

شناسایی افراد از طریق رگ‌های خونی انگشت دست در فضای رادون با به کارگیری الگوهای فضایی مشترک

حمید حسن‌پور و اکرم غلامی

یک ویژگی منحصر به فرد است. وضعیت رگ‌ها حتی میان دوقلوهای همسان هم ناهمسان است. تنها مشخصه‌ای از رگ‌ها که با گذشت زمان تغییر می‌کند اندازه آنهاست.

فرایند معمول شناسایی رگ انگشت از چهار مرحله تشکیل می‌شود: مرحله اخذ تصویر رگ انگشت، پردازش تصویر، استخراج ویژگی و شناسایی بر اساس تطبیق ویژگی [۳] و [۴]. تصاویر رگ انگشت با استفاده از طیف‌نمای نزدیک مادون قرمز^۱ اخذ می‌شوند. نور مادون قرمز با طول موج ۷۶۰ تا ۱۰۰۰ نانومتر می‌تواند از بیشتر بافت‌های بدن انسان عبور کند در حالی که هموگلوبین موجود در خون می‌تواند نور مادون قرمز را به طور کامل جذب کند [۵] و بنابراین الگوهای رگ انگشت توسط یک منبع نور مادون قرمز نزدیک (NIR) با طول موج مناسب اخذ می‌شوند. روش استخراج رگ تأثیر مستقیمی بر روی استخراج ویژگی و تطابق ویژگی‌ها دارد و بنابراین استخراج رگ اثر قابل توجهی بر کل سیستم دارد. مرحله پیش‌پردازش شامل بهبود تصویر، حذف نویز و نرمال‌سازی می‌باشد [۱] و [۳]. الگوریتم‌های بهبود [۶] تا [۹] به منظور بهبود کیفیت تصاویر استفاده می‌شوند.

قطعه‌بندی رگ انگشت یک مرحله بسیار مهم است و برخی روش‌های رایج برای این منظور وجود دارد [۱] و [۳]. میورا و همکارانش الگوی رگ انگشت را با ردیابی مکرر خط^۲ از تصویر ناواضح استخراج نموده‌اند [۱۰]. در [۱۱] ویژگی‌های مینوشیا از الگوهای رگ استخراج می‌شوند. نقاط مینوشیا^۳ شامل نقاط میانی و انتهایی هستند که برای نمایش هندسی شکل الگوهای رگ استفاده می‌شوند. نویسنده در [۱۲] یک روش انحنای متوسط^۴ را پیشنهاد نموده که با در نظر گرفتن تصویر رگ به عنوان یک شکل هندسی، ساختارهای شبیه دره^۵ با انحنای متوسط منفی را می‌یابد. ترکیب دو روش قطعه‌بندی شامل عملگرهای مورفولوژیک و نقاط حداکثر انحنای در پروفایل‌های تصویر نیز در استخراج الگوهای رگ انگشت استفاده شده است [۱۳]. در [۱۴] نویسنده برای استخراج ویژگی از یک آشکارساز خط وسیع^۶ استفاده می‌کند که علاوه بر کسب اطلاعات وسیع دقیق برای رگ‌ها، اطلاعات ویژگی‌های استخراج شده از تصاویر کم‌کیفیت را افزایش می‌دهد. به عنوان روشی دیگر در [۱۵] از فیلتر گابور دوبعدی برای فیلتر کردن تصویر رگ انگشت اصلی استفاده شده است و سپس ویژگی‌های بافت فاز و جهت استخراج شده‌اند. اطلاعات فاز و جهت در سطح ویژگی، ترکیب و کدگذاری و در نهایت شباهت توسط فاصله همینگ اصلاح شده اندازه‌گیری می‌شود. در [۱۶] و [۱۷] روش‌های مبتنی

چکیده: یکی از مناسب‌ترین بیومتریک‌ها برای شناسایی افراد، رگ‌های انگشت دست می‌باشد. در این مقاله روش جدیدی ارائه شده است که به شناسایی افراد از طریق رگ‌های خونی انگشت دست با دقت بالا می‌پردازد. این مقاله ابتدا از آستانه‌گذاری آنتروپی محلی برای قطعه‌بندی و استخراج رگ‌ها از تصاویر انگشت استفاده می‌نماید. آستانه‌گذاری آنتروپی محلی رگ‌ها را به خوبی استخراج می‌کند اما تصاویر حاصل از آن نویزی هستند به این مفهوم که رگ‌های استخراج شده ممکن است به صورت خطوط متقاطع ظاهر شوند. برای کم‌کردن حساسیت مرحله شناسایی نسبت به نویزهای موجود در تصاویر قطعه‌بندی شده، از تبدیل رادون استفاده می‌کنیم. تبدیل رادون به علت داشتن ماهیت انتگرالی، نسبت به نویزهای موجود در تصویر حساس نیست و بنابراین در مقایسه با سایر روش‌ها نسبت به نویز از مقاومت بیشتری برخوردار است. همچنین با استفاده از این تبدیل علاوه بر این که به استخراج خطوط رگ به طور دقیق نیاز نیست، دقت و سرعت شناسایی نیز افزایش می‌یابد. برای استخراج ویژگی از تصاویر رگ انگشت، الگوهای فضایی مشترک به بلوک‌های تبدیل رادون اعمال می‌شوند. در مرحله شناسایی نیز از دو روش نزدیک‌ترین همسایه (1-NN) و شبکه عصبی پرسپترون چندلایه (MLP) استفاده می‌شود. آزمایش‌های انجام شده روی مجموعه تصاویر رگ انگشت پایگاه داده دانشگاه پکنینگ نرخ موفقیت ۹۹٫۶۷۵۳ درصد در شناسایی افراد را نشان می‌دهد.

کلیدواژه: شناسایی رگ انگشت، آستانه‌گذاری آنتروپی محلی، تبدیل رادون، الگوهای فضایی مشترک (CSP).

۱- مقدمه

شناسایی بیومتریک افراد با تکیه بر خصوصیات فردی و رفتاری آنها انجام می‌شود. روش‌های شناسایی بیومتریک مختلفی وجود دارند که از آن جمله می‌توان به روش‌های مبتنی بر اثر انگشت، چهره، عنبیه، صوت و رگ دست اشاره کرد. روش‌های بیومتریک ذکر شده در شرایط خاص، محدودیت‌هایی دارند [۱]. به عنوان مثال، شناسایی چهره به چرخش‌ها و تغییرات روشنایی حساس است. در سیستم‌های شناسایی اثر انگشت، کاربران مجبورند توسط انگشت و دست خود با سطح سنسور ورودی در تماس باشند که می‌تواند نارضایتی کاربر را به همراه داشته باشد [۲]. علاوه بر این شرایط، یک انگشت به خاطر خشکی یا عرق زیاد می‌تواند مانع ایجاد یک الگوی واضح شود. شناسایی عنبیه از نظر دقت، بهتر اما دستگاه ضعیف آن گران‌قیمت است. برای غلبه بر این مشکلات، الگوهای رگ مطالعه شده‌اند [۲]. حالت رگ‌های هر شخص مانند اثر انگشت او

این مقاله در تاریخ ۱۵ اردیبهشت ماه ۱۳۹۵ دریافت و در تاریخ ۲۷ آذر ماه ۱۳۹۵ بازنگری شد.

