

معرفی یک روش ترکیبی برای شناسایی اتوماتیک بازوفیل ها در تصاویر هماتولوژی

سید حمید رضا توفیقی*¹، رضا آقائی زاده¹، ظروفی¹، حمید سلطانیان زاده¹، کارو لوکاس¹ و رضاعلی شریفیان²

¹قطب علمی کنترل و پردازش هوشمند، دانشکده مهندسی برق و کامپیوتر، دانشگاه تهران

²دانشکده علوم پزشکی، دانشگاه تهران

*E-mail:h.tofighi@ece.ut.ac.ir

چکیده

همه روزه میلیون ها گلبول های سفید خون توسط متخصصین هماتولوژی، بطور دستی و توسط میکروسکوپ در آزمایشگاههای هماتولوژی شناسایی و دسته بندی می شوند؛ که این وظیفه، یک کار بسیار طاقت فرسا و زمانگیر است. شناسایی و شمارش افتراقی اتوماتیک گلبول های سفید خون، می تواند به هماتولوژیست در تصمیم گیری و همچنین تسریع در عملیات هماتولوژی کمک نماید. در این مقاله یک روش ترکیبی معرفی شده است که بر پایه این روش، بازوفیلها از سایر گلبول های سفید بطور اتوماتیک جدا می شوند. برای این منظور، ابتدا هسته گلبولهای سفید خون توسط روش گرام اشमित بخش بندی شده است. سپس با استخراج ویژگیهای بافتی با استفاده از ماتریس Co-occurrence و ویژگی های شکلی از نواحی بخش بندی شده، سعی بر جدا سازی گلبول های سفید خون شده است. در این مقاله به منظور کاهش بعد بردار ویژگی، از روش forward sequential selection (FSS) و به منظور طبقه بندی این ویژگی ها، از دو دسته بندی کننده پرسپترون چند لایه (MLP) و سیستم استنباط نوروفازی تطبیقی (ANFIS) استفاده شده است. نتایج بدست آمده، نشان دهنده برتری سیستم استنباط نوروفازی تطبیقی نسبت به پرسپترون چند لایه بوده است.

کلمات کلیدی - گلبول های سفید خون، گرام اشमित، آنالیز بافت، انتخاب ویژگی، سیستم استنباط نوروفازی تطبیقی.

۱- مقدمه

سریع این بیماریها در درمان آنها تأثیر بسزایی دارد. اینکار توسط متخصصین هماتولوژی و از طریق ارزیابی وضعیت سلولهای خونی و مغز استخوان بخصوص ارزیابی گلبول های سفید در زیر میکروسکوپ، صورت میگیرد. بعضی از این وظایف مانند شمارش افتراقی تعداد سلولها، کاری بسیار طاقت فرسا، زمان گیر و مستلزم پذیرفتن درصدی خطا است. اتوماتیک کردن برخی از وظایف مشروح، می تواند به هماتولوژیست در تصمیم گیری و همچنین تسریع در عملیات هماتولوژی کمک نماید. از جمله این وظایف، شناسایی اتوماتیک گلبول های سفید خون می باشد.

سیستم ایمنی یکی از مهمترین سیستمهای دفاعی بدن انسان در برابر عوامل خارجی نظیر میکروبهها، ویروسها و غیره می باشد. بیماری هایی نظیر ایدز و انواع سرطانهای خونی از جمله بیماریهایی هستند که تغییراتی در یکی از مهمترین اجزای سیستم ایمنی، یعنی گلبول های سفید خون ایجاد می نمایند. سرطانهای خون نظیر انواع لوسمی ها از شایعترین سرطانها در جهان و بخصوص در کشورمان می باشد. تشخیص به موقع و

در آزمایشگاههای هماتولوژی معمولاً دو نوع لام مورد بررسی قرار می گیرد:

۱- لامهای مربوط به خون محیطی

۲- لامهای مربوط به مغز استخوان

که هر کدام از این لامها اطلاعات تشخیصی خاصی را در اختیار هماتولوژیست می گذارد.

