

ادغام ویژگی‌های رنگ و بافت به منظور تشخیص خویشاوندی از روی تصاویر چهره

فهمیه رمضانخانی^۱ و مهدی یزدیان دهکردی^۲

چکیده

سیستم تشخیص خویشاوندی با تجزیه و تحلیل تصاویر چهره دو فرد، خویشاوندی یا عدم خویشاوندی آن دو را مشخص می‌کند. برای تشخیص رابطه خویشاوندی ویژگی‌های مختلف را می‌توان از تصویر چهره دو فرد استخراج نمود. در این مقاله با بررسی ویژگی‌های بافت، رنگ و ادغام موثر این ویژگی‌ها و همچنین بررسی چند طبقه‌بندی‌کننده مختلف، یک سیستم کارا برای تشخیص روابط خویشاوندی نسل اول (پدر - پسر، پدر - دختر، مادر - پسر و مادر - دختر) ارائه شده است. در این راستا دو رویکرد پیشنهادی بررسی شده است: (۱) ادغام ویژگی‌های مؤثر و بررسی طبقه‌بندی‌کننده مختلف برای تشخیص خویشاوندی و (۲) استفاده از متریک یادگیری NRML به منظور تولید بردار ویژگی متمایزکننده جهت افزایش کارایی تشخیص خویشاوندی. روش‌های پیشنهادی برای دو پایگاه داده KinFaceW-I و KinFaceW-II در حالت‌های مختلف تحلیل و ارزیابی شده‌اند. نتایج ارزیابی‌ها نشان می‌دهد، ادغام ویژگی‌ها و استفاده از متریک NRML به خوبی توانسته است عملکرد سیستم تشخیص خویشاوندی را بهبود دهد. علاوه بر دو رویکرد پیشنهادی، استخراج ویژگی از کل تصویر و همچنین به صورت بلوکی از تصویر، بررسی شده و نتایج آن ارائه شده است. نتایج به دست آمده حاکی از آن است که استخراج ویژگی به صورت بلوکی می‌تواند در بهبود نتیجه نهایی تشخیص خویشاوندی موثر واقع شود.

کلیدواژه‌ها

تشخیص خویشاوندی، متریک یادگیری، متریک NRML، استخراج ویژگی، ادغام ویژگی، آنالیز چهره

۱ مقدمه

بهداشتی و سلامتی به صورت هوشمند فعالیت می‌کنند. یکی از دقیق‌ترین راه‌ها برای کسب این اطلاعات، داشتن DNA افراد است. دسترسی به این اطلاعات ممکن است در هر لحظه امکان‌پذیر نباشد [۱]. چهره به عنوان یک ویژگی منحصر به فرد در هر شخص، در استخراج اطلاعاتی مانند جنسیت [۲] تا [۴]، سن [۵] و [۶]، هویت [۷] و [۸]، حالت فرد [۹] و غیره بسیار مورد توجه است. تشخیص خویشاوندی^۱ افراد به وسیله چهره، یکی از زمینه‌های تحقیقاتی جدید به شمار می‌رود. در دهه گذشته

در حال حاضر بسیاری از برنامه‌های کاربردی با به کارگیری و تحلیل اطلاعات شخصی افراد مانند نام، جنسیت، سن، قومیت و غیره در زمینه‌هایی همچون خدمات رسانی، تبلیغات و مراقبت‌های

این مقاله در دی‌ماه ۱۳۹۹ دریافت در تیرماه ۱۴۰۰ بازنگری و در مردادماه همان سال پذیرفته شد.

^۱ دانشجوی کارشناسی ارشد مهندسی کامپیوتر، پردیس فنی و مهندسی، دانشگاه یزد

رایانامه: framazankhani@stu.yazd.ac.ir

^۲ دانشکده مهندسی کامپیوتر، پردیس فنی و مهندسی، دانشگاه یزد

رایانامه: yazdian@yazd.ac.ir

¹ Kinship verification

تبدیل آن به فضای رنگ HSV، ویژگی آماری نرمال شده تصویر^۸ را برای هر کانال آن به دست می‌آورد. دو بردار ویژگی استخراج شده از تصویر والد و فرزند توسط معیار شباهت کسینوس با یکدیگر ترکیب شده است. در انتها مدل یادگیری ماشین افراطی جهت تشخیص خویشاوندی آموزش داده شده است. بررسی دیگر از روش‌ها جهت استخراج ویژگی است. در سال ۲۰۱۹ Van [۱۶] و همکاران با استفاده از ویژگی بافت الگوهای دودویی محلی در کانال‌های رنگی مختلف تصویر، روشی را جهت تشخیص خویشاوندی مطرح کردند. در این روش ابتدا تصویر والد و فرزند به دو کانال رنگی YUV و bwruby منتقل شده و سپس هر تصویر به بلوک‌های فاقد همپوشانی در سطوح مختلف تقسیم می‌شوند. برای هر یک از بلوک‌ها ویژگی بافت الگوهای دودویی محلی استخراج می‌شود. در نهایت بردار ویژگی‌های به دست آمده با هم ترکیب می‌شوند. میزان همبستگی ویژگی‌های استخراج شده از تصویر والد و فرزند توسط فاصله مجذور کای^۹ محاسبه می‌شود. بردار ویژگی نهایی توسط طبقه‌بندی کننده ماشین بردار پشتیبان^{۱۰} جهت تأیید یا رد خویشاوندی استفاده شده است. همچنین Laiadi [۱۷] در سال ۲۰۱۹ کارایی اطلاعات رنگ در تصویر را در کانال‌های رنگی مختلف جهت تشخیص خویشاوندی مورد بررسی قرار داد. در این روش ابتدا تصویر RGB والد و فرزند به ۶ فضای رنگی YcbCr، Luv، Lab، HSV، HSL و YUV منتقل می‌شود. سپس ویژگی‌های محلی شامل ویژگی آماری نرمال شده تصویر، کمیت مرحله محلی^{۱۱} و وقوع همزمان الگوهای باینری محلی^{۱۲} برای هر یک از کانال‌ها محاسبه می‌شود. به‌ازای هر جفت بردار ویژگی برای هر یک از کانال‌های رنگ، میزان شباهت کسینوسی به دست آمده و امتیاز ادغام نتایج، توسط رگرسیون لجستیک^{۱۳} محاسبه می‌گردد. در انتها جهت تصمیم‌گیری خویشاوندی یا عدم خویشاوندی، امتیاز به دست آمده با حد آستانه مقایسه می‌شود. در سال ۲۰۱۵ Jiwen Lu [۱۸] و همکاران با استخراج ویژگی‌های هیستوگرام مبتنی بر گرادیان^{۱۴} (HOG) و LBP و اعمال الگوریتم‌های تجزیه و تحلیل مؤلفه اصلی، ابعاد بردار ویژگی را کاهش می‌دهند. در ادامه با استفاده از الگوریتم یادگیری متریک دفع همسایه (NRML)^{۱۵}، متریک فاصله متمایزکننده بین نمونه‌های داخل کلاس (دارای رابطه خویشاوندی) و نمونه‌های بین کلاسی (بدون رابطه خویشاوندی) آموزش داده می‌شود. در نهایت میزان شباهت کسینوسی در هر جفت رابطه

روش‌های گوناگونی برای این منظور ارائه شده است. تشخیص خویشاوندی، روشی است که طی آن خویشاوندی یا عدم خویشاوندی دو فرد با تحلیل تصاویر چهره آن‌ها مشخص می‌شود. نتایج به دست آمده از این تحلیل در زمینه‌هایی همچون پزشکی قانونی [۱]، پیدا کردن افراد گم شده [۱۰]، ساختن آلبوم خانوادگی، آنالیز تصاویر به اشتراک گذاری شده در شبکه‌های اجتماعی [۱۱]، بحران پناهندگی [۱۲] و غیره استفاده می‌شود.

عموماً ۱۱ رابطه خویشاوندی در ۳ سطح هم نسل، نسل اول و نسل دوم قابل تعریف است [۱۲]. روابط خویشاوندی هم نسل: برادر- برادر، خواهر- خواهر و برادر- خواهر، روابط خویشاوندی نسل اول: پدر- پسر، پدر- دختر، مادر- پسر و مادر- دختر و روابط خویشاوندی نسل دوم: پدر بزرگ- نوه پسر، پدر بزرگ- نوه دختر، مادر بزرگ- نوه پسر و مادر بزرگ- نوه دختر می‌باشند.

تشخیص خویشاوندی در دهه گذشته به یکی از زمینه‌های تحقیقاتی جدید روی تصاویر چهره تبدیل شده است. جمع‌آوری تصاویر مناسب مهم‌ترین چالشی است که در این زمینه با آن روبرو هستیم. تصاویر گرفته شده از اعضای خانواده به علت تغییرات میزان وضوح، روشنایی، تار بودن، پوشاندگی، پس زمینه شلوغ [۱۳]، فاصله سنی والدین و فرزندان و تفاوت جنسیت آن‌ها [۱۴]، در میزان دقت عملکرد سیستم اثرگذار خواهد بود.

ویژگی‌های کلاسیک بافت و رنگ تصاویر به منظور استخراج ویژگی‌های کلی و کم عمق از تصاویر استفاده می‌شوند. این دو ویژگی به صورت جداگانه و یا ترکیبی در کنار یکدیگر یکی از روش‌های رایج در تشخیص خویشاوندی می‌باشند. در سال ۲۰۱۸ wang [۱۴] و همکارانش با در نظر گرفتن فاصله زیاد سنی والدین و فرزندان، روشی را برای تقویت دقت تشخیص خویشاوندی مطرح کردند. در این روش ابتدا تصاویر جوان شده والدین مسن توسط شبکه مولد تخصصی^۱ تولید می‌شود. سپس ویژگی‌های بافت الگوهای دودویی محلی^۲ (LBP) و تبدیل ویژگی مستقل از مقیاس^۳ (SIFT) و ویژگی‌های عمیق استخراج شده توسط شبکه RENSET ارزیابی می‌شوند. الگوریتم‌های مقایسه‌ای پیش‌بینی حفظ مکان^۴، جاسازی محل نگهداری^۵، حاشیه بزرگترین نزدیک‌ترین همسایه^۶ و متریک یادگیری تبعیض‌آمیز^۷ با ویژگی‌های شبکه RENSET ادغام می‌شوند. جهت ارزیابی ویژگی‌های پیشنهادی از شباهت کسینوسی استفاده شده است. در سال ۲۰۱۸ Xiaoting Wu [۱۵] و همکارانش روشی را مطرح کردند که با دریافت تصویر از والد و فرزند در فضای رنگ RGB و

⁸ Binarized Statistical Image Features (BSIF)

⁹ Chi-Square Distance

¹⁰ Support Vector Machines (SVM)

¹¹ Local Phase Quantization (LPQ)

¹² Co-Occurrence Of Adjacent Local Binary Patterns (COALBP)

¹³ Logistic Regression

¹⁴ Histograms Of Oriented Gradients (HOG)

¹⁵ Neighborhood Repulsed Metric Learning (NRML)

¹ Generative Adversarial Networks (GANs)

² Local Binary Patterns (LBP)

³ Scale Invariant Feature Transformation (SIFT)

⁴ Locality Preserving Projections (LPP)

⁵ Neighborhood Preserving Embedding (NPE)

⁶ Large Margin Nearest Neighbor (LMNN)

⁷ Sparse Discriminative Metric Loss (SDM-Loss)

خویشاوندی را به حداقل و اختلاف بین نمونه‌ها با رابطه خویشاوندی را به حداکثر می‌رساند. سپس تابع مقابله با جذب نمونه‌های دارای رابطه خویشاوندی به یکدیگر و دفع نمونه‌های بدون رابطه خویشاوندی از یکدیگر، ویژگی‌های متمایزکننده تصاویر والد و فرزند را استخراج می‌کند. در سال ۲۰۲۰ Yan [۲۴] و همکارش از شبکه عمیق ارتباطی برای استخراج ویژگی از تصاویر خویشاوندی استفاده کرده‌اند. در این ساختار برای هر جفت از تصاویر ابتدا دو شبکه عصبی با وزن‌های اشتراکی استفاده شده تا مجموعه ویژگی‌ها در مقیاس‌های مختلف تولید شود. در ادامه برای هر گروه از ویژگی‌ها که مقیاس و مکان آن‌ها یکسان است از شبکه ارتباطی برای استدلال رابطه و برای استنباط آن براساس نتایج روابط محلی، از یک شبکه تأیید استفاده شده است. Dahan [۲۵] و همکارش یک سیستم واحد و چند منظوره برای تشخیص روابط خویشاوندی در سال ۲۰۲۰ معرفی کرده‌اند. در این ساختار همه کلاس‌های خویشاوندی به صورت مشترک توسط شبکه عصبی Siamese آموزش داده می‌شوند. سپس با استفاده از چند زیرشبکه، هر یک از روابط خویشاوندی طبقه‌بندی می‌شوند. در سال ۲۰۲۰، Chergui [۲۶] و همکارانش از شبکه VGG-Face برای استخراج ویژگی‌های عمیق استفاده کرده‌اند. همچنین از امتیاز فیشر برای انتخاب بهترین ویژگی‌ها استفاده شده است. در نهایت طبقه‌بندی‌کننده svm رابطه خویشاوندی را تأیید یا رد می‌کند. Wang [۲۷] و همکارش در سال ۲۰۲۰ به وسیله شبکه یادگیری عمیق تقویتی و نمونه‌گیری متمایزکننده، موثرترین نمونه‌های منفی (بدون رابطه خویشاوندی) را تولید می‌کنند. استفاده از این نمونه‌ها در شبکه عصبی، افزایش کارایی سیستم تشخیص خویشاوندی را به همراه دارد.