حمید حسن‌پور، دانشکده مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی شاهرود، شاهرود، (email: h.hassanpour@shahroodut.ac.ir)
اکرم غلامی، دانشکده مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی شاهرود، شاهرود، (email: a.gholami@shahroodut.ac.ir)

1. Near Infrared (NIR) Light
2. Repeated Line Tracking
3. Minutia Points
4. Mean Curvature
5. Vally-Like Structure
6. Wide Line Detector

از یک ماتریس هم‌رخدادی^۹ برای تعریف آنتروپی مرتبه دوم محلی^{۱۰} و آنتروپی مرتبه دوم اتصال^{۱۱} استفاده می‌کنند [۲۱]. آستانه مبتنی بر آنتروپی که با استفاده از ماتریس هم‌رخدادی سطح خاکستری به کار گرفته می‌شود [۲۱] آستانه بهینه را با در نظر گرفتن توزیع فضایی سطوح خاکستری نهفته در ماتریس هم‌رخداد محاسبه می‌کند. ماتریس هم‌رخدادی سطح خاکستری، یک ماتریس مربعی $L \times L$ از تصویر مقیاس خاکستری F از توزیع فضایی $P \times Q$ است که سطوح خاکستری آن در محدوده $[0, 1, \dots, L-1]$ می‌باشند و این ماتریس به صورت $T = [t_{ij}]_{P \times Q}$ نمایش داده می‌شود. عناصر ماتریس تعداد انتقال بین تمام جفت‌های سطوح خاکستری در یک مسیر خاص را مشخص می‌کنند [۲۱]. برای هر پیکسل تصویر در هم‌رخداد فضایی (m, n) که سطح خاکستری آن توسط $f(m, n)$ مشخص می‌شود، چهار نزدیک‌ترین پیکسل‌های همسایه آن در مکان‌های $(m, n+1)$ ، $(m-1, n)$ ، $(m+1, n)$ و $(m, n-1)$ در نظر گرفته می‌شوند. ماتریس هم‌رخداد با مقایسه تغییرات سطح خاکستری $f(m, n)$ به سطوح خاکستری همسایه متناظر با آن یعنی $f(m-1, n)$ ، $f(m+1, n)$ و $f(m, n-1)$ ایجاد می‌شود. با توجه به مسیری که سطح خاکستری i سطح خاکستری j را دنبال می‌کند، تعاریف متفاوتی از ماتریس هم‌رخداد شکل می‌گیرد. در اینجا ماتریس هم‌رخداد با در نظر گرفتن انتقال‌های افقی راست و عمودی پایین محاسبه شده است [۲۱] و بنابراین t_{ij} به صورت زیر تعریف می‌شود

$$t_{ij} = \sum_{l=1}^P \sum_{k=1}^Q \delta \quad (1)$$

$$?? = \begin{cases} 1 & \text{if } \begin{cases} f(l, k) = i \text{ and } f(l, k+1) = j \\ \text{or} \\ f(l, k) = i \text{ and } f(l+1, k) = j \end{cases} \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

رابطه (۱) تعداد کل انتقال‌ها در ماتریس هم‌رخداد است. یک احتمال انتقال مطلوب از سطح خاکستری i به سطح خاکستری j که با p_{ij} نشان داده می‌شود به صورت زیر به دست می‌آید

$$p_{ij} = \frac{t_{ij}}{\sum_i \sum_j t_{ij}} \quad (3)$$

اگر آستانه مطلوب را با s نشان دهیم و $0 \leq s \leq L-1$ باشد، در این صورت s یک تصویر را به پس‌زمینه و پیش‌زمینه تقسیم می‌کند (شکل ۱). پس‌زمینه شامل پیکسل‌ها با سطوح خاکستری پایین‌تر یا مساوی با s است و پیش‌زمینه متناظر با اشیایی است که پیکسل‌هایی با سطح خاکستری بالاتر از s دارند. علاوه بر این s ماتریس هم‌رخدادی را به چهارگوش‌هایی تقسیم می‌کند که به ترتیب متناظر با انتقال از پس‌زمینه به پس‌زمینه^{۱۲} (BB)، پس‌زمینه به شیء^{۱۳} (BO)، شیء به پس‌زمینه^{۱۴} (OB) و شیء به شیء^{۱۵} (OO) هستند. این چهارگوش‌ها به ترتیب A ، B ، C و D نامیده می‌شوند [۲۱] و [۲۲].

بر الگوهای دودویی پیشنهاد شده‌اند که از فیلتر بالاگذر گوسین اصلاح‌شده برای بهبود تصاویر رگ انگشت استخراج‌شده استفاده می‌شود. برای استخراج کدهای باینری از تصاویر بهبودیافته نیز^{۱۶} LBP،^{۱۷} LLBP^{۱۸} و [۱۷] و [۱۶] استفاده می‌شوند. همچنین از فاصله همینگ نیز برای بررسی شباهت بین کدهای باینری موجود و کدهای باینری استخراج‌شده استفاده می‌شود. اخیراً نیز محققان بسیاری بری شناسایی رگ انگشت از روش‌های یادگیری ماشین استفاده نموده‌اند [۱۸] تا [۲۰]. در این مقاله از آستانه‌گذاری آنتروپی محلی^۴ برای قطعه‌بندی تصویر استفاده نمودیم. این روش عملکرد خوبی در استخراج رگ‌ها دارد اما تصاویر قطعه‌بندی شده نویزی هستند. به این مفهوم که علاوه بر رگ‌ها که به صورت خطوط تیره ظاهر می‌شوند، تعدادی خطوط کوتاه و بلند دیگر نیز در تصاویر قطعه‌بندی شده وجود دارد. برای کاهش اثر نویز بر روی شناسایی از تبدیل رادون استفاده می‌کنیم. تبدیل رادون به علت داشتن ماهیت انتگرالی نسبت به نویز از مقاومت بیشتری برخوردار است. این تبدیل که یک جایگزین برای تبدیل هاف است تصاویری که شامل خط هستند را به یک فضا که شامل خصوصیات خط است انتقال می‌دهد. با این تبدیل مجبور نیستیم که به طور دقیق خطوط را از تصویر استخراج کنیم. سپس برای استخراج ویژگی، الگوهای فضایی مشترک را به بلوک‌های رادون اعمال نمودیم. الگوهای فضایی مشترک (CSP)، یک تبدیل خطی را برای تصویر کردن داده چندکاناله EEG^۵ به زیرفضای با ابعاد کمتر توسط یک ماتریس تصویر به کار می‌برند. در نهایت از شبکه عصبی پرسپترون چندلایه (MLP) و روش نزدیک‌ترین همسایه NN-1 برای دسته‌بندی داده‌ها استفاده نمودیم.

ادامه این مقاله به این صورت سازمان‌دهی شده است: قطعه‌بندی و استخراج الگوهای رگ انگشت در بخش ۲ معرفی می‌شود. تبدیل رادون^۶ در بخش ۳ توضیح داده خواهد شد. استخراج ویژگی با الگوی فضایی مشترک^۷ در بخش ۴ خواهد آمد. تطبیق ویژگی در بخش ۵ بیان می‌شود. در بخش ۶ روش پیشنهادی توصیف خواهد شد. نتایج تجربی در بخش ۷ قرار دارند و در نهایت بخش ۸ شامل نتیجه‌گیری است.


۲- قطعه‌بندی و استخراج الگوهای رگ انگشت

هنگامی که نویز کاهش و کنتراست بهبود می‌یابد، قطعه‌بندی منجر به جداسازی الگوی رگ از پس‌زمینه می‌شود. در واقع، الگوهای رگ مکان‌یابی شده و از بقیه تصویر جدا می‌شوند و در نتیجه تصویر باینری می‌گردد. این مهم‌ترین گام در کل فرایند شناسایی است. اگر رگ‌ها به درستی تشخیص داده نشوند خطر ابتلا به اشتباهات تا حد زیادی افزایش می‌یابد. بنابراین روش انتخاب‌شده نقش بزرگی در عملکرد کلی سیستم دارد. در این تحقیق از آستانه‌گذاری آنتروپی محلی برای قطعه‌بندی تصویر و استخراج رگ‌های انگشت استفاده شده است.