بطور کلی پنج نوع متفاوت گلبول سفید به طور طبیعی در لامهای خون محیطی در یک شخص سالم دیده می شود. این گلبول ها عبارتند از نوتروفیل‌های چند هسته ای، ائوزینوفیل‌های چند هسته ای، بازوفیل‌های چند هسته ای، مونوسیت‌ها و لنفوسیت‌ها [1]. با توجه به اینکه لامهای خون محیطی اطلاعات اولیه در مورد بیمار نظیر اینکه شخص مورد نظر سالم است یا اینکه مشکوک به نوعی لوسمی است را در اختیار هماتولوژیست خواهد گذاشت؛ آنالیز لامهای خون محیطی یکی از ابتدایی ترین و مهمترین مراحل تشخیصی در آزمایشگاههای هماتولوژی خواهد بود.

در بحث شناسایی اتوماتیک گلبول های سفید خون، بخش بندی اجزای گلبول سفید خون از دشوارترین مراحل در این آنالیز می باشد. اعم فعالیت مقالات در این زمینه، در جهت بخش بندی هر چه بهتر هسته و سیتوپلاسم گلبول سفید بوده است که به نتایج متفاوتی قابل قبولی در این زمینه دست یافته اند. در مقالات [2-4] بر اساس ویژگی رنگ و با استفاده از روشهای آستانه گیری از هیستوگرام و غیره، سعی بر بخش بندی هسته و سیتوپلاسم داشته اند. در یکی دیگر از مقالات [5] با استفاده از روش Fuzzy Clustering و دسته بندی کننده بیض (Bayes classifier) موفق به بخش بندی هسته گلبول های سفید خون از سایر اجزای تصویر شده است. در یکی از مقالات جدید [6]، با استفاده از تکنیک جدید تصویر برداری چند طیفی به نتایج بسیار قابل قبولی در زمینه بخش بندی دست یافته اند؛ ولی متأسفانه سیستم تصویر برداری چند طیفی با استفاده از میکروسکوپ در کشورمان موجود نمی باشد و دستیابی به چنین سیستمی مستلزم پرداخت هزینه های گزافی خواهد بود. مقاله [7] و [8] برترتیب بر اساس تکنیکهای Watershed و Snake و مقاله [9] بوسیله ترکیب این دو تکنیک و در نهایت مقالات [10,11] با استفاده از دیگر تکنیک های فازی، با دقتی محدود موفق به بخش بندی گلبول سفید در این تصاویر شده اند.

برای استخراج ویژگی، مقالات [4] و [12-14] به استخراج انواع ویژگی ها بر پایه شکل و ویژگی های بافتی اشاره می کنند. در مقاله [15] با استفاده از تبدیل موجک ویژگی بافتی مناسبی را از تصاویر پاتولوژی پروستات استخراج نموده است که می توان از این روش برای استخراج ویژگی بافتی بخصوص از هسته گلبول سفید در تصاویر هماتولوژی سود جست.

در بیشتر مقالات از دسته بندی کننده های شبکه عصبی استفاده شده است؛ که از جمله آن می توان شبکه های عصبی نظیر Local Linear Feed-Forward Backpropagation، Fuzzy Cellular Neural Network و Map(LLM) [16] را نام برد. در مقالات جدیدی که در سالهای اخیر به چاپ رسیده است از دسته بندی کننده Support Vector Machines (SVM) استفاده شده است که بعنوان مثال می توان به استفاده از این دسته بندی کننده در مقاله [6] اشاره نمود.

در این مقاله از روش گرام اشمیت، جهت بخش بندی هسته گلبول های سفید خون محیطی استفاده شده است. این روش، روشی ساده ولی در عین حال بسیار موثر و سریع در بخش بندی هسته گلبول های سفید می باشد. نتایج بدست آمده، حاکی از موثر بودن و سریع بودن این روش، نسبت به سایر روش ها می باشد.

