تصاویری با نورپردازی شدید)، روش WAODE نتایج بهتری دارد.

برای ارزیابی قابلیت اطمینان نتایج به‌دست آمده، روش پیشنهادی را بر روی پایگاه تصویری extended Yale[1] نیز امتحان کردیم. این پایگاه شامل ۲۴۳۲ تصویر از ۳۸ فرد در ۶۴ حالت نوری می‌باشد. جدول ۴ نتایج به‌دست آمده از روش پیشنهادی روی پایگاه تصویری extended Yale را نشان می‌دهد. همان‌طور که دیده می‌شود باز هم WAODE و SVM نتایج بهتری را نسبت به درخت تصمیم ارائه داده و SVM با وجود متوسط دقت بالاتر در برخی کلاس‌ها (کلاس ۴ و ۵) ضعیف‌تر از WAODE عمل نموده است.

بخش تاریک در تصاویر چهره به نوعی شامل نویز بوده و فاقد اطلاعات اصلی تصویر می‌باشد و در کلاس‌های نوری ۴ و ۵ به‌دلیل زاویه تابش زیاد، بخش زیادی از تصویر تاریک است. بنابراین می‌توان این‌طور نتیجه‌گیری کرد که روش WAODE به دلیل مقاومت بهتر در برابر نویز و فقدان اطلاعات (بر اساس جدول ۱)، در کلاس‌هایی با نورپردازی شدید بهتر از روش SVM جواب می‌دهد.

بر این اساس پیشنهاد ترکیب طبقه‌بندهای SVM و WAODE برای بهبود نتایج در هر یک از کلاس‌ها مطرح می‌شود. SVM از متوسط دقت بالایی برخوردار است، در مقابل WAODE با توجه به مقاومت بهتر در برابر نویز و فقدان داده، در کلاس‌هایی با نورپردازی شدید بهتر از SVM عمل نموده و قابلیت توصیف دانش خوبی دارد.

٦- جمع‌بندی

از آنجا که تغییرات نور و عدم اطلاعات کافی در مورد منبع نور و زاویه تابش یکی از مشکلات مطرح در سیستم‌های بازشناسی چهره می‌باشد، در این مقاله استخراج دانش مربوط به کلاس‌های نوری به‌عنوان راه حلی برای تعیین زاویه نورپردازی در تصاویر چهره پیشنهاد گردیده است. در این روش ضرایب ابتدایی DCT حامل ویژگی‌های فرکانسی مؤثر در تغییرات نورپردازی به‌عنوان ویژگی نوری انتخاب شده و پس از نرمال‌سازی به‌صورت بخش‌بندی شده (گسسته) مورد استفاده قرار گرفته‌اند.

در این مقاله با توجه به این که کلاس‌های نوری از پیش تعریف شده‌اند، رویکرد یادگیری بانظارت در پیش گرفته شده و پس از تحلیل و بررسی، روش‌های یادگیری درخت تصمیم، SVM و بیز برای یادگیری کلاس‌های نوری انتخاب شده‌اند. مقایسه روش‌های انتخاب‌شده (بر اساس متوسط معیار $F1$ در ۵ کلاس نوری) روی پایگاه تصویری YaleB و ExtendedYale که حاوی اطلاعات کافی در مورد منبع نور می‌باشد، انجام گرفته است. نتایج به‌دست آمده نشان می‌دهد که درخت‌های تصمیم در مسأله یادگیری کلاس‌های نوری از کم‌ترین دقت در بین سایر روش‌ها برخوردارند و این ناشی از ضعف درخت تصمیم در افراز قطری کلاس‌ها است. SVM نتایج بهتری را نسبت به درخت تصمیم به‌دست آورده که این بهبود به‌دلیل حساسیت کمتر SVM به نویز و همچنین اجتناب از Overfitting و توانایی در مدل‌کردن رابطه‌های غیر خطی در روش SVM می‌باشد.

جدول ۴: نتایج به‌دست آمده برای طبقه‌بندی کلاس‌های نوری روی پایگاه تصویری EXTENDED YALE.

روش / مجموعه	کلاس ۱	کلاس ۲	کلاس ۳	کلاس ۴	کلاس ۵	متوسط
J4.8	۷۰٫۸	۷۰٫۸	۷۱٫۴	۸۰٫۴	۹۱٫۵	۷۶٫۹۸
WAODE	۸۵٫۶	۸۹٫۶	۹۲٫۵	**۹۲٫۳**	**۹۶٫٤**	۹۱٫۲۸
SVM	**۸۷٫۹**	**۹۰٫۷**	**۹۳٫۳**	۹۱٫۲	۹۶٫۱	**۹۱٫۸٤**

روش WAODE هم نتایج قابل مقایسه‌ای را نسبت به روش SVM ارائه داده است و به‌دلیل برخورداری از ویژگی‌هایی نظیر آموزش سریع، عدم حساسیت به مفقودشدن داده‌ها و نویز، قابلیت توسعه و شفافیت توصیف دانش، گزینه‌ای مناسب برای طبقه‌بندی بهینه کلاس‌های نوری است.