در سال‌های اخیر، رویکردهای آستانه‌گذاری نظری اطلاعات مبتنی بر مفهوم تئوری شانون^۸، توجه زیادی را به خود جلب نموده‌اند. این روش‌ها

1. Local Binary Pattern
2. Local Directional Code
3. Local Line Binary Pattern
4. Local Entropy Thresholding
5. Electroencephalography
6. Radon Transformation
7. Common Spatial Pattern
8. Shannon's Entropy

9. Co-occurrence Matrix
10. Second-Order Local Entropy
11. Second-Order Joint Entropy
12. Background to Background
13. Background to Objects
14. Objects to Background



شکل ۲: (الف) یک تصویر انگشت دست و (ب) تصویر قطعه‌بندی شده با اعمال آستانه آنتروپی محلی.

$$T_E = \arg[\max_{T=1, \dots, L-1} H_T^{(v)}(S)] \quad (11)$$

که مقدار آستانه بهینه برای کلاس‌بندی شیء- پس‌زمینه می‌باشد. شکل ۲ تصویر رگ انگشت یک فرد را نشان می‌دهد که الگوهای رگ انگشت را با آستانه آنتروپی محلی استخراج نموده‌ایم. همان طور که در شکل می‌بینیم رگ‌ها به خوبی استخراج شده‌اند اما تصاویر قطعه‌بندی شده نویزی هستند. از آنجایی که تبدیل رادون به علت داشتن ماهیت انتگرالی نسبت به نویز حساس نیست و مقاومت بالایی در برابر نویز دارد در مرحله شناسایی از تبدیل رادون استفاده می‌کنیم. به این صورت که با اعمال تبدیل رادون به تصاویری که با استفاده از آستانه‌گذاری آنتروپی محلی قطعه‌بندی شده‌اند، این تصاویر را به فضای رادون انتقال می‌دهیم.

۳- تبدیل رادون

تبدیل رادون تبدیلی انتگرالی است که مقدار آن برابر با انتگرال تابع بر روی یک خط است. این تبدیل با جمع شدت پیکسل‌های تصویر [۲۴] و [۲۵] در همه جهتهای ممکن در شناسایی و موقعیت‌یابی خطوط در تصویر بسیار مناسب است [۲۶]. این تبدیل اساساً قادر است تا تصاویر دوبعدی حاوی خطوط را به حوزه‌ای با پارامترهای آن خطوط تبدیل کند، جایی که هر خطی یک قله را در جهت منطبق می‌دهد [۲۷] و [۲۸]. تبدیل رادون گسسته دوبعدی همان تبدیل هاف برای یک تصویر $f(x, y)$ است و می‌تواند به صورت زیر بیان شود [۲۹]

$$R(\rho, \theta) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \delta(\rho - x \cos \theta - y \sin \theta) dx dy \quad (12)$$


که در اینجا ρ فاصله خط از مبدأ، δ دیراک دلتا و θ زاویه‌ای است که تبدیل رادون در آن جهت گرفته می‌شود [۲۵] و [۲۸]. تبدیل رادون حالت خطی بودن، مقیاس، چرخش و کج کردن را ارضا می‌کند [۲۵]. این خصوصیات هم‌زمان با توانایی آن در شناسایی خطوط در محیطی با سطوح نویز زیاد، دلیل اصلی انتخاب این روش به عنوان یک ابزار مناسب برای تحلیل تصاویر می‌باشد. در شکل ۳ تبدیل رادون را به دو تصویر رگ انگشت اعمال نموده‌ایم.

۴- استخراج ویژگی

استخراج ویژگی فرایندی است که در آن با انجام عملیاتی بر روی داده‌ها، ویژگی‌های بارز و تعیین‌کننده آن مشخص می‌شود. هدف از مرحله استخراج ویژگی، استخراج ویژگی‌های واقعی از الگوی رگ از یک تصویر است که پس از آن برای تطبیق استفاده می‌شود. در این تحقیق از تکنیک CSP برای استخراج ویژگی استفاده شده است.

۴-۱ استخراج ویژگی با الگوی فضایی مشترک

یکی از موفق‌ترین شیوه‌ها برای تشخیص الگوهای مغزی، روش الگوهای فضایی مشترک (CSP) است [۳۰]. CSP یک تبدیل خطی را برای تصویر کردن داده EEG چندکاناله به یک زیرفضای فاصله‌ای با ابعاد



شکل ۱: چهارگوش‌های ماتریس هم‌رخداد [۲۲].

آنتروپی محلی تنها روی دو مربع A و C تعریف می‌شود در حالی که آنتروپی اتصال روی دو مربع دیگر تعریف می‌شود. برای محاسبه آستانه آنتروپی محلی احتمالات کلاس شیء و کلاس پس‌زمینه به صورت زیر تعریف می‌شوند [۲۱]

$$P_A = \sum_{i=0}^S \sum_{j=0}^S p_{ij} \quad (4)$$

$$P_C = \sum_{i=S+1}^{L-1} \sum_{j=S+1}^{L-1} p_{ij} \quad (5)$$

با نرمال‌سازی احتمالات درون هر چهارگوش به صورتی که مجموع احتمالات هر چهارگوش برابر با یک شود، احتمالات سلول که احتمالات نرمال شده کلاس شیء و کلاس پس‌زمینه هستند برای چهارگوش‌های مختلف به صورت زیر تعریف می‌شوند [۲۱]

$$P_{ij}^A = \frac{p_{ij}}{P_A} = \frac{t_{ij}}{\sum_{i=0}^S \sum_{j=0}^S t_{ij}} = \frac{t_{ij}}{\sum_{i=0}^S \sum_{j=0}^S t_{ij}}, \quad (6)$$

for $0 \leq i \leq S, 0 \leq j \leq S$

$$P_{ij}^C = \frac{p_{ij}}{P_C} = \frac{t_{ij}}{\sum_{i=S+1}^{L-1} \sum_{j=S+1}^{L-1} t_{ij}}, \quad (7)$$

for $S+1 \leq i \leq L-1, S+1 \leq j \leq L-1$

آنتروپی مرتبه دوم شیء به صورت زیر است [۲۱]

$$H_A^{(v)}(S) = -\frac{1}{v} \sum_{i=0}^S \sum_{j=0}^S P_{ij}^A \log_v P_{ij}^A \quad (8)$$

آنتروپی انتقال محلی A توسط $H_A^{(v)}(S)$ نشان داده می‌شود. به طور مشابه، آنتروپی مرتبه دوم پس‌زمینه به صورت زیر تعریف می‌شود [۲۱]

$$H_C^{(v)}(S) = -\frac{1}{v} \sum_{i=S+1}^{L-1} \sum_{j=S+1}^{L-1} P_{ij}^C \log_v P_{ij}^C \quad (9)$$

با جمع کردن آنتروپی‌های محلی مرتبه دوم شیء و پس‌زمینه، آنتروپی محلی مرتبه دوم به صورت زیر به دست می‌آید [۲۳]

$$H_T^{(v)}(S) = H_A^{(v)}(S) + H_C^{(v)}(S) \quad (10)$$

در نهایت، سطح خاکستری متناظر با ماکسیمم $H_T^{(v)}(S)$ ، مقدار آستانه بهینه برای کلاس‌بندی شیء- پس‌زمینه [۲۱] را می‌دهد و به صورت زیر محاسبه می‌شود

$$R_i = \frac{1}{l} \sum_{i=1}^l \frac{R^{(i)} R'^{(i)}}{\text{Trace}(R^{(i)} R'^{(i)})} \quad (14)$$

که در این رابطه l تعداد تصاویر مربوط به هر شخص است و R نیز ماتریس کواریانس نرمال شده را نشان می‌دهد. مجموع عناصر قطری x توسط $\text{trace}(x)$ ارائه می‌گردد. l تعداد آزمایشات و R' ترانهاده ماتریس R را بیان می‌کند. ماتریس کواریانس مرکب به صورت زیر محاسبه می‌شود

$$R = \sum_{i=1}^n R_i \quad (15)$$

در این رابطه n تعداد نمونه‌ها می‌باشد. بردارهای ویژه و مقادیر ویژه باید از ماتریس R استخراج شوند

$$R = U \cdot \sum U^T \quad (16)$$

بردارهای ویژه و مقادیر ویژه ماتریس R به ترتیب U و Λ می‌باشند. سپس ماتریس وزنی به صورت زیر محاسبه می‌شود

$$W = \Lambda^{-\frac{1}{2}} U^T \quad (17)$$

برای استخراج الگوهای فضایی مشترک مربوط به کلاس a از رابطه زیر استفاده می‌کنیم

$$R'_a = \sum_{i \neq a} R_i \quad (18)$$

سپس برای کلاس a می‌توانیم ماتریس‌های کواریانس تبدیل شده S_a و S'_a را به صورت زیر ارزیابی کنیم