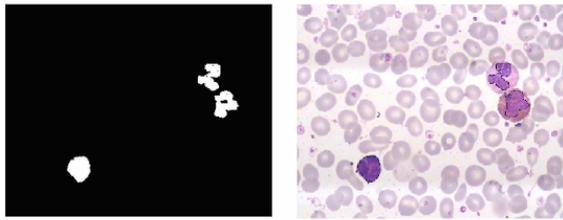
به علت اینکه هسته و سیتوپلاسم کلاس بازوفیل ها در نمونه های مورد پردازش، در اثر ماهیت این نوع گلبول ها سفید، با هم دیده می شود و نمی توان آنها را از هم جدا نمود، بنابراین پس از پردازش روش گرام اشمیت، باید این نوع از گلبول های سفید از سایر گلبول های سفید جدا گردد و در مراحل بعد، با استفاده از روش های دیگر، سیتوپلاسم سایر کلاس ها را بخش بندی نمود. برای جداسازی بازوفیل ها از سایر گلبول های سفید، لازم بود که از نواحی بخش بندی شده، ویژگیهایی استخراج شود. در این مقاله، ویژگی های استخراجی بر اساس ویژگی های بافتی (textural features) می باشد که از ماتریسهای Co-occurrence بدست می آید؛ این ویژگی ها شامل ۱۴ ویژگی می باشد. همچنین از دو ویژگی ساده شکلی (Morphological features)، شامل مساحت و معیار دایره گون بودن (Roundness feature) ناحیه بخش بندی شده، استفاده شده است.

به منظور کاهش بعد بردار ویژگی و انتخاب بهترین ویژگی ها از روش forward sequential selection (FSS) استفاده شده است. بوسیله این روش، بعد ویژگی ها را به ۵ ویژگی کاهش دادیم، بطوریکه بهترین افتراق را بین دو کلاس با این تعداد ویژگی داشته باشیم. در پایان از دو دسته بندی کننده پرسپترون چند لایه (MLP) و سیستم استنباط نوروفازی تطبیقی (ANFIS) استفاده شده است که نتایج این دو دسته بندی کننده با هم مقایسه شده است.

۲- مشخصات داده ها

تمامی نمونه ها از گلبول های سفید موجود در خون محیطی یک شخص نرمال گرفته شده است و حدود ۱۰۰ لام برای بدست آوردن ۲۵۱ نمونه، مورد بررسی قرار گرفته است. لامهای مورد

نواحی مطلوب بدست می آیند. نتیجه حاصل از بخش بندی در شکل ۲ نشان داده شده است.



شکل ۲: الف) تصویر سمت چپ، تصویر بدست آمده بعد از اعمال آستانه گیری و پس پردازش ب) تصویر کردن مرز نواحی بخش بندی شده بر روی تصویر اصلی

نتایج بدست آمده توسط این روش، با نتایج نواحی مشخص شده توسط متخصص، مقایسه شده است. برای ارزیابی نتایج بدست آمده، ما از مدل ارزیابی زیر استفاده کردیم:

$$Ts = \frac{(A_{program} \& A_{expert})}{\max(A_{program}, A_{expert})} \quad (1)$$

که در این معیار، $A_{program}$ ناحیه بخش بندی شده توسط برنامه و A_{expert} ناحیه مشخص شده توسط متخصص است. توسط این روش ما توانستیم به $Ts = 88.92\%$ دست یابیم.

۲-۲- استخراج ویژگی از نواحی بخش بندی شده

در این مرحله، هدف ما جداسازی کلاس بازوفیل از سایر کلاس های گلبول سفید می باشد. همانطور که اشاره شد، بازوفیلها در تصاویر به گونه ای رخ می دهد که سیتوپلاسم و هسته آن با هم است و نمی توان آنها را از هم جدا نمود، بنابراین در مرحله بخش بندی هسته به طور کامل بخش بندی میشوند و نیاز ندارد به مرحله بعدی یعنی بخش بندی سیتوپلاسم بروند. در نتیجه نیاز است یک جداسازی بین بازوفیل ها و سایر کلاس ها بر اساس اطلاعات بدست آمده در این مرحله، انجام شود. برای اینکار از ویژگی های بافتی (Textural features) و ویژگی های شکلی (Morphological features) جهت این جداسازی استفاده شده است. این ویژگی بر پایه کمی کردن ویژگی هایی است که یک متخصص از این تصاویر استخراج می کند.