شبکه‌های عصبی عمیق توانسته‌اند در کاربردهای مختلف به نتایج خوبی دست یابند. با این وجود استفاده از این شبکه‌ها می‌تواند با چالش‌هایی مانند نیاز آن‌ها به تعداد زیاد از داده‌ها برای آموزش شبکه که تهیه و برچسب‌گذاری آن‌ها بسیار هزینه‌بر می‌باشد همراه باشد [۱۵]. همچنین هزینه‌های زیاد جهت پیاده‌سازی و نیاز آن‌ها به سخت‌افزار GPU یکی دیگر از چالش‌های این روش‌ها به‌شمار می‌رود. لذا در بسیاری از موارد الگوریتم‌های کلاسیک می‌توانند با هزینه کمتری به کارایی مناسب دست یابند.

همان‌گونه که در پژوهش‌های پیشین اشاره شد، نحوه استخراج ویژگی از تصاویر یکی از چالش‌های اصلی در توسعه یک سیستم کارا برای تشخیص خویشاوندی است. در این تحقیق قصد داریم تا علاوه بر بررسی تاثیر ویژگی‌های مختلف و ترکیب آن‌ها، میزان بهبود دقت با بکارگیری طبقه‌بندی‌کننده‌های مختلف را بررسی کنیم. در این راستا دو رویکرد پیشنهادی جهت تشخیص خویشاوندی مطرح شده است. در رویکرد اول با بررسی ویژگی‌های مختلف و ساخت بردار ویژگی جدید با ادغام آن‌ها، کارایی ویژگی‌ها در کنار طبقه‌بندی‌کننده‌های مختلف بررسی شده است. در این رویکرد مناسب‌ترین ترکیب ویژگی و همچنین

تست، در فضای آموزش داده‌شده NRML محاسبه می‌گردد. Qin [۱۹] و همکارانش در سال ۲۰۲۰ متریک یادگیری جدیدی جهت تشخیص رابطه خویشاوندی مطرح کرده‌اند. در این روش با توجه به این که تغییرات محیطی و تفاوت‌های ژنتیکی در تشخیص خویشاوندی اثرگذار است، برای تصاویر خویشاوندی توزیع ترکیبی استفاده شده است. بنابراین با آموزش ترکیب غیرخطی تعدادی متریک فاصله Mahalanobis، از طبقه‌بندی‌کننده SVM برای ارزیابی نهایی استفاده می‌شود. در سال ۲۰۲۰ Sellam [۲۰] و همکارش توصیفگری بر اساس حداقل فاصله در همسایگی ارائه کرده‌اند. توصیفگر پیشنهادی در تصویر فرزند به دنبال شبیه‌ترین پیکسل به پیکسل فعلی در تصویر والد می‌گردد. این جستجو در یک همسایگی پیکسل فرزند محدود و برای بررسی میزان شباهت از فاصله اقلیدسی استفاده شده است.

در سال‌های اخیر با فراهم شدن منابع سخت‌افزاری با توان بالا، از شبکه‌های عصبی عمیق برای تشخیص خویشاوندی نیز استفاده شده است. در سال ۲۰۱۸ Lopez [۱۱] و همکارانش با استخراج ویژگی‌های عمیق از تصاویر در کنار ویژگی‌های بافت الگوهای دودویی محلی، روشی را جهت تشخیص خویشاوندی ارائه دادند. ویژگی‌های عمیق توسط شبکه عصبی حلقوی با ورودی فریم‌های ویدویی افراد استخراج شده است. Laiadi و همکارانش [۱] در سال ۲۰۱۹ روشی را جهت تشخیص خویشاوندی بین پدربزرگ / مادربزرگ و نوه ارائه کرده است. در این پژوهش ویژگی‌های عمیق از طریق شبکه عصبی VGG-Face استخراج شده است. در سال ۲۰۱۹ Nandy [۲۱] و همکارانش معماری شبکه عصبی تکاملی را جهت تشخیص خویشاوندی بین دو فرد با استخراج ویژگی‌های عمیق ارائه کردند. در این روش با هدف تقویت کیفیت ویژگی‌های استخراج شده از پیکسل‌ها و همچنین کانال‌های رنگی قرمز، سبز و آبی از مدل SqueezeNet استفاده شده است. ابتدا دو تصویر ورودی به دو مدل SqueezeNet داده می‌شود و دو بردار ویژگی تولید می‌گردد. با اعمال معیارهای شباهت کسینوسی و فاصله اقلیدسی، دو بردار ویژگی با یکدیگر ادغام می‌گردد. در انتها به وسیله تابع فعال‌ساز گوسی با تولید خروجی بین ۰ و ۱، خویشاوندی یا عدم خویشاوندی تشخیص داده می‌شود. روش مطرح شده توسط Dornaika [۲۲]، ترکیب ویژگی‌های عمیق و ادغام طبقه‌بندی‌کننده‌ها خویشاوندی را بررسی می‌کند. در این روش ابتدا ویژگی‌های عمیق تصویر والد و فرزند توسط دو مفسر، VGG-Face و VGG-F استخراج می‌گردد. چهار بردار ویژگی تولید شده توسط امتیاز فیشر مقدردهی شده و ویژگی‌ها با بیشترین ارتباط غربال می‌شوند. چهار بردار نهایی تولید شده به دو طبقه‌بند svm داده و نتایج آن‌ها با یکدیگر ادغام می‌شود. Zhang [۲۳] و همکارانش در سال ۲۰۲۰ از ساختار شبکه Residual با دو جریان، برای شناسایی رابطه خویشاوندی استفاده کرده‌اند. در این معماری تابع خصمانه اختلاف بین نمونه‌های بدون رابطه

۲-۱ ویژگی‌های بافت

آنالیز ویژگی‌های بافت تصاویر در گذشته به صورت گسترده‌ای در زمینه‌های تشخیص، شناسایی و تحلیل تصاویر چهره انسان استفاده شده است. در ادامه توضیح مختصری از برخی ویژگی‌های بافت استفاده شده در این پژوهش شامل ویژگی‌های HOG، LPQ، WLD، BSIF، TPLBP، PML، RCM و GRCM آمده است.

Histogram of Gradients (HOG)

این توصیفگر تعداد رخداد گرادیان جهت‌دار تصویر در بلوک‌های محلی تصویر یا ناحیه مورد نظر را شمرده و هیستوگرام آن را برمی‌گرداند [۲۸]. Jiwen Lu [۱۸] مفسری بر پایه HOG معرفی کرده است. ابتدا تصویر به 16×16 بلوک بدون همپوشانی با اندازه 4×4 و همچنین 8×8 بلوک با اندازه 8×8 تقسیم شده، سپس ویژگی HOG با ۹ بُعد از هر بلوک استخراج می‌گردد.

Local Phase Quantization (LPQ)

کمیت فاز محلی، توصیفگر قدرتمند تصاویر تار است. این توصیفگر بر اساس عدم حساسیت اجزاء فاز کم فرکانس به تاری متقارن مرکزی است. همچنین LPQ در مقابل تغییرات میانگین سطح روشنایی و تغییرات کنتراست روشنایی ثابت است [۲۹].

Weber local Descriptor (WLD)

توصیفگر محلی وبر، توصیفگر متراکم محلی تصویر است که بر اساس قانون وبر عمل می‌کند. این توصیفگر کارایی خوبی در طبقه‌بندی تصاویر بافت و شناسایی تصاویر چهره دارد. WLD به‌ازای هر پیکسل دو مقدار را محاسبه می‌کند: تحریک دیفرانسیل (نرخ بین مجموع شدت پیکسل‌های همسایه و همان پیکسل) و جهت گرادیان پیکسل. بردار ویژگی WLD، تصویر ورودی را به مقیاس‌های مختلف تبدیل و به‌ازای هر پیکسل آن، دو مشخصه تحریک دیفرانسیل و جهت گرادیان پیکسل را محاسبه می‌کند. در نهایت بردار ویژگی به صورت هیستوگرام به دست می‌آید [۳۰].

Binarized Statistical Image Features (BSIF)

بردار ویژگی دودویی آماری، توصیفگر بافت دودویی برگرفته از توصیفگرهای LBP و LPQ است. این روش‌ها تصویر را با فیلترهای خطی کانوالو (convolve) و جواب فیلتر را به صورت دودویی برمی‌گردانند تا همسایه هر پیکسل به صورت دودویی توصیف شود. در روش BSIF نیز رشته کد دودویی برای هر پیکسل تصویر تولید می‌شود. مقدار هر کد با دودویی کردن پاسخ فیلتر خطی با آستانه صفر به دست می‌آید [۳۱].

Three-Patch LBP Codes (TPLBP)

کد TPLBP ویژگی را بر اساس مقادیر سه قطعه (PATH) محاسبه و کد انتسابی به هر پیکسل تصویر را در قالب یک بیت محاسبه می‌کند. در این توصیفگر به‌ازای هر پیکسل تصویر یک قطعه با اندازه $b \times b$ و S قطعه اضافی که به صورت یکنواخت در دایره‌ای با شعاع r در اطراف آن پیکسل توزیع شده‌اند در نظر گرفته می‌شود. به تعداد α قطعه در اطراف دایره در نظر گرفته شده و

مناسب‌ترین طبقه‌بندی‌کننده برای تشخیص خوشاوندی مشخص می‌گردد. در رویکرد اول مشابه اکثر پژوهش‌های پیشین، از متریک تفاضل دو نمونه برای استخراج ویژگی خوشاوندی استفاده شده است. همان‌گونه که پیش‌تر اشاره شد، الگوریتم یادگیری متریک دفع همسایه (NRML)، امکان تخمین متریک مناسب برای مسئله را می‌تواند فراهم کند. این روش سعی می‌کند تا متریک مناسب را بر اساس فاصله متمایزکننده بین نمونه‌های داخل کلاس (دارای رابطه خوشاوندی) و نمونه‌های بین کلاسی (بدون رابطه خوشاوندی) آموزش دهد. در رویکرد پیشنهادی دوم، از روش یادگیری متریک NRML به همراه ترکیب ویژگی‌های مختلف، جهت رد یا تایید خوشاوندی استفاده شده و کارایی هر یک از آن‌ها تحلیل و ارزیابی شده است. در روش متریک NRML از یک حد آستانه جهت طبقه‌بندی نهایی نمونه‌ها استفاده می‌شود. همچنین در رویکرد دوم ترکیب ویژگی‌های مناسب به دست آمده از رویکرد اول بررسی شده است. آن دسته از ویژگی‌هایی که کارایی مناسب نداشتند، حذف شده و ویژگی‌های مناسب‌تر در نظر گرفته شده است. تحلیل و ارزیابی این رویکرد نیز بر روی دادگان مختلف در حالت‌های مختلف ارزیابی شده است. در آزمایش‌های انجام شده کارایی هر دو رویکرد پیشنهادی در حالت‌های مختلف نیز با یکدیگر مقایسه و ارزیابی شده‌اند. به‌طور کلی می‌توان سهم علمی مقاله را در موارد زیر خلاصه کرد:

- ارزیابی ویژگی‌های رنگ و بافت، همچنین بررسی کارایی چندین طبقه‌بندی‌کننده مختلف
- بررسی عملکرد ویژگی‌ها در کانال‌های رنگی HSV، RGB، سطح خاکستری و به صورت بلوکی
- ترکیب ویژگی‌های مختلف رنگ و بافت، بررسی کارایی آن‌ها و معرفی ویژگی‌های ترکیبی مؤثر
- استفاده از متریک یادگیری NRML به منظور تولید بردار ویژگی متمایزکننده

در ادامه مقاله، ویژگی‌های بافت و یادگیری متریک در بخش ۲ معرفی شده است. توضیحات روش‌های پیشنهادی در بخش ۳ آورده شده است. پس از آن نتایج و ارزیابی روش‌های پیشنهادی در بخش ۴ و در نهایت نتیجه‌گیری در بخش ۵ بررسی شده است.