$$S_a = W R_a W^T \quad (19)$$

$$S'_a = W R'_a W^T \quad (20)$$

بدیهی است که مجموع مقادیر ویژه منطبق با این ماتریس‌ها برابر با مقدار یک خواهد شد. S_a و S'_a بردارهای ویژه مشترک را به اشتراک می‌گذارند و بنابراین S_a و S'_a می‌توانند به صورت زیر تجزیه شوند

$$S_a = U \Lambda_a U^T \quad (21)$$

$$S'_a = U \Lambda'_a U^T \quad (22)$$

که در آن شرط زیر برقرار است


$$\Lambda_a + \Lambda'_a = I \quad (23)$$

با فرض این که بردارهای ویژه U به صورت نزولی نسبت به مقادیر ویژه Λ_a مرتب شده باشند (یا به صورت افزایشی نسبت به Λ'_a) در نتیجه ماتریس تصویر به صورت زیر است

$$S F_a = U W \quad (24)$$

$S F_a$ می‌تواند به عنوان فیلتر فضایی یک کلاس دیده شود. حال وقتی کلاس a و a' هر دو در اولین بردار ویژه U_1 ضرب می‌شوند، در این صورت کلاس a می‌تواند بیشینه واریانس و کلاس a' مینیمم واریانس را به دست آورد. در حالی که اگر کلاس‌ها در آخرین بردار ویژه U_N ضرب شوند نتایج معکوسی حاصل می‌شود یعنی در این صورت کلاس a موجب مینیمم واریانس و کلاس a' موجب بیشینه واریانس می‌شود. بنابراین نگاهت هر تصویر رگ انگشت از نمونه a را به صورت زیر به دست می‌آوریم

$$Z_a = S F_a X_a \quad (25)$$



شکل ۳: تصاویر رگ انگشت دو نفر و اعمال تبدیل رادون به آنها $\theta = 180^\circ$ و r یکسان در هر θ .

کم به کار می‌برد. این تبدیل می‌تواند تغییرات ماتریس‌های سیگنال دو کلاسه را ماکسیمم کند. روش CSP مبتنی بر قطری‌سازی ماتریس‌های کواریانس کلاس‌ها است. در واقع CSP با ترکیب خطی سیگنال از همه کانال‌ها واریانس را برای یک کلاس خاص ماکسیمم کرده و برای بقیه مینیمم می‌کند.

مشابه سیگنال‌های EEG تصاویری که به فضای رادون رفته‌اند تصاویر رنگی هستند و سه بخش اصلی دارند که مشابه مؤلفه‌های R ، G و B هستند. بنابراین می‌توانیم از روش الگوی فضایی مشترک برای استخراج ویژگی از این تصاویر رنگی استفاده کنیم. ابتدا تصاویر را به پنجره‌های با ابعاد یکسان تقسیم می‌کنیم. سپس بر روی تک‌تک پنجره‌ها روش استخراج ویژگی CSP را اعمال کرده و بردارهای ویژگی را از هر پنجره استخراج می‌کنیم. با کنار هم قرار دادن بردارهای ویژگی هر یک از پنجره‌ها، بردار ویژگی نهایی به دست خواهد آمد.

۴-۲- تعمیم CSP برای کلاسه‌بندی c کلاسه

روش CSP ابتدا برای کلاسه‌بندی دو کلاسه مطرح شد [۳۱] و بعداً به سه کلاس تعمیم داده شد. CSP می‌تواند بدون از دست دادن عمومیت به چندین کلاس توسعه یابد. بنابراین از این الگوریتم برای کلاسه‌بندی داده‌ها در c کلاس استفاده نموده‌ایم که $c = 154$ برابر با تعداد افرادی است که تصاویر رگ انگشت آنها در پایگاه داده مورد آزمایش وجود دارد. در مرحله پیش‌پردازش ابتدا هر تصویر را به یک بردار با یک سطر تبدیل می‌کنیم. فرض می‌شود اشخاص (کلاس‌های) مختلف به صورت ماتریس $X^{(i)}$ نشان داده می‌شوند که i شماره هر کلاس را نشان می‌دهد ($i = 1, \dots, 154$). ابعاد کلاس‌ها $N \times K$ می‌باشد که N تعداد مؤلفه‌های رنگی است که برابر با ۳ و K تعداد نمونه‌ها در ماتریس تصویر می‌باشد. ماتریس کواریانس فضایی برای هر کلاس به صورت زیر محاسبه می‌شود

$$R^{(i)} = \sum_{k=1}^K (x_k^{(i)})^2 - \frac{1}{K} \sum_{k=1}^K x_k^{(i)} \quad (13)$$

در اینجا $x_k^{(i)}$ یک بردار N بعدی در زمان k و t یک عملگر ترانهاده است. ماتریس‌های کواریانس نرمال شده به صورت زیر تعریف می‌شوند

دسته‌بندی و تطبیق ویژگی مورد بررسی قرار گرفته‌اند.

۶- سیستم پیشنهادی

در این تحقیق یک روش جدید برای شناسایی رگ انگشت ارائه شده که در آن از آستانه‌گذاری آنتروپی محلی برای استخراج رگ‌های انگشت استفاده شده است. الگوهای فضایی مشترک نیز برای استخراج ویژگی از تصاویر رگ انگشت مورد استفاده قرار گرفته‌اند. بلوک دیاگرام روش پیشنهادی در شکل ۴ نشان داده شده است. همان طور که قبلاً ذکر شد شناسایی رگ انگشت از چهار مرحله اخذ تصویر، پیش‌پردازش، استخراج ویژگی و تطبیق (دسته‌بندی) ویژگی‌ها تشکیل می‌شود. مرحله پیش‌پردازش شامل بهبود تصویر و قطعه‌بندی تصویر به منظور استخراج رگ‌ها می‌باشد. در این تحقیق تصاویر را به طور درست پردازش نمی‌کنیم بلکه تبدیل رادون را به آنها اعمال نموده و بعد پردازش می‌کنیم.

قطعه‌بندی یک گام بسیار مهم در فرایند شناسایی است و اگر رگ‌ها به خوبی استخراج نشوند نرخ شناسایی کاهش می‌یابد. برای قطعه‌بندی روش‌های متعددی وجود دارد و در این تحقیق از روش آستانه آنتروپی محلی برای قطعه‌بندی تصویر استفاده نمودیم. اگرچه این روش تلفات اتصال را کاهش می‌دهد و در نتیجه باعث بهبود دقت قطعه‌بندی می‌شود اما تعدادی خطوط کوچک و بزرگ را نیز که جزء رگ‌ها نیستند استخراج می‌کند و تصاویر حاصل از آن اندکی نویزی هستند. به دلیل این که تبدیل رادون به علت داشتن ماهیت انتگرالی نسبت به نویز مقاومت بیشتری دارد، بنابراین این تبدیل را بر روی تصاویر اعمال نمودیم.