ویژگی های شکلی استخراجی در این مرحله شامل دو ویژگی مساحت و معیار دایره گون بودن (Roundness) ناحیه بخش بندی شده می باشد. معیار دایره گون بودن ناحیه بخش بندی شده به صورت زیر تعریف می شود:

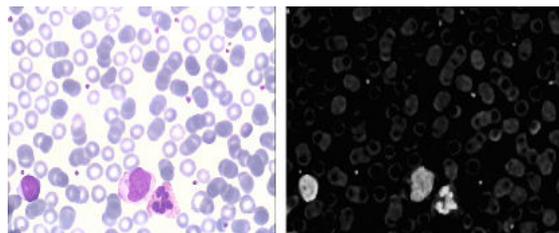
بررسی، همگی توسط Right & Gimsa رنگ آمیزی شده است و تصاویر توسط میکروسکوپ نوری و با استفاده از لنز با قدرت بزرگنمایی ۱۰۰ برابر همراه با ایمرسیون روغن، اخذ شده است.

تمامی پیاده سازی ها بر روی تصاویری انجام شده است که از میکروسکوپ نوری Microscope - Axioskop40 و توسط دوربین دیجیتال Digital Camera - Sony-Model No.SSC-DC50AP موجود در بیمارستان امام خمینی (ره) بدست آمده است. تمام این تصاویر، تصاویر رنگی 24-bit با سایز 576×720 می باشد. این تصاویر توسط متخصص هماتولوژیست به ۵ کلاس نوتروفیلهای چند هسته ای، ائوزینوفیلهای چند هسته ای، بازوفیلهای چند هسته ای، مونوسیتها و لنفوسیتها دسته بندی شده است.

۳- روش ها

۳-۱- بخش بندی هسته توسط روش گرام اشمیت

برای استفاده از این روش در این کاربرد، مقادیر RGB برای هر کدام از پیکسل های تصویر، به عنوان یک بردار در فضای RGB در نظر گرفته شده است. سپس با استفاده از روش گرام اشمیت برداری بدست می آید [17] که ضرب داخلی این بردار در مقادیر RGB پیکسل های تصویر، تصویری ایجاد میکند که هسته گلبول های سفید، شدت روشنایی بالاتری را نسبت به سایر اجزای تصویر نظیر پس زمینه، گلبول های قرمز و سیتوپلاسم، خواهد داشت (شکل ۱).



شکل ۱: الف) تصویر سمت چپ، یک تصویر نمونه ب) تصویر سمت راست، تصویر حاصل، بعد از اعمال روش گرام اشمیت

برای بخش بندی هسته از تصویر حاصل، یک آستانه با استفاده از ارزیابی میانگین و ماکزیمم مقدار تصویر مربوطه، انتخاب میشود. چون در این تصاویر یکسری اجزاء همرنگ با هسته نظیر پلاکتها و ضایعات رنگی وجود دارند (همانطور که در شکل ۱ مشاهده می کنید)، بنابراین پس از مرحله آستانه گیری، نواحی کوچکی بوجود می آیند، که جزء هسته نیستند و لی بخاطر تشابه رنگی، تشخیص داده می شوند. چون این نواحی از هسته بسیار کوچکتر هستند، بنابراین با حذف اجزای کوچک،

(redundant features)، عملکرد دسته بندی کننده بهبود می یابد [4].

برای انتخاب ویژگی لازم است که یک تابع تمایز برای میزان افتراق بین کلاس ها تعریف کرد. در این مقاله از معیار Fisher's discriminant ratio (FDR) بعنوان تابع تمایز استفاده شده است. این معیار برای دو کلاس به صورت زیر تعریف می شود:

$$FDR = \frac{(\mu_1 - \mu_2)^2}{(\sigma_1^2 + \sigma_2^2)} \quad (5)$$

که μ_1 و σ_1 بترتیب بیانگر میانگین و واریانس بردار ویژگی کلاس ۱ و μ_2 و σ_2 بیانگر میانگین و واریانس بردار ویژگی کلاس ۲ می باشد [18].

۳-۳-۱ روش FORWARD SEARCH (FSS) SEQUENTIAL

در این روش ابتدا از یک ویژگی شروع می کنیم. این ویژگی به گونه ای انتخاب می شود که با استفاده از توابع تمایز، ویژگی که بهترین میزان افتراق را نسبت به دیگر ویژگی ها دارد، انتخاب می شود. سپس تمام جفت ویژگی هایی که شامل ویژگی انتخاب شده در مرحله قبل هست را به توابع تمایز می دهیم و بهترین دوتایی از ویژگی ها را انتخاب می کنیم. سپس بهترین ۳ تایی که شامل دو ویژگی محاسبه شده در مرحله عمل است را حساب می کنیم و الگوریتم را تا جای پیش می بریم که بهترین m تایی از ویژگی ها انتخاب شود [18].