۲ پس زمینه

در پژوهش‌های انجام شده در زمینه تشخیص خوشاوندی در سال‌های اخیر، ویژگی‌هایی مانند ویژگی‌های رنگ و بافت، استفاده شده است. همچنین نتایج به دست آمده نشان می‌دهند که انتخاب ویژگی‌ها و نحوه ترکیب آن‌ها در دقت تشخیص بسیار اهمیت دارد. در این بخش توضیح مختصری از ویژگی‌های بافت، توصیفگرهای ویژگی و روش‌های یادگیری متریک استفاده شده ارائه می‌گردد.

(PML)، در هر سطح هرم، از هر بلوک ویژگی RCM را استخراج می‌کند. بردار نگاشت این تحقیق به صورت رابطه ۲ است.

$$\Phi(I, x, y) = \begin{bmatrix} x & y & R(x, y) & G(x, y) & B(x, y) \\ H(x, y) & S(x, y) & V(x, y) & & \\ |I_x| & |I_y| & |I_{xy}| & |I_{yx}| & |I_{xx}| & |I_{yy}| \\ LBP_{u2} & LBP_{ri} & LBP_{riu2} & & \\ QLRBP_{p1} & QLRBP_{p2} & QLRBP_{p3} & & \end{bmatrix} \quad (2)$$

این تابع نگاشت شامل اطلاعات مکان پیکسل‌ها (x, y) ، مقدار عددی پیکسل در کانال قرمز $R(x, y)$ ، سبز $G(x, y)$ و آبی $B(x, y)$ ، مقدار عددی پیکسل در کانال $H(x, y)$ ، $S(x, y)$ و $V(x, y)$ ، نرم مشتق اول و مشتق دوم، بردار ویژگی LBP در سه حالت یکنواخت، ثابت به دوران و هر دو و توصیفگر ویژگی الگوی دودویی رتبه‌بندی محلی کوآترنونیک (QLRBP) می‌باشد.

Gabor-wavelet-based Region Covariance Matrix

در سال ۲۰۰۸ Pang [۳۴] برای افزایش کارایی توصیفگر RCM، از ویژگی‌های گبور به همراه مکان پیکسل‌ها (x, y) استفاده کرده است. ویژگی‌های گبور با تبدیل دو بعدی موجک گبور^۲ از شدت تصویر به دست می‌آیند. در این تبدیل از کرنل‌های دو بعدی گبور استفاده می‌شود. این کرنل‌ها شامل هشت جهت‌گیری و پنج مقیاس مختلف می‌باشند. ویژگی‌های گبور با کانولوشن کرنل‌های گبور و تصویر I استخراج می‌گردد. بردار نگاشت، با ترکیب مکان پیکسل‌ها، شدت آنها و ویژگی‌های گبور ساخته می‌شود.

Quaternionic Local Ranking Binary Pattern (QLRBP)

توصیفگر ویژگی الگوی دودویی رتبه‌بندی محلی کوآترنونیک (QLRBP) بر اساس نمایش کوآترنونیک (QR)^۳ تصاویر رنگی و رمزگذاری همزمان کانال‌های رنگی تصاویر در بُعد چهارم تعریف شده است [۳۵]. نسل چهار بعدی اعداد مختلط، یک کوآترن است و به صورت $q = a + ib + jc + kd$ تعریف می‌شود. در این رابطه a, b, c, d اعداد حقیقی و i, j, k عملگرهای مختلط هستند. برای نمایش کوآترنونیک یک پیکسل از قسمت موهومی کوآترن به صورت $q = ir + jg + kb$ استفاده می‌شود. در رتبه‌بندی QR دو پیکسل رنگی، کوآترن مرجع^۴ مطابق رابطه ۳ تعریف می‌شود. در این رابطه $\epsilon_{mn} \in [0.0, 1]$ ، اعداد تصادفی هستند.

$$\begin{pmatrix} i_1 \\ j_1 \\ k_1 \end{pmatrix} = \begin{pmatrix} 1 - \epsilon_{11} & \epsilon_{12} & \epsilon_{13} \\ \epsilon_{21} & 1 - \epsilon_{22} & \epsilon_{23} \\ \epsilon_{31} & \epsilon_{32} & 1 - \epsilon_{33} \end{pmatrix} \begin{pmatrix} i \\ j \\ k \end{pmatrix} \quad (3)$$

جهت استخراج ویژگی QLRBP از تصویر رنگی I ، ابتدا مجموعه سه‌تایی کوآترن مرجع $\{p_1, p_2, p_3\}$ به ازای هر یک از کانال رنگی قرمز، سبز و آبی مطابق رابطه ۳ محاسبه می‌گردد. سپس تمام پیکسل‌های تصویر توسط رابطه ۴ به صورت کوآترنونیک

مقادیر آنها با مقادیر قطعه مرکزی مقایسه می‌شود. مقدار بیت بر این اساس که کدام دو قطعه به قطعه مرکزی شبیه‌تر هستند، به دست می‌آید. بدین صورت به ازای هر پیکسل، S بیت ساخته می‌شود. در نهایت توصیفگر تصویر با تقسیم تصویر کد شده به بلوک‌های هم‌اندازه بدون همپوشانی، محاسبه هیستوگرام نرمال شده هر بلوک و ادغام آنها با یکدیگر به دست می‌آید [۳۲].

Pyramid Multi-Level (PML) face representation

در نمایش تصاویر چهره به روش هرمی چند سطحی (PML)، تصویر مربوط به هر سطح هرم در مقیاس‌های مختلف نمایش داده می‌شود. هر یک از این تصاویر به صورت نمایش چند بلوکی^۱، پردازش می‌شود و بردار ویژگی مربوطه از آن استخراج می‌گردد. اگر I تصویر با اندازه $N \times N$ باشد، و برای هرم l سطح و اندازه $(b \times b)$ برای هر بلوک در نظر گرفته شود، نمایش هرمی تصویر به صورت $P = \{L_1, \dots, L_l\}$ خواهد بود. با مقیاس کل تصویر به اندازه $(b \times b)$ ، تصویر در سطح یک هرم ساخته می‌شود. در بقیه سطوح، تصویر به صورت بلوک‌های چندتایی با اندازه $\frac{N}{l} \times \frac{N}{l}$ نمایش داده می‌شود. در نهایت نمایش هرمی تصویر I در l سطح، به صورت دنباله‌ای از L_1, \dots, L_l می‌باشد. در هر سطح L_i, i به صورت $L_i = \{B_{i,1}, \dots, B_{i,n_i}\}$ تعریف می‌شود [۲۸].

Region Covariance Matrix (RCM)

توصیفگر ویژگی RCM در سال ۲۰۰۶ توسط Tuzel [۳۳] معرفی شده است. RCM ماتریس کوواریانس چندین بردار آماری محاسبه شده از نواحی تصویر می‌باشد. این توصیفگر، به صورت ذاتی روشی جهت ترکیب چندین ویژگی از یک ناحیه تصویر در قالب ماتریس است. اگر I تصویر با اندازه $N \times M$ باشد، تابع Φ بردار ویژگی Z_i را از پیکسل (x, y) استخراج می‌کند. تمام پیکسل‌ها (x, y) در ناحیه R واقع شده‌اند.

برای ناحیه R از تصویر که شامل n پیکسل است، بردار $\{Z_i\}_{i=1..n}$ نقاط ویژگی d بعدی می‌باشد. این ناحیه توسط ماتریس کوواریانس $d \times d$ از نقاط ویژگی، نشان داده می‌شود. در مرجع [۳۳]، مکان پیکسل‌ها (x, y) ، مقدار عددی پیکسل‌ها در کانال RGB و مشتق مرتبه اول و دوم نسبت به x و y به عنوان توابع نگاشت در نظر گرفته شده است. این بردار ویژگی در رابطه ۱ نشان داده شده است.

$$\Phi(I, x, y) = \begin{bmatrix} x & y & R(x, y) & G(x, y) & B(x, y) & |I_x| & |I_y| \\ & & & |I_{xx}| & |I_{yy}| & & \end{bmatrix} \quad (1)$$

PML_COV

در سال ۲۰۱۸ Moujahid [۲۸] ویژگی PML_COV را معرفی کرده است. این مفسر با استفاده از توصیفگر هرمی چند سطحی

² 2-D Gabor wavelet transformation

³ Quaternionic representation

⁴ Reference quaternion

¹ Multi-block representation

پس از حل مساله بهینه‌سازی NRML و محاسبه مساله مقدار خاص^۳، ماتریس W محاسبه می‌شود [۳۶]. سپس مقدار نزدیک‌ترین همسایه برای x_i و y_i مطابق رابطه ۵ مجدد محاسبه شده و ماتریس W به‌روزرسانی می‌گردد. Jiwen Lu سپس از متریک NRML برای مساله تشخیص خویشاوندی استفاده کرده‌است. برای این منظور میزان شباهت کسینوسی ویژگی‌های والد و فرزند با حد آستانه مقایسه می‌شود [۳۶].

۳ الگوریتم پیشنهادی

دو روش پیشنهادی بررسی شده در این پژوهش عبارتند از:

رویکرد اول: ادغام ویژگی و طبقه‌بندی

رویکرد دوم: متریک یادگیری

رویکرد اول با هدف بررسی ویژگی‌های مختلف در حوزه تشخیص چهره و همچنین تاثیر ادغام ویژگی‌ها^۴ برای دست یافتن به کارایی مناسب در تشخیص خویشاوندی استفاده شده‌است. همچنین عملکرد طبقه‌بندی‌کننده‌های مختلف برای انتخاب مناسب‌ترین طبقه‌بندی‌کننده بررسی شده‌است. در رویکرد اول مشابه اکثر پژوهش‌های پیشین، از متریک تفاضل بردار ویژگی والد و فرزند جهت شناسایی شباهت بین نمونه‌ها استفاده شده‌است. عملکرد روش‌های یادگیری ماشین برای اغلب طبقه‌بندی‌ها مثل SVM یا KNN به متریک انتخابی وابسته است. منطبق نبودن متریک انتخابی به داده‌ها می‌تواند در عملکرد نهایی سیستم اثرگذار باشد. در سال‌های اخیر جهت بهبود مدل‌های طبقه‌بندی‌کننده، روش‌های یادگیری متریک به‌منظور سازگار کردن متریک با داده‌ها مورد توجه قرار گرفته‌اند. در رویکرد پیشنهادی دوم از روش یادگیری متریک NRML، به‌همراه ادغام ویژگی‌های رنگ و بافت، برای رد یا تایید خویشاوندی بهره گرفته شده‌است. در ادامه این بخش توضیح تکمیلی هر کدام از رویکردهای آورده شده است.

۳-۱ ادغام ویژگی و طبقه‌بندی

پیش‌تر اشاره شد که یکی از ایده‌های مطرح شده در این تحقیق ترکیب ویژگی‌ها با هدف ساخت بردار ویژگی متمایزکننده و بررسی کارایی بردار به‌دست آمده توسط چند طبقه‌بندی‌کننده مختلف است. شکل ۱ روند کلی این روش پیشنهادی را نشان می‌دهد.