روش CSP روشی است که برای استخراج ویژگی از سیگنال‌های EEG استفاده می‌کند زیرا برای ثبت سیگنال‌های EEG از مغز افراد، چندین الکترود بر روی سر افراد قرار داده می‌شود و سیگنال‌هایی از ترکیب سیگنال‌های دریافتی از همه این الکترودها به دست می‌آید. CSP از ویژگی‌های متفاوت هر یک از این کانال‌ها استفاده کرده و ویژگی مناسب را از سیگنال استخراج می‌کند. برای به کارگیری این روش برای تصاویر، مؤلفه‌های R ، G و B تصاویر رادون را به عنوان کانال‌های مختلف در نظر گرفتیم و به استخراج ویژگی پرداختیم. برای استخراج ویژگی از تصاویر رادون، ابتدا این تصاویر را که سایز آنها 512×384 پیکسل می‌باشد به تصاویری با اندازه 50×50 تغییر اندازه می‌دهیم. تصاویر رادون تصاویری رنگی هستند که سه مؤلفه رنگی دارند. سپس تصویر رادون را با سایز $3 \times 50 \times 50$ (که ۳ تعداد مؤلفه‌های رنگی می‌باشد) را به بردارهای 3×2500 تبدیل می‌کنیم. حال با داشتن یک بردار 3×2500 تایی که نماینده هر یک از تصاویر رادون است به استخراج ویژگی می‌پردازیم. برای استخراج ویژگی از این بردار، ابتدا مؤلفه‌های R ، G و B آن را از هم جدا می‌کنیم. به دلیل این که این ابعاد برای الگوی فضایی مشترک بسیار بزرگ است، برای استخراج ویژگی توسط الگوهای فضایی مشترک یا CSP، این بردار 3×2500 تایی را به 20 پنجره مساوی تقسیم می‌کنیم، بنابراین هر پنجره دارای ابعاد 125 تایی است ($2500/20$). به عبارتی به جای داشتن یک بردار 3×2500 تایی، 20 بردار 125 تایی خواهیم داشت. سپس از هر یک از پنجره‌ها به صورت جداگانه ویژگی استخراج می‌کنیم، بردارهای ویژگی استخراج شده از این پنجره‌ها را در کنار یکدیگر قرار داده و بردار ویژگی نهایی را می‌سازیم. در نهایت با استفاده از یک شبکه عصبی پرسپترون چندلایه و روش نزدیک‌ترین همسایه (1-NN) به دسته‌بندی و تطبیق ویژگی پرداخته و عملکرد آنها را با یکدیگر مقایسه نمودیم.



شکل ۴: بلوک دیاگرام روش پیشنهادی.

ماتریس نگاشت با انتخاب تعداد کمی از بردارهای ویژه $U_m = (U_1, \dots, U_m, U_{N-m+1}, \dots, U_N)$ که در اینجا m کوچک است ($m \ll N$) به صورت زیر تعریف می‌شود

$$SF_a^s = U_m W \quad (26)$$

ماتریس تصویر شده نهایی به صورت زیر تعریف می‌شود

$$Z_a^s = SF_a^s X_a \quad (27)$$


پس از محاسبه Z_{is} برای $i = 1, \dots, 154$ باید ویژگی‌های مناسب از Z استخراج شوند. به عنوان گام آخر برای استخراج ویژگی جهت دسته‌بندی، لگاریتم تبدیل یافته واریانس نرمال شده Z را محاسبه می‌کنیم

$$f_i^k = \log \frac{\text{var } Z_{pi}^k}{\sum_{p=1}^m \text{var } Z_p} \quad (28)$$

هر سطر از ماتریس f_i^k یکی از ویژگی‌های استخراج شده مرتبط با i امین کلاس است. تعداد ویژگی‌های استخراج شده دو برابر بردارهای ویژه انتخاب شده است (آرگومان m).

۵- تطبیق ویژگی

هنگامی که ویژگی‌ها استخراج شدند با آنها به پایگاه داده هستند مقایسه شده و بر اساس این مقایسه تصمیم گرفته می‌شود. اساساً تصمیم‌گیری به این صورت است که اگر ویژگی‌های ورودی شبیه به یک مجموعه‌ای در پایگاه داده باشند، بر طبق آن تصویر شناسایی می‌شود و در غیر این صورت رد می‌شود [۳۲]. در این تحقیق دو روش شبکه عصبی پرسپترون چندلایه و روش نزدیک‌ترین همسایه (1-NN) برای

شکل ۶: مؤلفه‌های R ، G و B تصویر رادون.


($1-NN$) را برای دسته‌بندی و تطبیق ویژگی بررسی نمودیم. روش پیشنهادی به ازای هر دو کلاسه‌بند بر روی تعداد کلاس‌های مختلف شامل ۱۰، ۵۰، ۱۰۰ و ۱۵۴ کلاس بررسی گردید. در این مقاله برای ارزیابی روش‌های پیشنهادی از معیار TP^2 استفاده نموده‌ایم که از تقسیم تعداد داده‌های درست کلاسه‌بندی شده بر تعداد کل داده‌ها به دست می‌آید. شکل ۶ یک نمونه از تصاویر رادون را نشان می‌دهد که مؤلفه‌های R ، G و B این تصویر نمایش داده شده‌اند

$$TP = (29) \text{تعداد کل داده‌ها/تعداد داده‌های درست کلاسه‌بندی شده}$$

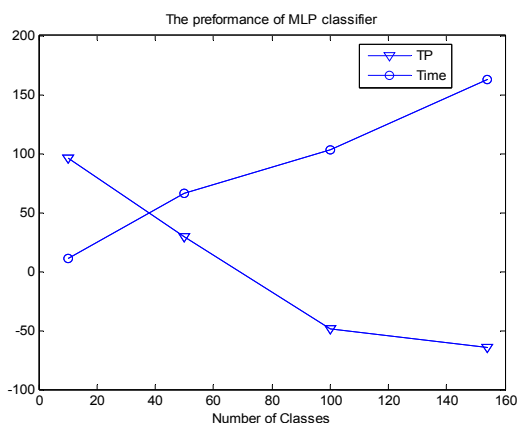
۷-۱ استفاده از شبکه عصبی پرسپترون چندلایه در کلاسه‌بندی

به عنوان الگوریتم تطبیق از یک شبکه عصبی MLP سه‌لایه استفاده نمودیم. به دلیل استفاده از یک لایه مخفی و بالابودن ابعاد داده ورودی، باید تعداد نودهای لایه مخفی را به قدر کافی زیاد در نظر بگیریم که در اینجا آن را هفت در نظر گرفته‌ایم. تعداد نودهای لایه خروجی نیز هشت است تا بتواند ۱۵۴ کلاس را به صورت باینری کد کند. همچنین برای کلاسه‌بندی ۱۰، ۵۰ و ۱۰۰ کلاس نیز تعداد نودهای لایه خروجی را به ترتیب چهار، شش و هفت در نظر گرفتیم تا بتوانیم داده‌های این کلاس‌ها را به صورت باینری کد کنیم. پس از استخراج ویژگی‌های مناسب و تشکیل بردار ویژگی نهایی، آن را به عنوان ورودی به این شبکه عصبی می‌دهیم. تعداد نودهای لایه ورودی برابر با طول بردار ویژگی می‌باشد و چون طول بردار ویژگی به تعداد پنجره‌ها بستگی دارد، بنابراین تعداد نودهای لایه ورودی برابر است با $W \times F$ که W تعداد پنجره‌های انتخاب‌شده و F تعداد ویژگی‌های استخراج‌شده از هر پنجره است. با فرض این که میزان خطای شبکه MLP با MSE نشان داده شود، نرخ موفقیت همان عملکرد شبکه MLP است که این میزان را با استفاده از فرمول $(1-MSE) \times 100$ به دست آورده‌ایم. برای تعداد کلاس‌های مختلف با تغییر ضریب یادگیری شبکه، بهترین حالت شبکه را انتخاب نموده‌ایم. در شکل ۷ عملکرد این کلاسه‌بند را به ازای تعداد کلاس‌های مختلف مشاهده می‌کنید.

همان طور که از شکل پیداست این شبکه تنها برای تعداد ۱۰ کلاس



شکل ۵: نمونه‌هایی از تصاویر موجود در پایگاه داده.




شکل ۷: نمایش عملکرد کلاسه‌بند MLP در روش CSP از لحاظ نرخ موفقیت و زمان مصرفی برای تعداد کلاس‌های مختلف.