در مجموع، روش SVM متوسط دقت بهتری را نسبت به سایر روش‌ها در مسأله یادگیری کلاس‌های نوری ارائه داده است و این در حالی است که در کلاس‌هایی با نورپردازی شدید (کلاس ۴ و ۵)، روش WAODE به‌دلیل مقاومت بهتر در مقابل نویز و فقدان اطلاعات بهترین نتایج طبقه‌بندی را ارائه می‌دهد. در مقابل نیاز ذاتی SVM به نمونه‌های آموزشی زیاد، الگوریتم‌های مبتنی بر بیز با مجموعه آموزشی نسبتاً کوچکی آموزش می‌بینند و یادگیرنده‌های قابل توسعه‌ای هستند که از شفافیت لازم برای توصیف دانش نیز برخوردارند. از این رو ترکیب طبقه‌بندهای بیز و SVM با هدف بهبود نتایج در هر یک از کلاس‌های نوری برای ادامه کار مطرح شده است.

این تحقیق نشان می‌دهد که اطلاعات نهفته در ضرایب فرکانس پایین DCT قادر به تفکیک کلاس‌های نوری بر اساس زاویه نورپردازی به‌صورت مناسب می‌باشند. در ادامه می‌توان از دانش کسب‌شده جهت اصلاح تصاویر چهره با نورپردازی مختلف استفاده نمود و راه حل‌هایی را جهت کاهش تأثیرات نور برای هر یک از کلاس‌های نوری ارائه داد.

مراجع

[1] T. Chen, W. Yin, X. S. Zhou, D. Comaniciu, and T. S. Huang, "Total variation models for variable lighting face recognition," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 28, no. 9, pp. 1519-1524, Sep. 2006.

[2] [2] J. Ruiz-del-Solar, and J. Quinteros, "Illumination compensation and normalization in eigenspace-based face recognition: a comparative study of different pre-processing approaches," *Pattern Recognition Letters*, vol. 29, no. 14, pp. 1966-1979, Oct. 2008.

[3] [3] O. Arandjelovic and R. Cipolla, "A methodology for rapid illumination - invariant face recognition using image processing filters," *Computer Vision and Image Understanding,* vol. 113, no. 2, pp. 159-171, Feb. 2009.

[4] [4] Y. K. Park, S. L. Park, and J. Kim,, "Retinex method based on adaptive smoothing for illumination invariant face recognition," *Signal Processing,* vol. 88, no. 8, pp. 1929-1945, Aug. 2008.

[5] S. I. Choi, Ch. Kim, C. H. Choi, "Shadow compensation in 2D images for face recognition," *Pattern Recognition*, vol. 40, no. 7, pp. 2118-2125, Jul. 2007.