با استفاده از این روش، در این مقاله، از ۱۶ ویژگی بدست آمده، ۵ تا از بهترین ویژگی ها در این مرحله انتخاب شد.

۳-۴-۲ دسته بندی کننده (Classifier)

در این مرحله از دو دسته بندی کننده برای دسته بندی کردن کلاس ها استفاده شده است.

۳-۴-۱ شبکه عصبی مصنوعی

در این قسمت از یک پرسپترون چند لایه (MLP) با یک لایه مخفی استفاده شده است. تعداد نورون های لایه مخفی برابر ۴۰ و تعداد نرونهای خروجی برابر ۱ در نظر گرفته شده است. تابع عبوری (Transfer function) در هر دو لایه تابع تانژانت سیگموئید (tangent sigmoid) می باشد. در صورت ۱ شدن خروجی، نمونه مورد بررسی از کلاس بازوفیل و در غیر این صورت از کلاس غیر بازو فیل می باشد.

$$\gamma = \frac{P^2}{4\pi A} \quad (2)$$

۳-۲-۱ استخراج ویژگی با استفاده از

CO-OCCURRENCE های ماتریس

آنالیز بافت بطور گسترده ای در بخش بندی تصویر (Image segmentation)، آنالیز شکل (Shape analysis)، شناسایی و دسته بندی اجزای تصاویر بکار می رود. بسیاری از ویژگی های بافتی را می توان با استفاده از ماتریس های Co-occurrence تخمین زد. این ماتریس، بیانگر یک توزیع احتمال توأم از اجزای دو بعدی تصویر در یک جهت و فاصله مشخص شده، می باشد [4].

برای محاسبه ماتریس GLMC (در این مقاله با A نمایش داده شده است) باید دو پارامتر را مشخص شود؛ یکی پارامتر زاویه θ و دیگری پارامتر گام d. در این مقاله $d=1$ فرض شده است و ماتریس A را برای زوایای ۰، ۴۵، ۹۰ و ۱۳۵ درجه حساب شده است. عناصر ماتریس A به صورت زیر بدست می آیند:

$$A = \frac{1}{R} \begin{bmatrix} \eta(0,0) & \eta(0,1) & \eta(0,2) & \eta(0,3) \\ \eta(1,0) & \eta(1,1) & \eta(1,2) & \eta(1,3) \\ \eta(2,0) & \eta(2,1) & \eta(2,2) & \eta(2,3) \\ \eta(3,0) & \eta(3,1) & \eta(3,2) & \eta(3,3) \end{bmatrix} \quad (3)$$

که $\eta(I_1, I_2)$ بیانگر تعداد پیکسل هایی است که اگر یک پیکسل شدت I1 داشته باشد اگر به اندازه d و درجه θ از آن پیکسل حرکت کنیم، شدت روشنایی پیکسل بدست آمده I2 باشد.

برای اینکه این ویژگی انتخابی نسبت به زاویه حساس نباشد نسبت به زوایای مختلف از ماتریس GLMC میانگیری می شود.

$$P_{iso} = \sum_{\theta=0,45,90,135} \frac{(p_{\theta} + p_{\theta}^T)}{8} \quad (4)$$

که در اینجا $P_{\theta} = \frac{\eta(I_1, I_2)}{R}$ می باشد [4] و [18].

در این مقاله ۱۴ نوع ویژگی با استفاده از این ماتریس میانگیری شده استخراج میشود.

۳-۳ انتخاب ویژگی

انتخاب ویژگی یکی از مهمترین مراحل در کاهش بعد فضایی ویژگی های انتخاب شده می باشد؛ به گونه ای که بهترین ویژگیها با بیشترین افتراق بین کلاس حاصل گردد. نشان داده شده است که اغلب در اثر حذف ویژگی های اضافی

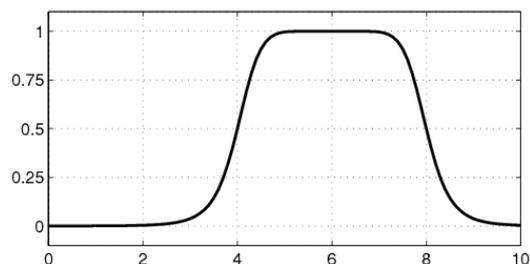
۳-۴-۲- شبکه استنباط عصبی - فازی تطبیقی (ANFIS)

انتشار خطا، پارامترهای لایه اول تنظیم می شوند. این عمل تا محقق شدن شرط توقف، ادامه می یابد.