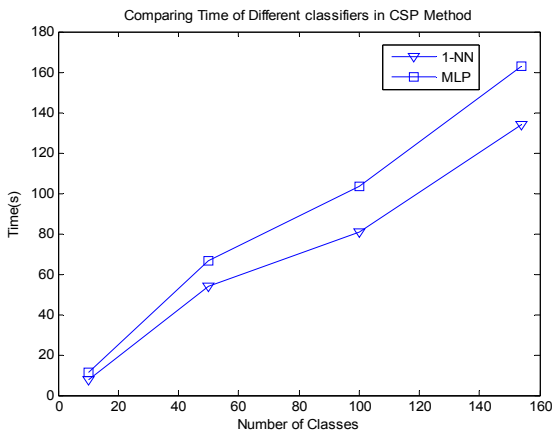
۷-۲ نتایج تجربی

این تحقیق بر روی مجموعه داده رگ انگشت که توسط آزمایشگاه هوش مصنوعی دانشگاه پکنینگ [۳۳] تهیه شده، آزمایش گردیده است. تعداد افرادی که تصاویر رگ انگشت از آنها تهیه شده ۲۰۰ نفر می‌باشند و تصاویر رگ انگشت از هشت انگشت هر فرد به دست آمده‌اند، همه تصاویر در فرمت bmp می‌باشند و تعداد کل تصاویر ۱۵۹۷ تصویر است. ۴۶ فایل از این تصاویر کیفیت خوبی نداشتند و این تصاویر توسط شخص آزمایش‌کننده نشان‌دار شده بودند. بنابراین در این پژوهش از تصاویر مربوط به ۱۵۴ نفر که در کیفیت مناسب هستند استفاده نمودیم. به این صورت که از هشت تصویر مربوط به هر فرد شش تا را برای آموزش و دو تا را برای تست استفاده نمودیم. بنابراین ۷۵٪ از داده‌ها برای آموزش سیستم و ۲۵٪ از آنها برای تست سیستم استفاده شدند. بنابراین مجموعه داده در مجموع شامل ۱۲۳۲ تصویر رگ انگشت در سایز 512×384 پیکسل می‌باشد. شکل ۵ مثال‌هایی از تصاویر مجموعه داده مورد استفاده را نشان می‌دهد.

همان طور که ذکر شد از آستانه آنتروپی محلی برای قطعه‌بندی تصاویر و استخراج الگوهای رگ استفاده و پس از آن تبدیل رادون را به تصاویر قطعه‌بندی شده اعمال نمودیم. سپس تصاویر رادون را به ۲۰ پنجره با ابعاد یکسان تقسیم کرده و روش CSP را به صورت جداگانه بر روی هر پنجره اعمال نموده و به استخراج ویژگی پرداختیم. با کنار هم قرار دادن بردارهای ویژگی هر یک از پنجره‌ها، بردار ویژگی نهایی را به دست آوردیم. در نهایت کلاسه‌بند MLP و روش نزدیک‌ترین همسایه



(الف)



(ب)

شکل ۱۱: مقایسه دو کلاسه‌بند، (الف) از لحاظ نرخ موفقیت و (ب) از لحاظ زمان مصرفی.


۲-۷ استفاده از روش نزدیک‌ترین همسایه (۱-NN) برای کلاسه‌بندی

به عنوان روش دیگری برای دسته‌بندی روش نزدیک‌ترین همسایه ۱-NN را مورد استفاده قرار دادیم. در این روش برای اندازه‌گیری فاصله داده تست از داده‌های آموزشی، از معیار شباهت منهن استفاده نمودیم. نتایج دسته‌بندی روش نزدیک‌ترین همسایه با استفاده از معیار شباهت منهن برای کلاس‌های مختلف در شکل ۱۰ قابل مشاهده است. همان طور که از شکل پیداست با استفاده از ۱-NN به عنوان کلاسه‌بند (روش ۱-NN-CSP) عملکرد خوبی حاصل شده و نرخ موفقیت برای تعداد کلاس‌های مختلف بالا است به طوری که برای تعداد ۵۰ و ۱۰۰ کلاس نرخ موفقیت ۱۰۰٪ و برای ۱۵۴ کلاس نیز نرخ موفقیت ۹۹٫۶۷۵۳٪ حاصل شده است.


۳-۷ مقایسه‌ای بین کلاسه‌بندهای ۱-NN و MLP

در این قسمت بین دو کلاسه‌بند ۱-NN و MLP از لحاظ دقت دسته‌بندی و زمان مصرفی مقایسه‌ای انجام شده است. در مورد دقت دسته‌بندی نشان داده می‌شود که روش ۱-NN می‌تواند دسته‌بندی مناسب‌تر و دقیق‌تری را نسبت به MLP انجام دهد.


در شکل ۱۱-الف مقایسه‌ای بین دقت دسته‌بندی این دو کلاسه‌بند به ازای ویژگی CSP انجام شده است. هنگامی که از ۱-NN برای دسته‌بندی داده‌ها در حالت ۱۵۴ کلاسه استفاده می‌کنیم، حدود ۱۳۵ ثانیه زمان صرف اجرای الگوریتم می‌شود. در حالی که از شبکه عصبی استفاده



شکل ۸: خطای شبکه MLP برای ۱۰ کلاس با در نظر گرفتن ۳۰۰ مرحله آموزشی (epoch=۳۰۰) در حالت ۲۰ پنجره‌ای با انتخاب سه الگوی فضایی در روش CSP در تست. (m=۳)



شکل ۹: خطای شبکه MLP برای ۱۵۴ کلاس با در نظر گرفتن ۳۰۰ مرحله آموزشی (epoch=۳۰۰) در حالت ۲۰ پنجره‌ای با انتخاب سه الگوی فضایی در روش CSP در تست. (m=۳)

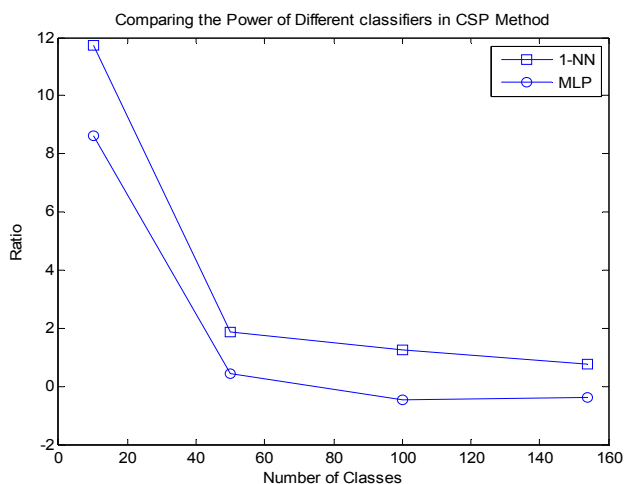


شکل ۱۰: نمایش عملکرد کلاسه‌بند ۱-NN در روش CSP از لحاظ نرخ موفقیت و زمان مصرفی برای تعداد کلاس‌های مختلف.

عملکرد خوبی دارد و توانسته است نرخ موفقیت ۹۵٫۶۶۱۲٪ را کسب کند اما با افزایش تعداد کلاس‌ها نرخ موفقیت با استفاده از MLP (روش CSPMLP) شدیداً کاهش یافته است به طوری که برای تعداد ۱۰۰ و ۱۵۴ کلاس نرخ موفقیت این شبکه منفی به دست آمده است. نمودار خطای این شبکه نیز برای ۱۰ و ۱۵۴ کلاس در شکل‌های ۸ و ۹ قابل مشاهده است.

جدول ۲: مقایسه نرخ موفقیت روش پیشنهادی با سایر روش‌های مطرح.

عملکرد	پایگاه داده (تعداد نمونه × انگشت)	مرجع	روش پیشنهادی
EER: %۰,۱۴۵	تصویر ۳۳۹×۲	[۱۰]	ردیابی مکرر خطوط
EER: %۰,۸	تصویر ۱×۷۰	[۱۹]	یادگیری منیقولد
TAR: %۹۹,۲	تصویر ۵۰×۱۰	[۳۴]	تبدیل رادون
EER: %۰,۷۶۱	تصویر ۵۰×۱۰	[۱۱]	نقاط مینوشیا
EER: %۰,۲۵	تصویر ۱۲۵×۹	[۱۲]	انحنای متوسط
TAR: %۹۵	تصویر ۷×۱۴	[۱۳]	نقاط با حداکثر انحنای
EER: %۰,۸۷	تصویر ۱۰۱۴×۵	[۱۴]	آشکارساز خط وسیع
TAR: %۹۹,۳۱	تصویر ۳۰×۵	[۱۵]	فیلتر گابور دوبعدی
TAR: %۹۹,۶۷۵۳	تصویر ۱۵۴×۸		CSP۱-NN



شکل ۱۲: نمایش کیفیت دو کلاسه‌بند بر اساس معیار Ratio.