به‌ازای تصویر والد و فرزند مجموعه ویژگی‌های $[f_1, f_2, f_3, \dots, f_n]$ استخراج شده و بردار ویژگی والد و فرزند به‌ترتیب با نام‌های F_C و F_P تشکیل شده‌است. این بردارها به روش $\min \max$ مطابق رابطه ۶ نرمال شده‌اند:

$$F = \frac{F - \min(F)}{\max(F) - \min(F)} \quad (6)$$

نمایش داده می‌شوند. تصویر به‌دست آمده Q_I نامیده شده‌است. در این رابطه μ ، کوآترن خالص واحد^۱ و θ فاز کوآترن می‌باشد.

$$\hat{q} = |\hat{q}|e^{i\theta} = |\hat{q}|(\cos\theta + i\sin\theta) \quad (4)$$

به‌ازای هر یک از کوآترن‌های مرجع، تابع ترجمه کلیفورد از کوآترن (CTQ)^۲ بر روی المان‌های تصویر Q_I اعمال شده و فاز CTQ محاسبه می‌شود. در ادامه فاز CTQ، به بلوک‌های 3×3 (S_m) با پیکسل مرکزی q_m تقسیم می‌شوند. سپس تفاضل فاز پیکسل‌های همسایه و پیکسل مرکزی محاسبه می‌شود. اگر مقدار تفاضل مساوی یا بزرگتر از ۰ باشد، کد ۱ و اگر کوچکتر از ۰ باشد، از کد ۰ در تصویر کدگذاری شده QLRBP استفاده می‌شود. تصویر QLRBP به بلوک‌های با هم‌پوشانی تقسیم می‌شود. برای هر بلوک، هیوستگرام نرمال‌شده محاسبه و بردارهای به‌دست آمده ترکیب می‌شوند. بردار ویژگی نهایی با ادغام بردار ویژگی‌های به‌دست آمده برای هر کوآترن مرجع، به‌دست می‌آید.

۲-۲ یادگیری متریک

اغلب روش‌های یادگیری ماشین مانند SVM و K-means از متریکی جهت شناختن شباهت (فاصله) بین نمونه‌ها استفاده می‌کنند. لذا عملکرد آن‌ها به متریک انتخابی وابسته است. در صورت نداشتن اطلاعات پیشین از داده‌ها، تنها متریک‌های عمومی مانند فاصله اقلیدسی و شباهت کسینوسی قابل استفاده خواهند بود. از آنجایی که این متریک‌ها منطبق بر رفتار داده‌ها نیستند، بر کارایی الگوریتم یادگیری اثر می‌گذارند. یکی از راه‌حل‌های رفع این مشکل سازگار کردن متریک با داده‌ها می‌باشد. در ادامه یادگیری متریک دفع همسایه (NRML) آمده است.

Neighborhood Repulsed Metric Learning (NRML)

در سال ۲۰۱۲ Jiwen Lu [۳۶] و همکارانش یادگیری متریک دفع همسایه را برای تشخیص خویشاوندی معرفی کردند. نمونه‌های بدون رابطه خویشاوندی که شباهت بیشتری دارند، در همسایگی خویشاوندی قرار گرفته و به احتمال زیاد اشتباه طبقه‌بندی می‌شوند. یادگیری متریک NRML سعی دارد نمونه‌ها با رابطه خویشاوندی، تا حد امکان به هم نزدیک و نمونه‌ها بدون رابطه خویشاوندی که در همسایگی خویشاوندی قرار می‌گیرند تا حد امکان دفع و از همسایگی سایر نمونه‌ها دور شوند. به عبارت دیگر در مجموعه آموزشی $S = \{(x_i, y_i) | i = 1, 2, \dots, N\}$ که x_i والد، و y_i فرزند را نشان می‌دهد، NRML متریک فاصله d را پیدا می‌کند که در آن فاصله بین x_i و $y_j (i = j)$ کم و فاصله بین x_i و $y_j (i \neq j)$ زیاد باشد. رابطه ۵ نحوه محاسبه فاصله را نشان می‌دهد.

$$d(x_i, y_j) = \sqrt{(x_i - y_j)^T W W^T (x_i - y_j)} \quad (5)$$

³ eigenvalue

⁴ Feature fusion

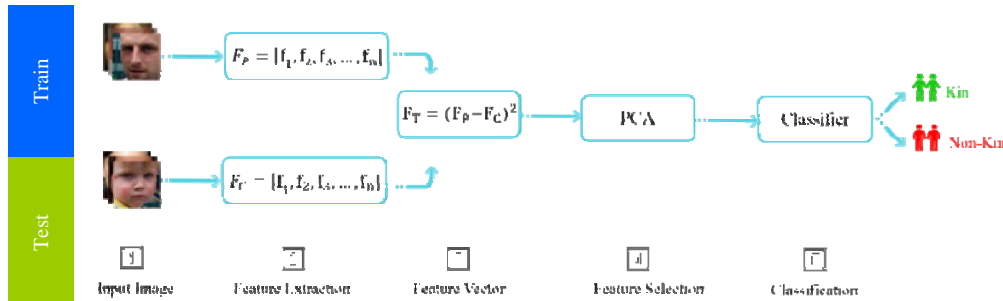
¹ unit pure quaternion

² Clifford translation of quaternion (CTQ)

$$F_{TR} = W^T F_T \quad (۸)$$

ماتریس تبدیل W در روش استخراج ویژگی PCA با ماکزیمم کردن تابع هدف در رابطه ۹ به دست می آید:

$$W = \operatorname{argmax} [\operatorname{var}(F_{TR}) - \alpha(W^T W - 1)] \quad (۹)$$



شکل ۱ روند کلی روش پیشنهادی

۴ نتایج و ارزیابی رویکردهای پیشنهادی

در این بخش، رویکردهای پیشنهاد شده جهت تشخیص خویشاوندی ارزیابی شده اند. ابتدا مجموعه داده های محک استفاده شده در ارزیابی ها معرفی شده و سپس معیارها و نحوه ارزیابی روش ها توضیح داده شده است. در بخش بعد، بردارهای ویژگی استفاده شده، نحوه ترکیب آن ها و پارامترهای به کار گرفته شده در آن ها آورده شده است. در ادامه نتایج به دست آمده رویکردها، تحلیل و ارزیابی شده و با روش های پیشین مقایسه شده است.

۴-۱ مجموعه داده های محک

جهت سنجیدن کارایی رویکردهای پیشنهادی از دو پایگاه داده معروف خویشاوندی KinFaceW-I و KinFaceW-II استفاده شده است. این دو پایگاه داده در سال ۲۰۱۲ توسط Lu et al. [۳۶] معرفی شده اند. هر دو پایگاه داده تصاویر خویشاوندی چهار رابطه والد-فرزند: پدر-پسر (F_S)، پدر-دختر (F_D)، مادر-پسر (M_S) و مادر-دختر (M_D) را شامل می شوند. تصاویر چهره افراد با سن، قومیت مختلف و در محیط های کنترل نشده فراهم شده است. همچنین این تصاویر محدودیتی در نحوه جاگیری افراد ندارند. KinFaceW-I به ترتیب ۱۵۶، ۱۳۴، ۱۱۶ و ۱۲۷ جفت تصویر برای هر رابطه والد-فرزند وجود دارد. در پایگاه داده KinFaceW-II هر رابطه خویشاوندی ۲۵۰ جفت تصویر را شامل می شود. در تصاویر هر دو پایگاه داده، تصاویر چهره از پس زمینه برش خورده و اندازه همه تصاویر ۶۴*۶۴ است.

پس از آن بر اساس مربع اختلاف بردار ویژگی ها، بردار F_T به صورت رابطه ۷ تشکیل می شود.

$$F_T = (F_P - F_C)^2 \quad (۷)$$

با ادغام دو بردار ویژگی در یک بردار، تجزیه و تحلیل مؤلفه اصلی یا PCA با به دست آوردن ماتریس تبدیل W جهت کاهش ابعاد ویژگی مطابق رابطه ۸ استفاده شده است.

در نهایت بردار ویژگی نهایی F_{TR} به عنوان ورودی طبقه بندی کننده نهایی قرار گرفته است. در بخش نتایج، آموزش و ارزیابی چندین طبقه بندی کننده مختلف در این رویکرد بررسی و تحلیل شده است.

۳-۲ متریک یادگیری

در رویکرد قبل، مانند اغلب پژوهش ها، از متریک تفاضل بردار ویژگی والد و فرزند استفاده گردید [۱۶]، [۲۸] و [۱۷]. متریک های عمومی اغلب نمی توانند بر رفتار درست داده منطبق شوند و به همین دلیل الگوریتم های یادگیری متریک معرفی شده اند [۳۷]. در رویکرد پیشنهادی دوم اثر ترکیب ویژگی ها و روش یادگیری متریک NRML در بهبود کارایی الگوریتم یادگیری بررسی خواهد شد. شکل ۲ روند کلی این روش پیشنهادی را نشان می دهد. در مرحله آموزش، مطابق شکل ۲-الف به ازای هر تصویر آموزشی والد و فرزند مجموعه ویژگی های $[f_1, f_2, f_3, \dots, f_n]$ استخراج شده است. متریک فاصله W به روش یادگیری متریک NRML محاسبه می گردد.

در مرحله تست، مطابق شکل ۲-ب، تصاویر والد و فرزند پس از محاسبه بردار ویژگی و اعمال الگوریتم کاهش ابعاد، در متریک فاصله W محاسبه شده در مرحله آموزش، ضرب می شوند تا مجموعه داده در فضای جدید ساخته شود. سپس شباهت کسینوسی هر جفت داده بر اساس رابطه ۱۰ محاسبه می شود:

$$\text{score} = \operatorname{sim}(F'_P, F'_C) = \frac{F'_P \cdot F'_C}{\|F'_P\| \cdot \|F'_C\|} \quad (۱۰)$$

در این رابطه عملگر $\|F'_P\|$ و $\|F'_C\|$ نرم اقلیدسی بردار F'_P و F'_C را نشان می دهد. برای تایید یا رد خویشاوندی، میزان شباهت کسینوسی با یک حد آستانه Th مقایسه می شود.

۴-۲ معیارهای ارزیابی

مطابق پژوهش‌های پیشین، جهت بررسی و مقایسه روش‌های پیشنهادی از معیار صحت^۱ به صورت رابطه ۱۱ استفاده شده است.

$$Accuracy = \frac{P_{Correct}}{P_{Total}} \quad (11)$$

در این رابطه PCorrect و PTotal به ترتیب نشان‌دهنده تعداد نمونه‌های درست طبقه‌بندی شده و کل نمونه‌ها می‌باشد. برای ارزیابی روش‌های پیشنهادی از روش five-fold cross validation استفاده شده است. در این روش در هر تکرار چهار fold آن برای آموزش و یک fold برای تست در نظر گرفته شده است. میانگین نتایج پنج fold به عنوان نتایج نهایی گزارش شده است. در هر fold تعداد جفت تصاویر مثبت (با رابطه خویشاوندی) و جفت تصاویر منفی (بدون رابطه خویشاوندی) برابر می‌باشند. جهت بهینه‌سازی حد آستانه از روش اعتبارسنجی متقابل تو در تو^۲ استفاده شده است. در این روش داده آموزشی به دو مجموعه داده آموزشی و اعتبارسنجی تقسیم می‌شود و بهترین پارامتر حد آستانه بر اساس داده‌های اعتبارسنجی انتخاب می‌شود. سپس دقت (accuracy) داده‌های تست بر اساس این حد آستانه گزارش شده است.