1. http://vision.ucsd.edu/~leekc/ExtYaleDatabase/ExtYaleB.html

Archive of SID

www.SID.ir

[6] [6] A. Franco, L. Nanni, "Fusion of classifiers for illumination robust face recognition," *Expert Systems with Application*, vol. 36, no.5, pp. 8946-8954, Jul. 2009.
[7] A. S. Georghiades, P. N. Belhumeur, and D. J. Kriegman, "From few to many: illumination cone models for face recognition under differing pose and lighting," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 23, no. 6, pp. 643-660, Jun. 2001.
[8] Y. Adini, Y. Moses, and S. Ullman, "Face recognition: the problem of compensating for changes in illumination direction," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 19, no. 7, pp. 721-732, Jul. 1997.
[9] B. K. P. Horn, "Determining lightness from an image," *Computer Graphics and Image Processing*, vol. 3, no. 1, pp. 277-299, Dec. 1974.
[10] W. Chen, M. J. Er, and S. Wu, "Illumination compensation and normalization for robust face recognition using discrete cosine transform in logarithm domain," *IEEE Trans. on Systems, Man, and Cybernetics Part B: Cybernetics*, vol. 36, no. 2, pp. 458-466, Apr. 2006.
[۱۱] ش. نادری، ن. ا. مقدم چرکری و م. ش. معین، "روشی جدید برای کاهش تأثیر تغییرات نور در بازدهی سیستم‌های بازشناسی چهره،" *پانزدهمین کنفرانس مهندسی برق ایران*،صص. ۱۷۶-۱۸۲، اردیبهشت ۱۳۸۶.
[12] E. Kirkosa, C. Spathisb, and Y. Manolopoulosc, "Support vector machines, decision trees and neural networks for auditor selection," *J. of Computational Methods in Sciences and Engineering Archive*, vol. 8, no. 3, pp. 213-224, Aug. 2008.
[13] M. W. Kattan and R. B. Cooper, "A simulation of factors affecting machine learning techniques: an examination of partitioning and class proportions," *Omega Int. J. Management Science,* vol. 28, no. 5, pp. 501-512, Oct. 2000.
[14] T. S. Lim, W. Y. Loh, and Y. S. Shih, "A comparison of prediction accuracy, complexity, and training time of thirty-three old and new classification algorithms," *Machine Learning,* vol. 40, no. 3, pp. 203-228, Sep. 2000.
[15] S. B. Kotsiantis, "Supervised machine learning: a review of classification techniques," *Informatica*, vol. 31, no. 3, pp. 249-268, Oct. 2007.
[16] G. H. John and P. Langley, "Estimating continuous distributions in bayesian classifiers," in *Proc. 11th Conf. on Uncertainty in Artificial Intelligence*, pp. 338-345, 18-20 Aug. 1995.
[17] G. Webb, J. Boughton, and Z. Wang, "Not so naive bayes: aggregating one-dependence estimators," *Machine Learning J.*, vol. 58, no. 1, pp. 5-24, Jan. 2005.
[18] L. Jiang and H. Zhang, "Weightily averaged one - dependence estimators," in *Proc. of the 9th Biennial Pacific Rim International Conf. on Artificial Intelligence, PRICAI'06*, pp. 970-974, 7–11 Aug. 2006.
[19] H. Zhang and L. Jiang, "Hidden naive bayes," in *Proc. 12th National Conf. on Artificial Intelligence*, pp. 919-924, Pittsburgh, Pennsylvania, US, 9-13 Jul. 2005.
[20] "WEKA: Waikato environment for knowledge analysis", http://www.cs.waikato.ac.nz/ml/weka.
[21] J. R. Quinlan, "Discovering Rules by Induction from large collections of examples," in *Expert Systems in the Micro-Electronic Age*, D. Michie, ed. , pp. 168-201, 1979.
[22] S. L. Salzberg, "Book Review: C4.5: Programs for Machine Learning by J. Ross Quinlan. Morgan Kaufmann Publishers, Inc., 1993," *Machine Learning*, vol. 16, no. 3, pp. 235-240, Sep. 1994.
[23] W. W. Cohen, "Fast effective rule induction," in *Proc. of 12th Int. Conf. on Machine Learning,* pp. 115-123, Lake Tahoe, CA, US, Jul. 1995.
[24] P. Winston, "C4.5 Tutorial, http://www2.cs.uregina.ca /~dbd/cs831/notes/ml/dtrees/c4.5/tutorial.html", 1992.

شقایق نادری تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد کامپیوتر گرایش نرم‌افزار در دانشگاه‌های تربیت معلم تهران و تربیت مدرس به‌ترتیب در سال‌های ۱۳۷۹ و ۱۳۸۱ به پایان رسانده است. نام‌برده از سال ۱۳۸۵ تحصیلات خود را در مقطع دکتری مهندسی کامپیوتر گرایش نرم‌افزار در دانشگاه تربیت مدرس شروع کرده که در حال حاضر هم دانشجوی دکتری این دانشگاه می‌باشد. زمینه پژوهشی مورد علاقه او پردازش تصویر به ویژه بازشناسی تصاویر چهره است.

نصرالله مقدم چرکری کارشناسی خود را در علوم کامپیوتر از دانشگاه شهید بهشتی تهران در سال ۱۳۶۵ دریافت کرد. تحصیلات کارشناسی ارشد و دکترای خود را در رشته‌های مهندسی کامپیوتر و مهندسی سیستم‌های اطلاعاتی در دانشگاه یاماناشی ژاپن به‌ترتیب در سال‌های ۱۳۷۱ و ۱۳۷۴ به پایان رسانده است. او در حال حاضر استادیار دانشکده مهندسی برق و کامپیوتر دانشگاه تربیت مدرس است. زمینه‌های پژوهشی مورد علاقه او الگوریتم‌های موازی، هوش مصنوعی و درک تصویر است.

احسان‌اله کبیر کارشناسی ارشد پیوسته خود را در مهندسی برق و الکترونیک از دانشکده فنی دانشگاه تهران و دکترای خود را در مهندسی سیستم‌های الکترونیک از دانشگاه اسکس در انگلستان به‌ترتیب در سال‌های ۱۳۶۴ و ۱۳۶۹ دریافت کرد. او اکنون استاد دانشکده مهندسی برق و کامپیوتر دانشگاه تربیت مدرس است. زمینه پژوهشی مورد علاقه او بازشناسی الگو، به‌ویژه بازشناسی متون چاپی و دست‌نویس است.

Archive of SID

www.SID.ir