جدول ۱: مقایسه عملکرد کلاسه‌بندهای MLP و 1-NN در روش CSP.

روش پیشنهادی اول (CSPMLP)		روش پیشنهادی دوم (CSP۱-NN)		تعداد کلاس‌ها
نرخ موفقیت (عملکرد شبکه بر حسب درصد)	زمان مصرفی (ثانیه)	نرخ موفقیت	زمان مصرفی (ثانیه)	
۹۵,۶۶۱۲	۱۱,۰۹۶۷۵۹	۹۰	۷,۶۶۳۴۳۲	۱۰
۰,۰۷				ضریب یادگیری شبکه
۲۹,۲۷۱۲	۶۶,۵۲۵۱۷۷	۱۰۰	۵۳,۸۵۵۱۱۸	۵۰
۰,۰۲				ضریب یادگیری شبکه
-۴۸,۵۴۶۱	۱۰۳,۱۵۸۷۹	۱۰۰	۸۰,۸۳۴۰۶۴	۱۰۰
۰,۰۱				ضریب یادگیری شبکه
-۶۴,۲۷۹۲	۱۶۲,۶۷۴۹۱	۹۹,۶۷۵۳	۱۳۴,۱۳۸۵۰	۱۵۴
۰,۱				ضریب یادگیری شبکه

است. EER و TAR از معیارهای مهم برای برآورد دقت سیستم‌های بیومترک هستند. EER بیانگر نرخ خطا است و معمولاً به صورت درصد بیان می‌شود و TAR نیز بیانگر نرخ پذیرش صحیح می‌باشد.

به طور کلی نتایج (جدول ۱ و ۲) نشان می‌دهند که روش پیشنهادی CSP۱-NN (استخراج ویژگی توسط الگوهای فضایی مشترک (CSP) و استفاده از 1-NN به عنوان کلاسه‌بند) در مقایسه با روش CSPMLP (استخراج ویژگی توسط الگوهای فضایی مشترک (CSP) و استفاده از MLP به عنوان کلاسه‌بند) و همچنین روش‌های ارائه شده در مقالات دیگر از نظر بالابودن نرخ شناسایی عملکرد بسیار خوبی دارد. این روش می‌تواند شناسایی افراد با رگ‌های انگشت دست را با یک نرخ موفقیت بالا (۹۹,۶۷۵۳ درصد) در یک زمان کوتاه (۱۶۲,۶۷۴۹۱ ثانیه) انجام دهد.

۸- نتیجه‌گیری

در این تحقیق روش جدیدی برای شناسایی افراد توسط رگ‌های خونی انگشت دست ارائه نمودیم که از آستانه آنتروپی محلی برای قطعه‌بندی و استخراج الگوهای رگ استفاده می‌کند. ایده اصلی این روش استفاده از الگوی فضایی مشترک برای استخراج ویژگی می‌باشد. این الگوریتم به تصاویری که قطعه‌بندی شده و به فضای رادون انتقال یافته‌اند اعمال می‌شود به این صورت که در روش پیشنهادی ابتدا الگوهای رگ را با اعمال آستانه آنتروپی استخراج می‌کنیم، با این روش رگ‌ها به خوبی استخراج می‌شوند اما مقداری نویزی هستند. به دلیل این که تبدیل رادون به علت داشتن ماهیت انتگرالی نسبت به نویز مقاومت بیشتری دارد بنابراین این تبدیل را بر روی تصاویر اعمال نمودیم. سپس تصاویر رادون را به پنجره‌هایی با ابعاد یکسان تقسیم نمودیم (۲۰ پنجره). با اعمال

نمودیم نیز زمان اجرای الگوریتم حدود ۱۶۳ ثانیه می‌باشد. بنابراین این دو کلاسه‌بند از لحاظ زمان مصرفی تقریباً عملکردی نزدیک به هم دارند اما نرخ موفقیت با استفاده از این دو کلاسه‌بند بسیار متفاوت است. بنابراین برای تخمین کیفیت هر کلاسه‌بند از معیار Ratio استفاده نموده‌ایم که از تقسیم نرخ موفقیت کلاسه‌بند بر زمان مصرفی آن حاصل می‌شود. در شکل ۱۲ کیفیت این دو کلاسه‌بند بر اساس معیار Ratio آمده است.

همان طور که در شکل ۱۲ می‌بینیم MLP در سطح پایین‌تری نسبت به 1-NN قرار دارد. بنابراین با توجه به شکل کاملاً مشخص است که استفاده از 1-NN به عنوان کلاسه‌بند مناسب‌تر می‌باشد زیرا 1-NN علاوه بر این که زمان مصرفی کمتری نسبت به MLP دارد، برای تعداد کلاس‌های مختلف نرخ موفقیت بالاتری نیز دارد.

نرخ موفقیت روش‌های پیشنهادی در جدول ۱ قابل مشاهده است. روش‌های پیشنهادی وابسته به نوع کلاسه‌بند، کارایی متفاوتی دارند. همان طور که قبلاً گفته شد در روش نزدیک‌ترین همسایه 1-NN از معیار شباهت منتهن استفاده شده است. در مورد شبکه MLP نیز نرخ موفقیت همان عملکرد و کارایی شبکه است. در روش CSPMLP نرخ موفقیت به ازای ضرایب یادگیری مختلف بررسی گردیده و برای تعداد کلاس‌های مختلف بیشینه نرخ موفقیت انتخاب شده است. در این جدول ضریب یادگیری مزبور که باعث بیشینه شدن شده است برای کلاس‌های مختلف آمده است.

در جدول ۲ نیز مقایسه‌ای بین روش پیشنهادی در این مقاله با سایر روش‌های مطرح بر اساس معیارهای ارزیابی EER^۱ و TAR^۲ انجام شده

1. Equal Error Rate
2. True Acceptance Rate

- [18] J. D. Wu and C. T. Liu, "Finger-vein pattern identification using principal component analysis and the neural network technique," *Expert Systems with Applications*, vol. 38, no. 5, pp. 5423-5427, May 2011.
- [19] Z. Liu, Y. H. Yin, H. Wang, S. Song, and Q. Li, "Finger vein recognition with manifold learning," *J. of Network and Computer Applications*, vol. 33, no. 3, pp. 275-282, May 2010.
- [20] J. D. Wu and C. T. Liu, "Finger-vein pattern identification using SVM and neural network technique," *Expert Systems with Applications*, vol. 38, no. 11, pp. 14284-14289, Oct. 2011.
- [21] T. Chanwimaluang and G. Fan, "An efficient blood vessel detection algorithm for retinal images using local entropy thresholding," in *Proc. of IEEE Int. Symp. on Circuits and Systems*, vol. 5, pp. 21-24, Bangkok, Thailand, Mar 2003.
- [22] N. R. Pal and S. K. Pal, "Entropic thresholding," *Signal Processing*, vol. 16, no. 2, pp. 97-108, Feb. 1989.
- [23] C. I. Chang, K. Chen, J. Wang, and M. L. G. Althouse, "A relative entropy-based approach to image thresholding," *Pattern Recognition*, vol. 27, no. 9, pp. 1275-1289, Sept. 1994.
- [24] A. Gavlasova and A. Prochazka, "Simulink modelling of radon and wavelet transforms for image feature extraction," in *Proc. Int. Conf. Technical Computing*, 7 pp., Prague, Czech Republic 2005.
- [25] A. Asad, S. A. M. Gilani, and U. Shafique, "Affine invariant feature extraction using a combination of Radon and wavelet transforms," T. Sobh (ed.), in *Innovations and Advanced Techniques in Computer and Information Sciences and Engineering*, pp. 93-97, 2013.
- [26] X. Jia, J. J. Cui, D. Y. Xue, and F. Pan, "An adaptive dorsal hand vein recognition algorithm based on optimized HMM," *J. of Computational Information Systems*, vol. 8, no. 8, pp. 313-322, 2012.
- [27] A. Kumar and Y. B. Zhou, "Human identification using finger images," *IEEE Trans. Image Process.*, vol. 21, no. 4, pp. 2228-2244, Apr. 2011.
- [28] *Radon Transform*, http://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/AV0405/HAYDEN/Slice_Reconstruction.html, Accessed on 1 Sept. 2014
- [29] S. Venturas and I. Flaounas, "Study of radon transformation and application of its inverse to NMR," Athenas, Available from cgi.di.uoa.gr/~erga/mobio/05/prj2/Flaounas_Venturas_Final.doc, 2005, Accessed on 19 October 2007.
- [30] J. Muller-Gerking, G. Pfurtscheller, and H. Flyvbjerg, "Designing optimal spatial filters for single-trial EEG classification in a movement task," *Clin. Neurophysiol.*, vol. 110, no. 5, pp. 787-798, May 1999.
- [31] E. Niedermeyer and F. H. L. D. Silva, *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*, Lippincott Williams & Wilkins, 2005.
- [32] S. Kulkarni and R. D. Raut, "Finger vein recognition," *IOSR J. of Electrical and Electronics Engineering*, vol. 2, pp. 32-36, 2014.
- [33] PKU Finger Vein Database (V4) from Peking University, <http://rate.pku.edu.cn/>.
- [34] J. D. Wu and S. H. Ye, "Driver identification using finger-vein patterns with radon transform and neural network," *Expert Syst. Appl.*, vol. 36, no. 3, pp. 5793-5799, Apr. 2009.