۴-۳ جزئیات استخراج بردارهای ویژگی و ترکیب آن‌ها

بر اساس پژوهش‌های پیشین، انواع ویژگی‌هایی که در تشخیص خویشاوندی کارایی مناسبی داشته‌اند و همچنین ترکیب‌های مختلف آن‌ها بررسی و ارزیابی شده است. ویژگی‌های استفاده شده شامل ویژگی‌های LBP، HOG، LPQ، WLD، BSIF، TPLBP، PML_RCM، PML_GRCM و QLRBP می‌باشند. در خصوص ویژگی BSIF، بردار ویژگی دودویی آماری در سه حالت از تصویر استخراج شده است: در حالت اول، از تصویر اصلی در سه ماهیت تصویر سطح خاکستری، تصویر رنگی RGB و تصویر رنگی RGB به همراه HSV استفاده شده است. این بردارهای ویژگی به ترتیب BSIF(RGB)، BSIF(HSV_RGB) نامگذاری شده‌اند. در حالت دوم ویژگی‌های BSIF از بلوک‌های هم‌اندازه و بدون همپوشانی استخراج شده که به صورت BSIF(HSV) و BL_BSIF(HSV_RGB) نشان داده شده است. در حالت سوم به منظور افزایش قدرت بردار ویژگی نهایی نسبت به پوشاندگی و تغییرات زیاد نور در تصاویر، علاوه بر استخراج ویژگی از کل تصویر، نیمه‌های بالا، پایین، چپ و راست تصویر نیز در نظر گرفته شده‌اند [۳۴]. لذا ویژگی BSIF از پنج ناحیه تصویر در فضای رنگی RGB و HSV استخراج شده است. این بردار ویژگی 5REG_BSIF نامگذاری شده است. در خصوص روش‌های PML_RCM و PML_GRCM، این دو روش با استخراج ویژگی‌های RCM و GRCM مبتنی بر روش

هرمی چند سطحی PML از تصاویر، تعریف شده‌اند. در PML_RCM به جای استفاده از تابع نگاشت رابطه ۲، از تابع نگاشت جدید مطابق رابطه ۱۲ استفاده شده است.

$$\emptyset(I, x, y) \quad (12)$$

$$= \begin{bmatrix} x & y & R(x, y) & G(x, y) & B(x, y) \\ H(x, y) & S(x, y) & V(x, y) \\ |I_x| & |I_y| & |I_{xy}| & |I_{yx}| & |I_{xx}| & |I_{yy}| \\ LBP_{u2} & LBP_{ri} & LBP_{riu2} & I(x, y) & \theta(x, y) \end{bmatrix}$$

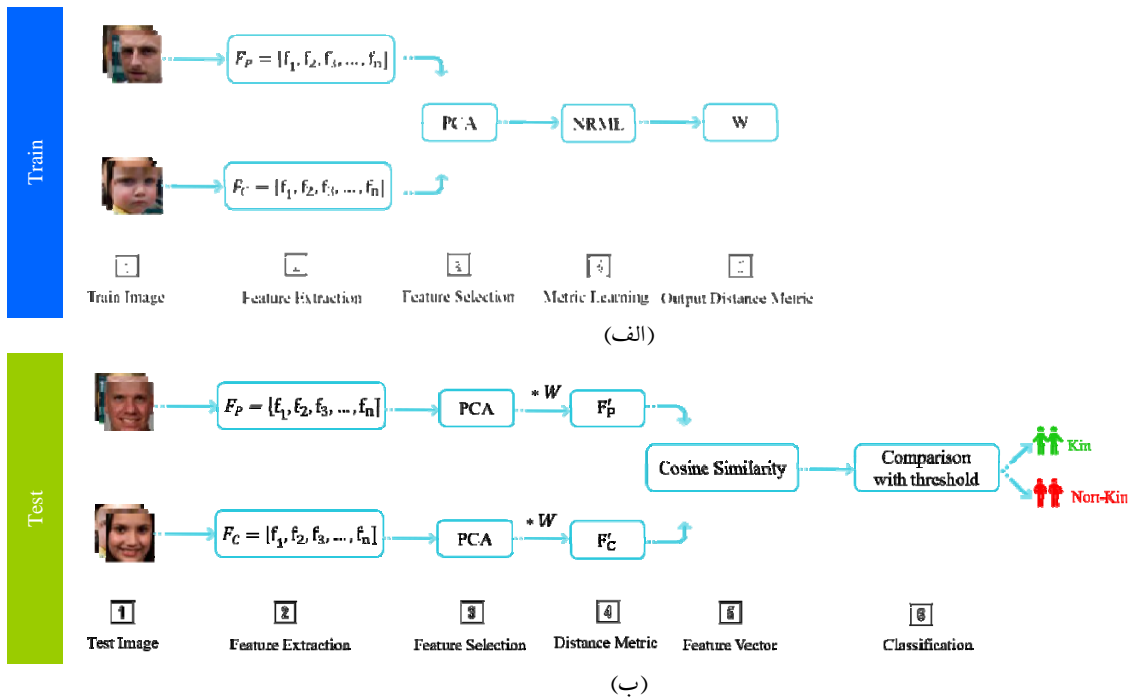
باتوجه به پژوهش‌های دیگر، مشخص گردید که اطلاعات دیگری نیز می‌توانند در تشخیص خویشاوندی موثر واقع شوند. بنابراین در رابطه ۱۲ از روشنایی پیکسل‌ها (x, y) و زاویه لبه به جای توصیفگر ویژگی الگوی دودویی رتبه‌بندی محلی کوآرتونیک در رابطه ۲ استفاده شد.

مفسر جدید PML_GRCM با ترکیب توصیفگر هرمی چند سطحی (PML) و ویژگی GRCM تعریف شده است. به این صورت که در هر سطح هرم، از هر بلوک، ویژگی GRCM استخراج شده است. پارامترهای (l, b) که به ترتیب تعداد سطوح هرم و اندازه بلوک برای توصیفگر PML را نشان می‌دهند، برای رویکردهای PML_RCM1، PML_RCM2 و PML_GRCM به ترتیب برابر (4, 16)، (7, 9) و (4, 16) مقرر شده است. بردار ویژگی 5REG_RCM نیز از کل تصویر و چهار نیمه بالا، پایین، چپ و راست تصویر استخراج شده است. نتایج به دست آمده از این بردار ویژگی نشان می‌دهند استفاده از تابع نگاشت رابطه ۱۳ با عملکرد بهتری همراه است.

$$\emptyset(I, x, y) \quad (13)$$

$$= \begin{bmatrix} x & y & R(x, y) & G(x, y) & B(x, y) \\ H(x, y) & S(x, y) & V(x, y) \\ |I_x| & |I_y| & |I_{xy}| & |I_{yx}| & |I_{xx}| & |I_{yy}| \\ LBP_{u2} & LBP_{ri} & LBP_{riu2} \end{bmatrix}$$

¹ Accuracy
² Nested Cross-Validation



شکل ۲ روند کلی روش پیشنهادی ۲- (الف): آموزش متریک فاصله W، (ب): ارزیابی روش پیشنهادی ۲

۴-۴ ارزیابی و تحلیل نتایج

روش‌های استفاده‌شده در سه بخش بررسی شده‌است. در بخش اول با بررسی ویژگی‌های پایه، بهترین طبقه‌بندی‌کننده انتخاب شده‌است. در ادامه ترکیب ویژگی‌های کلاسیک با بهترین طبقه‌بندی‌کننده مورد ارزیابی قرار می‌گیرد. در بخش دوم نتایج روش یادگیری متریک NRML برای ویژگی‌های بافت و رنگ و ادغام آن‌ها آورده شده‌است. در بخش سوم نیز بهترین روش‌های پیشنهادی با روش‌های پیشین مقایسه شده‌اند. نتایج به‌دست‌آمده در بخش جدول نتایج آورده شده‌است.

۴-۴-۱ ارزیابی طبقه‌بندی‌کننده‌ها و ترکیب ویژگی‌ها

در این بخش با بررسی عملکرد طبقه‌بندی‌کننده‌های SVM، Logistic Regression، Decision Tree و AdaBoost برای ویژگی‌های کلاسیک، بهترین طبقه‌بندی‌کننده انتخاب می‌شود. شکل ۳ نتایج به‌دست‌آمده از طبقه‌بندی‌کننده‌های ذکر شده، برای ویژگی‌های HOG، LPQ، WLD، BSIF و TPLBP را نشان می‌دهد. همچنین جدول (۱)، پارامترهای در نظر گرفته شده برای طبقه‌بندی‌کننده‌های ذکر شده را نشان می‌دهد. پارامترهای طبقه‌بندی‌کننده SVM به صورت c ، Kernel و γ به ترتیب پارامتر منظم‌سازی، نوع کرنل در الگوریتم و ضریب کرنل هستند. در طبقه‌بندی‌کننده Logistic Regression پارامترهای c ، penalty و \max_iter به ترتیب نرم استفاده شده در تابع هزینه، پارامتر منظم‌سازی و حداکثر تعداد تکرار را مشخص می‌کنند. در طبقه‌بندی‌کننده Decision Tree پارامترهای \max_depth و $\text{impurity_criterion}$ حداکثر عمق درخت و تابع ارزیابی

ناخالصی در گره‌های درخت می‌باشند. در طبقه‌بندی‌کننده AdaBoost پارامترهای base_estimator و $n_estimators$ نشان‌دهنده طبقه‌بندی‌کننده پایه استفاده شده و حداکثر برآوردگرهایی که تقویت در آنها خاتمه می‌یابد هستند. نتایج به‌دست آمده برای چهار رابطه خویشاوندی و در دو پایگاه داده KinFaceW-II و KinFaceW-I می‌باشند. در شکل ۳ به ترتیب میانگین صحت طبقه‌بندی‌کننده‌ها به ازای هر ویژگی، میانگین صحت ویژگی‌ها روی همه طبقه‌بندی‌کننده‌ها و میانگین صحت طبقه‌بندی‌کننده‌ها روی همه ویژگی‌ها نشان داده شده‌است. همانطور که نتایج هر دو پایگاه داده نشان می‌دهند، طبقه‌بندی‌کننده Logistic Regression به صورت میانگین عملکرد بهتری و طبقه‌بندی‌کننده SVM عملکرد مناسبی دارد. نتایج ارزیابی به‌دست آمده از ترکیب ویژگی‌های کلاسیک توسط طبقه‌بندی‌کننده Logistic Regression گزارش شده است. نتایج به‌دست آمده از ترکیب ویژگی‌ها برای دو پایگاه داده KinFaceW-II و KinFaceW-I به ترتیب در جدول ۲ و جدول ۳ آورده شده‌است. همانطور که نتایج نشان می‌دهند، بردار ویژگی ساخته‌شده از ادغام ویژگی‌های HOG، LBP، LPQ و WLD برای هر دو پایگاه داده به صورت میانگین بهترین نتیجه را به همراه دارد. بردار ویژگی ترکیبی M11 توانسته است میانگین کلی نتایج را نسبت به سایر ویژگی‌های پایه و ترکیب آنها بهبود دهد.

جدول ۱ پارامترهای تنظیم شده برای طبقه‌بندی‌کننده‌ها

Classifiers	Description
SVM	$[c=1.0, \text{Kernel}='rbf', \gamma=\frac{1}{\text{number of features}}]$
Logistic Reg	$[\text{penalty}=l2, c=10^{-2}, \max_iter=4000]$
Decision Tree	$[\text{impurity_criterion}='gini', \max_depth=5]$
AdaBoost	$[\text{base_estimator}='Decision Tree', n_estimators=50]$

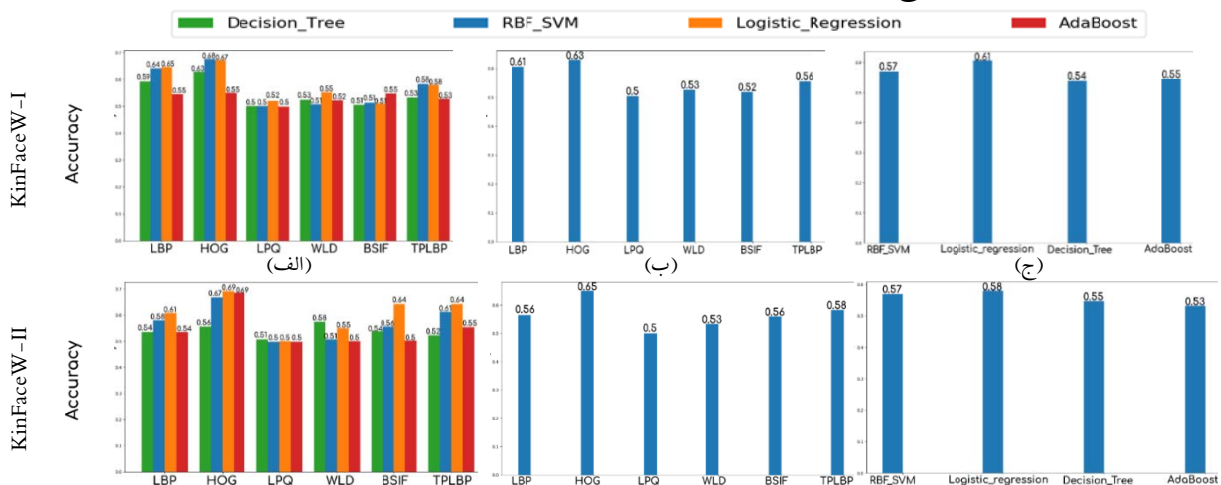
ویژگی‌های HOG و BSIF(HSV_RGB) (روش M28) و همچنین ترکیب ویژگی‌های HOG و LBP (روش M29) به صورت میانگین بهترین نتیجه برای پایگاه داده KinFaceW-I را داشته‌اند. در این روش‌ها ویژگی‌های HOG و LBP به صورت بلوکی در فضای خاکستری استخراج شده‌اند و ویژگی BSIF(HSV_RGB) از کل تصویر از فضای رنگی RGB و HSV استخراج شده است. در پایگاه داده KinFaceW-II جدول ۵، روش M43 با ترکیب ویژگی‌های HOG، PML_RCM1، PML_RCM2، PML_GRCM، 5REG_RCM و ویژگی‌های HOG بهترین نتیجه را داشته است. ویژگی‌های HOG به صورت بلوکی از فضای خاکستری و بقیه ویژگی‌ها به صورت بلوکی از هر سه فضای خاکستری، RGB و HSV استخراج شده‌اند.

۴-۳-۴- مقایسه با روش‌های پیشین

در مقایسه با روش‌های پیشین مشخص گردید برخی از مقالات بیان کرده‌اند که برای تنظیم حد آستانه از روش ارزیابی ارائه شده توسط مقاله [۱۸] استفاده کرده‌اند و سایر مقالات در این خصوص جزئیاتی را ذکر نکرده‌اند. در مرجع [۱۸] از fold کنار گذاشته شده برای داده‌های تست در انتخاب حد آستانه استفاده شده

۴-۴-۲- ارزیابی روش یادگیری NRML و ادغام ویژگی‌ها

پیش‌تر به رویکرد ترکیب ویژگی‌های کلاسیک با روش یادگیری متریک NRML اشاره شد. جهت ارزیابی این روش پیشنهادی ویژگی‌های استفاده شده در روش پیشنهادی اول به همراه ویژگی‌های مناسب‌تر دیگری بررسی شده است. لذا در این بخش با بررسی ویژگی‌های HOG، BSIF(HSV)، BSIF(HSV_RGB)، PML_GRCM، 5REG_BSIF.BL_BSIF(HSV_RGB)، PML_RCM2، PML_RCM1، 5REG_RCM، RGB_QLRBP و HSV_QLRBP و ترکیب آنها، این روش پیشنهادی ارزیابی شده است. نتایج به دست آمده برای هر ویژگی و مناسب‌ترین ترکیب آنها در جدول‌های ۴ و ۵ برای دو پایگاه داده KinFaceW-I و KinFaceW-II آورده شده است. جدول‌های ۴ و ۵ نشان می‌دهند، ترکیب ویژگی‌هایی که از فضاها رنگی RGB، HSV و خاکستری استخراج شده‌اند غالباً نسبت به ویژگی‌هایی که از یک فضای رنگی استخراج شده‌اند، عملکرد بهتری دارند. همچنین ترکیب ویژگی‌های استخراج شده به صورت بلوکی با ویژگی‌های استخراج شده از کل تصویر نیز توانسته است موثر واقع شود. به صورت خاص نتایج نشان می‌دهند که ترکیب



شکل ۳ ارزیابی طبقه‌بندی کننده‌ها با ویژگی‌های پایه. (الف): میانگین صحت طبقه‌بندی کننده‌ها به ازای هر ویژگی، (ب): میانگین صحت ویژگی‌ها روی همه طبقه‌بندی کننده‌ها و (ج): میانگین صحت طبقه‌بندی کننده‌ها روی همه ویژگی‌ها

و دقت گزارش شده است. این مقاله‌ها در جدول نتایج با علامت * مشخص شده‌اند. لذا جهت مقایسه عادلانه با این روش‌ها، علاوه بر گزارش نتیجه روش‌های پیشنهادی با استفاده از اعتبارسنجی متقابل تو در تو، نتیجه روش‌های پیشنهادی بر اساس رویکرد مرجع [۱۸] نیز در جدول‌های مقایسه اضافه شده است. همچنین برای مقایسه بهتر، علاوه بر گزارش دقت روش‌ها، از نمودار ROC که در برخی از مقالات گزارش شده بود نیز برای مقایسه روش‌های پیشنهادی استفاده شده است. ارزیابی روش‌های پیشنهادی نشان می‌دهد، بهترین نتایج به دست آمده از روش‌های پیشنهادی شامل بردار ویژگی‌های M11، M28، M29 و M43 می‌باشند. مقایسه روش‌های پیشنهادی با روش‌های پیشین در جدول‌های ۶ و ۷ برای دو پایگاه داده KinFaceW-I و KinFaceW-II آورده شده است. نتایج

مشخص شده‌اند. در جدول ۶ نتایج مقایسه روش‌های پیشنهادی با روش‌های کلاسیک برای KinFaceW-I آورده شده است. نتایج نشان می‌دهند که روش‌های پیشنهادی M28 و M29 عملکرد بهتری دارند. مقایسه روش‌های پیشنهادی M28* با روش‌های کلاسیک HOG و LBP در فضای خاکستری و HOG و LBP و BSIF(HSV_RGB) در فضای رنگی RGB و HSV در KinFaceW-I نشان می‌دهد، روش‌های پیشنهادی M28 و M29 نسبت به روش‌های کلاسیک HOG و LBP در فضای خاکستری و HOG و LBP و BSIF(HSV_RGB) در فضای رنگی RGB و HSV در KinFaceW-I عملکرد بهتری دارند. این مسئله را می‌توان ناشی از

نتایج عمیق برای تشخیص خوشخوانندی در تصاویر پایگاه داده KinFaceW-I استفاده کرده‌اند. همان‌طور که نتایج نشان می‌دهد، روش‌های پیشنهادی M28 و M29 می‌توانسته‌اند عملکرد بهتری نسبت به روش [۴۱] داشته باشند. این مسئله را می‌توان ناشی از

بهرتر عمل کرده است. همچنین در پایگاه داده KinFaceW-II، روش پیشنهادی در همه روابط از روش [۱۸] و در سه رابطه F-S، M-D، S و M-S از روش های [۴۹] و [۴۱] بهتر عمل کرده است. برای پایگاه داده های KinFaceW-I و KinFaceW-II، نتایج نشان می دهند که نتایج روابط خویشاوندی F_S و M_D که جنسیت های یکسان دارند از روابط F_D و M_S که جنسیت در آنها متفاوت است بهتر است. در نهایت می توان نتیجه گرفت متریک یادگیری NRML با ترکیب ویژگی های رنگ و بافت نسبت به سایر روش های مبتنی بر متریک های یادگیری و طبقه بندی کننده در رد یا تایید رابطه خویشاوندی عملکرد بهتری دارد. با بررسی نتایج ویژگی ها نیز مشخص گردید، ادغام ویژگی های استخراج شده از فضای رنگی RGB، HSV، و خاکستری و همچنین ویژگی های استخراج شده به صورت بلوکی و هم از کل تصویر، می تواند میانگین نتایج را افزایش دهد.

۵ نتیجه گیری و جمع بندی

در این مقاله یک سیستم کارا برای تشخیص خویشاوندی مبتنی بر یادگیری ماشین بررسی شده است. در این سیستم دو رویکرد ادغام ویژگی های پایه به همراه طبقه بندی کننده های مختلف و ادغام ویژگی های رنگ و بافت با استفاده از روش یادگیری متریک NRML ارائه شده است. نتایج رویکرد اول نشان می دهند استفاده ترکیبی از ویژگی های پایه HOG، LBP، LPQ، WLD و ساخت مدل طبقه بندی کننده Logistic Regression با نتایج خوبی برای هر دو پایگاه داده به همراه بود. در ادامه روش پیشنهادی دوم نشان داد استفاده از متریک NRML به همراه ترکیب ویژگی ها در تشخیص رابطه خویشاوندی از سایر روش های مبتنی بر طبقه بندی کننده و متریک های یادگیری بهتر عمل کرده است. در این پژوهش علاوه بر ویژگی های LBP و HOG ارزیابی شده در روش NRML [۳۶]، ویژگی های دیگری شامل WLD، BSIF، TPLBP، PML_RCM، PML_GRCM و QLRBP نیز بررسی شده اند. همچنین از ترکیب ویژگی ها در سطوح مختلف بلوکی و کل تصویر و در کانال های رنگی RGB، HSV و Gray Scale نیز استفاده و کارایی آن ها ارزیابی شده است. نتایج نشان می دهند، روش NRML با ویژگی های ترکیبی، توانسته است کارایی را بهبود بخشد. مناسب ترین ترکیب ویژگی به ترتیب برای پایگاه داده KinFaceW-I و KinFaceW-II بردارهای ویژگی M28، M29 و M43 بودند. در کارهای آینده در ادامه این پژوهش روش های یادگیری عمیق و ترکیب آن ها با روش های کلاسیک برای تشخیص خویشاوندی بررسی خواهد شد.

کم بودن تعداد نمونه های آموزشی برای آموزش شبکه های پیشنهادی در روش [۴۱] دانست. در مقابل روش [۴۳] با افزایش تعداد داده ها از طریق استخراج ۱۰ تصویر از تصویر اولیه و روش [۲۳] با تولید نمونه های جدید با یادگیری تخصصی توانسته اند به نتایج بهتری دست پیدا کنند. برای مقایسه بهتر در ادامه، نتایج این روش ها بر اساس نمودار ROC نیز مقایسه خواهد شد.

مقایسه نتایج روش های پیشنهادی با روش های پیشین بر روی پایگاه داده KinFaceW-II در جدول ۷ آورده شده است. در اینجا روش پیشنهادی M43 برای این پایگاه داده عملکرد مناسب تری داشته است. در این روش علاوه بر تنظیم معیار یادگیری بر اساس تصاویر والد و فرزند، از ادغام ویژگی ها در جهت تقویت بردار ویژگی نهایی استفاده شده است. برای دو روش [۲۶] و [۴۱] که از یادگیری عمیق جهت تشخیص رابطه خویشاوندی استفاده کرده اند، روش M43 نسبت به [۴۱] به صورت میانگین نتیجه بهتری داشته و نسبت به روش [۲۶]، در روابط M-S و M-D دقت بهتری داشته است. مقایسه روش پیشنهادی M43* با روش [۱۸]* که تنها از ویژگی HOG استفاده کرده است، نشان می دهد که ترکیب ویژگی ها در روش M43* دقت را به صورت میانگین ۸ درصد بهبود داده است. این روش پیشنهادی نسبت به سایر روش های پیشین نیز عملکرد بهتری داشته است. نتایج نشان می دهند که ویژگی های ترکیبی به همراه یادگیری متریک NRML، نتایج بهتری نسبت به روش های [۳۸]، [۴۷] و [۴۹] که از متریک های یادگیری BNRML، NRCML و SSML استفاده کرده اند، داشته است.


روش مرجع [۲۳] بهترین دقت در هر دو پایگاه داده KinFaceW-I و KinFaceW-II را داشته است. این روش از یک شبکه کانولوشن مولد تخصصی عمیق برای تشخیص رابطه خویشاوندی استفاده کرده و توانسته است با بهره گیری از رقابت بین دو جریان شبکه در مدل مولد^۱ و مدل متمایزگر^۲، نتایج بهتری نسبت به روش های پیشنهادی ما کسب کند. در این روش مدل مولد برای تولید نمونه های جدید آموزش و مدل متمایزگر برای تشخیص نمونه های واقعی از نمونه های جعلی تولید شده در رقابت هستند. اگر از نظر هزینه تهیه سخت افزار GPU و هزینه پردازش، محدودیت وجود نداشته باشد، این روش می تواند مفید باشد. در شرایط دیگر روش های پیشنهادی می توانند گزینه مناسبی باشند.