حمید حسن پور استاد تمام دانشکده مهندسی کامپیوتر دانشگاه شاهرود است. ایشان در سال ۱۳۷۲ مدرک کارشناسی مهندسی کامپیوتر خود را از دانشگاه علم و صنعت و در سال ۱۳۷۵ مدرک کارشناسی ارشد خود را در گرایش هوش ماشین از دانشگاه صنعتی امیرکبیر دریافت نمود. در سال ۱۳۸۳ موفق به اخذ مدرک دکتری خود از دانشگاه صنعتی کوئینزلند استرالیا در گرایش پردازش سیگنال شد. از سال ۱۳۸۴ الی ۱۳۸۶ نامبرده به عنوان عضو هیأت علمی در دانشکده مهندسی برق و کامپیوتر دانشگاه صنعتی بابل فعالیت داشت؛ سپس به دانشکده مهندسی کامپیوتر دانشگاه شاهرود انتقال یافت. زمینه‌های علمی مورد علاقه ایشان پردازش سیگنال، پردازش تصویر، داده‌کاوی، و پردازش متن می‌باشد.

اکرم غلامی در سال ۱۳۸۹ مدرک کارشناسی مهندسی فناوری اطلاعات و در سال ۱۳۹۲ مدرک کارشناسی ارشد مهندسی کامپیوتر خود را از دانشگاه صنعتی شاهرود دریافت نمود. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: پردازش تصویر و شبکه عصبی.

CSP بر روی هر کدام از این پنجره‌ها به صورت جداگانه بردار ویژگی مربوط به هر پنجره را استخراج نموده و از کنار هم قرار دادن تمام بردارهای ویژگی استخراج شده، بردار ویژگی نهایی را تشکیل دادیم. در نهایت با استفاده از کلاسه‌بند MLP و روش نزدیک‌ترین همسایه (1-NN) به دسته‌بندی داده‌ها پرداختیم. نتایج تجربی نشان داد که روش پیشنهادی CSP-NN (استخراج ویژگی توسط الگوهای فضایی مشترک (CSP) و استفاده از 1-NN به عنوان کلاسه‌بند) عملکرد خوبی در شناسایی افراد از طریق رگ‌های انگشت دست دارد و عمل شناسایی را در یک زمان کوتاه با نرخ ۹۹/۶۷۵۳٪ به صورت صحیح انجام می‌دهد.

مراجع

- [1] X. J. Meng, G. P. Yang, Y. L. Yin, and R. Y. Xiao, "Finger vein recognition based on local directional code," *Sensors*, vol. 12, no. 12, pp. 14937-14952, Nov. 2012.
- [2] K. Park, "Finger vein recognition by combining global and local feature base on SVM," *Computing and Informatics*, vol. 30, no. 2, pp. 295-309, Apr. 2011.
- [3] G. P. Yang, X. M. Xi, and Y. L. Yin, "Finger vein recognition based on (2D) 2PCA and metric learning," *J. Biomed. Biotechnol.*, vol. 2012, 9 pp., Mar. 2012.
- [4] G. P. Yang, X. M. Xi, and Y. L. Yin, "Finger vein recognition based on a personalized best bit map," *Sensors*, vol. 12, no. 2, pp. 1738-1757, Feb. 2012.
- [5] J. D. Wu and C. T. Liu, "Finger-vein pattern identification using principal component analysis and the neural network technique," *Expert Syst.*, vol. 38, no. 5, pp. 5423-5427, May 2011.
- [6] C. B. Yu, D. M. Zhang, and H. B. Li, "Finger vein image enhancement based on multi-threshold fuzzy algorithm," in *Proc. of the 2nd Int. Congress on Image and Signal Processing, CISP'09*, 3 pp., Tianjin, China, Oct. 2009.
- [7] J. F. Yang and J. L. Yang, "Multi-channel Gabor finger design for finger vein image enhancement," in *Proc. of the 5th International Conf. on Image and Graphics, ICIG'09*, pp. 87-91, Xi'an, China, Sept. 2009.
- [8] J. F. Yang and M. F. Yan, "An improved method for finger-vein image enhancement," in *Proc. of the 2010 IEEE 10th Int. Conf. on Signal Processing*, pp. 1706-1709, Beijing, China, Oct. 2010.
- [9] J. F. Yang, J. L. Yang, and Y. H. Shi, "Combination of Gabor wavelets and circular Gabor filter for finger-vein extraction," in *Proc. of the 5th Int. Conf. on Emerging Intelligent Computing Technology and Applications*, pp. 346-354, Ulsan, Korea, Sept. 2009.
- [10] N. Miura, A. Nagasaka, and T. Miyatake, "Feature extraction of finger-vein patterns based on repeated line tracking and its application to personal identification," *Mach. Vis. Appl.*, vol. 15, no. 4, pp. 194-203, Oct. 2004.
- [11] C. B. Yu, H. F. Qin, L. Zhang, and Y. Z. Cui, "Finger-vein image recognition combining modified Hausdorff distance with minutiae feature matching," *Interdisciplinary Sciences: Computational Life Sciences*, vol. 1, no. 4, pp. 280-289, Dec. 2009.
- [12] W. Song, T. Kim, H. C. Kim, J. H. Choi, H. J. Kong, and S. R. Lee, "A finger-vein verification system using mean curvature," *Pattern Recogn. Lett.*, vol. 32, no. 11, pp. 1541-1547, Aug. 2011.
- [13] N. Miura, A. Nagasaka, and T. Miyatake, "Extraction of finger-vein patterns using maximum curvature points in image profiles," in *Proc. of the 9th IAPR Conf. on Machine Vision Applications, MVA'05*, pp. 347-350, Tsukuba, Japan, May 2005.
- [14] B. N. Huang, Y. G. Dai, and R. F. Li, "Finger-vein authentication based on wide line detector and pattern normalization," in *Proc. of the 20th Int. Conf. on Pattern Recognition*, pp. 1269-1272, Istanbul, Turkey, Aug. 2010.
- [15] K. J. Wang, J. Y. Liu, P. Popoola Oluwatoyin, and W. X. Feng, "Finger vein identification based on 2-D Gabor filter," in *Proc. of the 2nd Int. Conf. on Industrial Mechatronics and Automation*, pp. 10-13, Wuhan, China, May 2010.
- [16] B. A. Rosdi, C. W. Shing, and S. A. Suandi, "Finger vein recognition using local line binary pattern," *Sensors*, vol. 11, no. 12, pp. 11357-11371, Nov. 2011.
- [17] E. C. Lee, H. Jung, and D. Kim, "New finger biometric method using near infrared imaging," *Sensors*, vol. 11, no. 3, pp. 2319-2333, Feb. 2011.