در برخی از مقالات از نمودار ROC که به ازای حد آستانه های مختلف رسم می شود، برای مقایسه بهتر روش ها نیز استفاده شده است. در شکل ۴ نمودار ROC بهترین روش پیشنهادی و روش های مراجع [۱۸]، [۴۱]، [۴۹] و [۲۳] برای دو پایگاه داده KinFaceW-I و KinFaceW-II نشان داده شده است. همانطور که در نمودارها مشخص است، در پایگاه داده KinFaceW-I روش پیشنهادی در همه روابط از روش های [۱۸]، [۴۱] و [۴۹]

¹ Generator Model

² Discriminative Model

ادغام ویژگی‌های رنگ و بافت به منظور تشخیص خوشخواندی از روی تصاویر چهره



شکل ۴: منحنی ROC روش‌های مختلف در پایگاه داده KinFaceW-I و KinFaceW-II

جدول نتایج

جدول ۲: مقایسه ترکیب ویژگی‌های کلاسیک برای پایگاه داده KinFaceW-I

Name	Classifier	Feature	F-D	F-S	M-D	M-S	Mean
M1	Logistic Regression	BSIF+LPQ	51.4	53.5	52.8	49.5	51.8
M2	Logistic Regression	LPQ+WLD	52.9	54.1	54.3	55.1	54.1
M3	Logistic Regression	LBP+LPQ	55.2	67.3	56	50	57.1
M4	Logistic Regression	LBP+BSIF	58.9	66.3	56.2	55.1	59.1
M5	Logistic Regression	LBP+TPLBP	64.5	74.3	63.1	58.1	65
M6	Logistic Regression	HOG+BSIF	61.9	78.8	61.4	63.3	66.3
M7	Logistic Regression	HOG+LBP	63	78.8	63.3	63.3	67.1
M8	Logistic Regression	HOG+LPQ	68.3	76.9	64.5	65.5	68.8
M9	Logistic Regression	HOG+TPLBP	71.2	74.3	66.8	63.6	68.9
M10	Logistic Regression	HOG+LBP+LPQ	71.6	78.5	67.3	63.3	70.2
M11	Logistic Regression	HOG+LBP+LPQ+WLD	72.4	77.5	65.7	65.5	70.3

جدول ۳: مقایسه ترکیب ویژگی‌های کلاسیک برای پایگاه داده KinFaceW-II

Name	Classifier	Feature	F-D	F-S	M-D	M-S	Mean
M2	Logistic Regression	LPQ+WLD	50.4	53.6	58.6	54.4	54.2
M1	Logistic Regression	BSIF+LPQ	54	59	52.2	57.6	55.7
M3	Logistic Regression	LBP+LPQ	57.6	62.2	55.4	57.2	58.1
M4	Logistic Regression	LBP+BSIF	63.4	67	62.6	61.8	63.7
M5	Logistic Regression	LBP+TPLBP	63.8	67.6	61.4	63.2	64
M8	Logistic Regression	HOG+LPQ	65.4	74	65.6	67.4	68.1
M9	Logistic Regression	HOG+TPLBP	68.8	74.6	67	65	68.8
M6	Logistic Regression	HOG+BSIF	66.2	77.2	65.2	69.4	69.5
M10	Logistic Regression	HOG+LBP+LPQ	67	76.8	67.4	69.2	70.1
M7	Logistic Regression	HOG+LBP	69.8	75	69.8	66.6	70.3
M11	Logistic Regression	HOG+LBP+LPQ+WLD	68.8	77.2	67.8	69.4	70.8

جدول ۴ نتایج روش پیشنهادی ۲ برای پایگاه داده KinFaceW-I

Name	Method	Classifier	Feature	F-D	F-S	M-D	M-S	Mean
M12	NRML	-	PML GRCM	60.8	58.6	63.8	58.1	60.3
M13	NRML	-	BSIF (HSV RGB)	58.9	63.1	63.8	57.7	60.9
M14	NRML	-	BL BSIF(HSV RGB)	60.4	64.7	64.9	56.9	61.7
M15	NRML	-	BSIF(HSV)	57.1	65.7	65	64.3	63.1
M16	NRML	-	5REG BSIF	59.9	67.2	66.4	62	63.8
M17	NRML	-	RGB QLRBP	63	67.9	69.1	64.2	66.1
M18	NRML	-	PML RCM1	64.9	68.5	65.9	65.5	66.2
M19	NRML	-	5REG RCM	63	66.3	68.1	68.6	66.5
M20	NRML	-	HSV QLRBP	62.2	72.1	67.6	66.8	67.2
M21	NRML	-	BL BSIF(HSV)	63.8	71.1	68.5	66.3	67.4
M22	NRML	-	PML RCM2	62.7	68.5	72.1	68	67.8
M23	NRML	-	PML GRCM+HSV QLRBP	67.1	72.7	71.9	69.3	70.3
M24	NRML	-	HOG+5REG RCM	69.8	73.3	73.2	68	71.1
M25	NRML	-	HOG+ BL BSIF(HSV)	70.1	80.1	71.6	66.8	72.2
M26	NRML	-	HOG+5REG BSIF	70.1	80.4	73.2	68.1	73
M27	NRML	-	HOG+BSIF(HSV)	71.6	80.1	74	66.7	73.1
M28	NRML	-	HOG+BSIF(HSV RGB)	68.3	80.8	76.8	66.7	73.2
M29	NRML	-	HOG+LBP	70.9	80.7	74	68.9	73.6

جدول ۵ نتایج روش پیشنهادی ۲ برای پایگاه داده KinFaceW-II

Name	Method	Classifier	Feature	F-D	F-S	M-D	M-S	Mean
M12	NRML	-	PML GRCM	62.8	63.8	61.6	61.8	62.5
M14	NRML	-	BL BSIF(HSV RGB)	63	69.4	67.6	71.2	67.8
M16	NRML	-	5REG BSIF	63.6	72.8	69.2	69.8	68.8
M12	NRML	-	BL BSIF(HSV)	64.2	73.6	69	70.4	69.3
M21	NRML	-	BSIF (HSV RGB)	63.8	72	70	71.8	69.4
M15	NRML	-	BSIF(HSV)	65.6	71.6	71.8	72	70.2
M20	NRML	-	HSV QLRBP	66.4	75	68.2	76.2	71.4
M17	NRML	-	RGB QLRBP	67.4	78	70	72.8	72
M22	NRML	-	PML RCM2	69.6	69.6	77.2	74.6	72.7
M19	NRML	-	5REG RCM	67.6	74.6	78	74.6	73.7
M18	NRML	-	PML RCM1	68	77.2	75.8	78.6	74.9
M30	NRML	-	PML RCM1+BSIF(HSV)	68.2	77.4	75.8	78.8	75
M31	NRML	-	PML RCM1+HOG	68	78.6	75	78.8	75.1
M32	NRML	-	BL BSIF(HSV RGB)+5REG RCM	71.2	77	78.6	75	75.4
M33	NRML	-	RGB QLRBP+5REG RCM	71.6	79.6	73	78	75.5
M34	NRML	-	BSIF(HSV RGB)+5REG RCM	70.2	76.8	79.2	77	75.8
M35	NRML	-	HSV QLRBP+5REG RCM	71.2	80.8	74.2	79.8	76.5
M36	NRML	-	PML RCM1+PML RCM2	69.6	76.8	82.6	81.4	77.6
M37	NRML	-	RGB QLRBP+ PML RCM1+PML RCM2	69.6	79.2	81.4	81.6	77.9
M24	NRML	-	HOG+5REG RCM	72	82.8	79.6	78	78.1
M38	NRML	-	5REG RCM+PML RCM1+PML RCM2	69.6	79.4	83.6	81.2	78.4
M39	NRML	-	HOG+ PML RCM1+PML RCM2	71	77.8	82.8	82	78.4
M40	NRML	-	HOG+5REG RCM+BSIF(HSV RGB)	71.4	82.8	80.4	79.8	78.6
M41	NRML	-	HOG+5REG RCM+BL BSIF(HSV RGB)	73.2	82.4	80.2	78.6	78.6
M42	NRML	-	HOG+ PML RCM1+PML RCM2+PML GRCM	71.4	78.6	84.2	82.8	79.2
M43	NRML	-	HOG+ PML RCM1+PML RCM2+PML GRCM+5REG RCM	72.4	78.6	83.4	83.2	79.4

جدول ۶ مقایسه روش‌های پیشنهادی با روش‌های پیشین برای پایگاه داده KinFaceW-I

NAME	year	Method	Classifier	Feature	F-D	F-S	M-D	M-S	Mean
[۲۸]	2018	PML	SVM	COV	50.7	50	50.3	48.2	49.8
[۳۸]	2017	NRCML	-	LE	61.1	66.1	73	66.9	66.3
[۳۶]	2012	MNRML	SVM	LBP + TPLBP + SIFT + LE	66.5	72.5	72.0	66.2	69.9
M11	2021	-	LGR	HOG+LBP+LPQ+WLD	72.4	77.5	65.7	65.5	70.3
[۳۹]*	2016	QMD	-	QMCCBP	68.1	72.2	76	67.8	71
[۴۰]*	2016	Simple scoring	-	-	65.7	69.9	79.6	70.7	71.4
[۱۵]	2018	Shallow	ELM	BSIF	64.2	70.0	77.2	73.0	71.7
[۴۱]	2016	SMCNN	-	-	75	75	72.2	68.7	72.2
[۱۶]	2019	-	SVM	LBP	69.2	78.1	72.2	70.8	72.6
M28	2021	NRML	-	HOG+BSIF(HSV RGB)	68.3	80.8	76.8	66.7	73.1
[۴۲]*	2017	QIWL	-	QIWL	69.7	73.7	78	72.8	73.6
M29	2021	NRML	-	HOG+LBP	70.9	80.7	74	68.9	73.6
[۴۳]	2015	CNN-Basic	-	-	70.8	75.7	79.4	73.4	74.8
[۴۴]	2016	SF-GVF	-	SIFT	74.6	76.3	80	75.5	76.1
M29*	2021	NRML	-	HOG+LBP	74.6	83.6	78.7	71.1	77
[۱۸]*	2015	NRML	-	HOG	83.6	74.6	71.5	79.9	77.4
[۴۳]	2015	CNN-Points	-	-	71.8	76.1	84.1	78	77.5
M28*	2021	NRML	-	HOG+BSIF(HSV RGB)	75	83.3	80.7	71.5	77.6
[۲۳]	2020	E-ADvKin	-	-	77.3	76.6	86.2	78.4	79.6

جدول ۷ مقایسه روش‌های پیشنهادی با روش‌های پیشین برای پایگاه داده KinFaceW-II

NAME	year	Method	Classifier	Feature	F-D	F-S	M-D	M-S	Mean
[۲۸]	2018	PML	SVM	COV	51.4	51.4	50.6	50.8	51
M11	2021	-	LGR	HOG+LBP+LPQ+WLD	68.8	77.2	67.8	69.4	70.8
[۱۸]*	2015	NRML	-	HOG	72	80	70	74	74
[۳۹]*	2016	QMD	-	QMCCBP	71.6	77.2	73.4	79	75.3
[۴۵]*	2016	ESL	-	HOG	73	81.2	73	75.6	75.7
[۴۶]	2016	Multiview SSL	-	HOG, LBP	74	81.8	72.5	75.3	75.9
[۳۶]	2012	MNRML	SVM	LBP + TPLBP + SIFT + LE	74.3	76.9	77.6	77.4	76.5
[۴۲]*	2017	QIWL	-	QIWL	73.6	77.4	76.8	78.4	76.6
[۱۵]	2018	Shallow	ELM	BSIF	73.6	78.6	79.6	81.0	78.2
[۳۸]	2017	NRCML	-	LE	76.1	79.8	80	79.8	78.7
[۴۱]	2016	SMCNN	-	-	79	75	85	78	79.3
M43	2021	NRML	-	HOG+ PML RCM1+PML RCM2+PML GRCM+5REG RCM	72.4	78.6	83.4	83.2	79.4
[۴۰]*	2016	Simple scoring	-	-	73.2	78.2	88.2	87.2	80.1
[۴۷]*	2016	SSML	-	HOG	77	85	78.4	80.4	80.2
[۴۸]*	2017	EHRMFS	-	LBP+LE+SIFT+TPLBP	84.4	80.6	84.4	77.6	80.2
[۴۹]*	2017	BNRML	-	LTP	79	84	80	79.2	80.5
[۲۶]	2020	CNN	SVM	-	80.4	82.1	82	79.8	81.1
M43*	2021	NRML	-	HOG+ PML RCM1+PML RCM2+PML GRCM+5REG RCM	74	81.6	86.6	86	82
[۲۳]	2020	E-ADvKin	-	-	85.2	91.6	92.4	90.2	89.9

مراجع

- [12] J. p. Robinson , M. Shao , Y. Wu, H. Liu, T. Gillis and Y. Fu, "Visual Kinship Recognition of Families in the Wild", IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 40, no. 11, pp. 2624–2637, Nov 2018.
- [13] X. Wu , E. Granger, X. Feng, T. H. Kinnunen and A. Hadid, "Audio-Visual Kinship Verification in the Wild", Computing Research Repository (CoRR), vol. abs/1906.10096, 2019.
- [14] S. Wang , Z. Ding and Y. Fu, "Cross-Generation Kinship Verification with Sparse Discriminative Metric", IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 41, no. 11, pp. 2783–2790, Nov 2019.
- [15] X. Wu, X. Feng, E. Boutellaa and A. Hadid , "Kinship Verification using Color Features and Extreme Learning Machine", in IEEE 3rd International Conference on Signal and Image Processing (ICSIP), 2018.
- [16] T. N. Van and V. T. Hoang, "Kinship Verification based on Local Binary Pattern features coding in different color space", in 26th International Conference on Telecommunications (ICT), Hanoi, Vietnam, 2019.
- [17] O. Laiadi, A. Ouamane, E. Boutellaa, A. Benakcha, A. Taleb-Ahmed and A. Hadid, "Kinship verification from face images in discriminative subspaces of color components", Multimedia Tools and Applications, vol. 78, no. 12, p. 16465–16487, June 2019.
- [18] J. Lu, J. Hu, V. E. Liong, X. Zhou, A. Bottino, . I. U. Islam, i. F. Vieira, X. Qin, X. Tan, S. Chen, S. Mahpod, Y. Keller, L. Zheng, K. Idrissi, C. Garcia, S. Duffner, A. Baskurt, M. Castrillon-Santana and J. Lorenzo-Navarro, "The FG 2015 Kinship Verification in the Wild Evaluation", in 11th IEEE International Conference and Workshops on Automatic Face and Gesture Recognition (FG), Ljubljana, 2015.
- [19] X. Qin, D. Liu, B. Gui and D. Wang, "New metric learning model using statistical inference for kinship verification", Applied Soft Computing, vol. 95, no. 12, pp. 1–10, 2020.
- [20] A. Sellam and H. Azzoune , "Neighborhood min distance descriptor for kinship verification", Multimedia Tools and Applications, vol. 79, p. 20861–20880, 2020.
- [21] A. Nandy and S. S. Mondal, "Kinship Verification using Deep Siamese Convolutional Neural Network", in 14th IEEE International Conference on Automatic Face & Gesture Recognition, Lille, France, 2019.
- [22] F. Dornaika, I. Arganda-Carreras and O. Serradilla, "Transfer learning and feature fusion for kinship verification", Neural Computing and Applications, p. 1–13, 2019.
- [23] L. Zhang, Q. Duan, D. Zhang, W. Jia and X. Wang, "AdvKin: Adversarial Convolutional Network for Kinship Verification", IEEE Transactions on Cybernetics, pp. 1–14, 2020.
- [1] O. Laiadi, A. Ouamane, A. Benakcha, A. Taleb-Ahmed and A. Hadid, "Kinship Verification based Deep and Tensor Features through Extreme Learning Machine", in 14th IEEE International Conference on Automatic Face & Gesture Recognition , Lille, France, 2019.
- [2] A. Geetha, M. Sundaram and B. Vijayakumari, "Gender classification from face images by mixing the classifier outcome of prime, distinct descriptors", Soft Comput, vol. 23, no. 8, p. 2525–2535, April 2019.
- [3] A. Patil, K. R and S. S. Gornale, "Analysis of Multi-modal Biometrics System for Gender Classification Using Face, Iris and Fingerprint Images", International Journal of Image, Graphics & Signal Processing, vol. 11, no. 5, pp. 34–43, May 2019.
- [4] M. Afifi and A. Abdelhamed, "Deep gender classification based on AdaBoost-based fusion of isolated facial features and foggy faces", Journal of Visual Communication and Image Representation, vol. 62, pp. 77–86, July 2019.
- [5] M. Duan, K. Li, C. Yang and K. Li, "A hybrid deep learning CNN-ELM for age and gender classification", Neurocomputing , vol. 275, pp. 448–461, 31 January 2018.
- [6] L. Chen, C. Fan, H. Yang, S. Hu, L. Zou and D. Deng, "Face age classification based on a deep hybrid model", Signal, Image and Video Processing, vol. 12, no. 8, p. 1531–1539, November 2018.
- [7] S. Y. Wong, K. S. Yap, Q. Zhai and X. Li, "Realization of a Hybrid Locally Connected Extreme Learning Machine With DeepID for Face Verification", IEEE Access, vol. 7, pp. 70447–70460, 2019.
- [8] R. Ranjan , A. Bansal , J. Zheng, H. Xu, J. Gleason, B. Lu, A. Nanduri, J.-C. Chen, C. D. Castillo and R. Chellappa, "A Fast and Accurate System for Face Detection, Identification, and Verification", IEEE Transactions on Biometrics, Behavior, and Identity Science, vol. 1, no. 2, pp. 82–96, April 2019.
- [9] S. Saha, R. Navarathna, L. Helminger and R. Weber, "Unsupervised Deep Representations for Learning Audience Facial Behaviors", in The IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops, 2018.
- [10] Y. Wu, Z. Ding, H. Liu, J. Robinson and Y. Fu, "Kinship Classification through Latent Adaptive Subspace", in 13th IEEE International Conference on Automatic Face & Gesture Recognition, Xi'an, 2018.
- [11] M. B. Lopez, A. Hadid, E. Boutellaa, J. Goncalves, V. Kostakos and S. Hosio, "Kinship verification from facial images and videos: human versus machine", Machine Vision and Applications, vol. 29, no. 5, p. 873–890, July 2018.

- [37] A. Bellet, A. Habrard and M. Sebban, "A Survey on Metric Learning for Feature Vectors and Structured Data", in ArXiv, 2013.
- [38] H. Yan, "Kinship verification using neighborhood repulsed correlation metric learning", *Image and Vision Computing*, vol. 60, pp. 91-97, 2017.
- [39] R. Lan and Y. Zhou, "Quaternion-Michelson Descriptor for Color Image Classification", *IEEE Transactions on Image Processing*, vol. 25, no. 11, pp. 5281-5292, 2016.
- [40] M. B. López, E. Boutellaa and A. Hadid, "Comments on the "Kinship Face in the Wild" Data Sets", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 38, no. 11, pp. 2342-2344, 2016.
- [41] L. Li, X. Feng, X. Wu, Z. Xia and A. Hadid, "Kinship Verification from Faces via Similarity Metric Based Convolutional Neural Network", *International conference image analysis and recognition*. Springer, vol. 9730, p. 539-548, 2016.
- [42] R. Lan, Y. Zhou and Y. Y. Tang, "Quaternionic Weber Local Descriptor of Color Images", *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 27, no. 2, pp. 261-274, 2017.
- [43] K. Zhang, Y. Huang, C. Song, H. Wu and L. Wang, "Kinship Verification with Deep Convolutional Neural Networks", 2015.
- [44] A. Puthenputhussery, Q. Liu and C. Liu, "SIFT flow based genetic fisher vector feature for kinship verification", Phoenix, AZ, 2016.
- [45] X. Zhou, Y. Shang, H. Yan and G. Guo, "Ensemble similarity learning for kinship verification from facial images in the wild", *Information Fusion*, vol. 32, no. PB, pp. 40-48, 2016.
- [46] X. Zhou, H. Yan and Y. Shang, "Kinship verification from facial images by scalable similarity fusion", *similarity fusion*, vol. 197, pp. 136-142, 2016.
- [47] Y. Fang, Y. Yan, S. Chen, H. Wang and C. Shu, "Sparse similarity metric learning for kinship verification", in *Visual Communications and Image Processing (VCIP)*, Chengdu, 2016.
- [48] B. RaviKumarY and C. Kumar, "Harmonic Rule for Measuring the Facial Similarities among Relatives", *Transactions on Machine Learning and Artificial Intelligence*, vol. 4, p. 29, 2018.
- [49] B. Patel, R. Maheshwari and B. Raman, "Evaluation of periocular features for kinship verification in the wild", *Computer Vision and Image Understanding*, vol. 160, pp. 24-35, 2017.
- [24] H. Yan and C. Song, "Multi-scale deep relational reasoning for facial kinship verification", *Pattern Recognition*, vol. 110, 2021.
- [25] E. Dahan and Y. Keller, "A Unified Approach to Kinship Verification", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pp. 1-8, 2020.
- [26] A. Chergui, S. Ouchtati, S. Mavromatis, S. E. Bekhouche, M. Lashab and J. Sequeira, "Kinship Verification Through Facial Images Using CNN-Based Features", *Traitement du Signal*, vol. 37, no. 01, pp. 1-8, 2020.
- [27] S. Wang and H. Yan, "Discriminative sampling via deep reinforcement learning for kinship verification", *Pattern Recognition Letters*, vol. 138, pp. 38-43, 2020.
- [28] A. Moujahid and F. Dornaika, "A pyramid multi-level face descriptor: application to kinship verification", *Multimedia Tools and Applications volume*, vol. 78, no. 7, pp. 9335-9354, 2019.
- [29] X. Wu, E. Boutellaa, . M. B. Lopez , X. Feng and A. Hadid, "On the usefulness of color for kinship verification from face images", in *IEEE International Workshop on Information Forensics and Security (WIFS)*, Abu Dhabi, 2016.
- [30] A. Bottinok, I. U. Islam and T. F. Vieira, "A multi-perspective holistic approach to Kinship Verification in the Wild", in *11th IEEE International Conference and Workshops on Automatic Face and Gesture Recognition (FG)*, Ljubljana, 2015.
- [31] J. Kannala and E. Rahtu, "BSIF: Binarized Statistical Image Features", in *Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012)*, Tsukuba, 2012.
- [32] L. Wolf, T. Hassner and Y. Taigman, "Effective Unconstrained Face Recognition by Combining Multiple Descriptors and Learned Background Statistics", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 33, no. 10, pp. 1978-1990, 2011.
- [33] O. Tuzel, F. Porikli and P. Meer, "Region Covariance: A Fast Descriptor for Detection and Classification", in *9th European conference on Computer Vision*, Berlin, Heidelberg, 2006.
- [34] Y. Pang, Y. Yuan and X. Li, "Gabor-Based Region Covariance Matrices for Face Recognition", *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 18, no. 7, pp. 989-993, 2008.
- [35] R. Lan, Y. Zhou and Y. Y. Tang, "Quaternionic Local Ranking Binary Pattern: A Local Descriptor of Color Images", *IEEE Transactions on Image Processing*, vol. 25, no. 2, pp. 566-579, 2016.
- [36] J. Lu, J. Hu, X. Zhou, Y. Shang, Y.-P. Tan and G. Wang, "Neighborhood repulsed metric learning for kinship verification", in *IEEE Conference on Computer Vision and Pattern Recognition*, Providence, RI, 2012.



فهمیه رمضانخانی مدرک کارشناسی مهندسی فناوری اطلاعات را در سال ۱۳۹۶ از دانشگاه یزد اخذ کرد و از سال ۱۳۹۷ دانشجوی کارشناسی ارشد مهندسی کامپیوتر گرایش هوش مصنوعی دانشگاه یزد است. زمینه‌های پژوهشی ایشان تشخیص الگو و یادگیری ماشین است.



مهدی یزدیان دهکردی مدرک کارشناسی مهندسی کامپیوتر گرایش نرم‌افزار را در سال ۱۳۸۵ از دانشگاه یزد و مدرک کارشناسی ارشد و دکترای خود را به ترتیب در سال‌های ۱۳۸۸ و ۱۳۹۴ در رشته مهندسی کامپیوتر گرایش هوش مصنوعی از دانشگاه شیراز اخذ کرد. در حال حاضر عضو هیئت علمی دانشکده مهندسی کامپیوتر دانشگاه یزد می‌باشد. زمینه‌های پژوهشی اصلی ایشان بینایی ماشین، یادگیری ماشین و یادگیری عمیق است.