شبکه ANFIS در این مقاله به همین شکل آموزش داده شده است. به عنوان ورودی همان ۵ ویژگی انتخاب شده در مرحله انتخاب ویژگی به این شبکه داده شده است. در این مرحله تعداد مجموعه های تعلق برای هر ورودی به صورت زیر تنظیم شده است:

$$\text{numMFs} = [2 \ 2 \ 3 \ 2 \ 2]^T$$

برای انتخاب نوع تابع عضویت، انواع توابع عضویت امتحان گردید؛ ولی در این کاربرد، تابع عضویت زنگی شکل (Generalized bell-shaped membership function) بهترین نتیجه را در برداشت. این تابع به صورت زیر تعریف می گردد.



شکل ۴. نمایی از یک Generalized bell-shaped membership function

$$f(x, a, b, c) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}} \quad (6)$$

به این ترتیب، در صورت ۱ شدن خروجی، نمونه مورد بررسی از کلاس بازوفیل و در غیر این صورت از کلاس غیر بازوفیل می باشد.

۴- نتایج بدست آمده

جدول ۱ بیانگر نتایج عملکرد دو دسته بندی کننده برای افتراق بین کلاس بازوفیل و کلاس غیر بازوفیل می باشد. در این جدول از سه معیار Sensitivity، Specificity و Accuracy، جهت بیان قدرت دسته بندی کننده استفاده شده است.

جدول (۱): نتایج بدست آمده

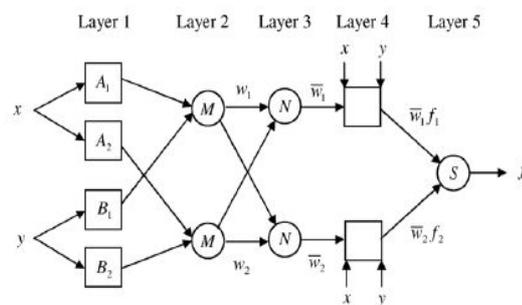
Classifier	True Positive	False Negative	True Negative	False Positive	Sensitivity	Specificity	Accuracy
MLP	47/50	3/50	160/160	0/160	94%	100%	98.57 %
ANFIS	48/20	2/50	160/160	0/160	96%	100%	98.89%

این شبکه یک مدل Sugeno می باشد که امکان یادگیری و تطبیق دارد. برای ارائه این مدل، فرض کنیم قوانین اگر- آنگاه را برای دو ورودی به صورت زیر داریم:

Rule 1: If (x is A1) and (y is B1) then
(f1 = p1x + q1y + r1)

Rule 2: If (x is A2) and (y is B2) then
(f2 = p2x + q2y + r2)

که در آن x و y ورودی، A و B مجموعه های فازی می باشند. در شکل ۳ می توان نمایی از این سیستم را ملاحظه نمود. در این سیستم گره هایی که با دایره نمایش داده شده اند، ثابت هستند و گره هایی که با مربع نمایش داده شده اند دارای پارامترهایی می باشند که می باید آموزش داده شوند. لایه اول شامل گره های تطبیقی است و در عمل میزان تعلق ورودی را به یک مجموعه فازی بدست می آورد. پارامترهای مربوط به این گره ها، همان پارامترهای توابع عضویت گوناگون می باشند. لایه دوم، یک گره ثابت است و در واقع نقش AND را در قوانین اگر- آنگاه اجرا می کند که در این مورد توسط ضرب کردن این عمل را انجام می دهد. لایه سوم در واقع یک نرمالیزاسیون را بر روی خروجی لایه های قبل انجام می دهد. خروجی لایه چهارم در واقع یک تابع خطی از خروجیهای لایه قبل می باشد که پارامترهای این تابع تحت آموزش قرار می گیرند [19].



شکل ۳: نمایی از یک ANFIS با دو ورودی [19]

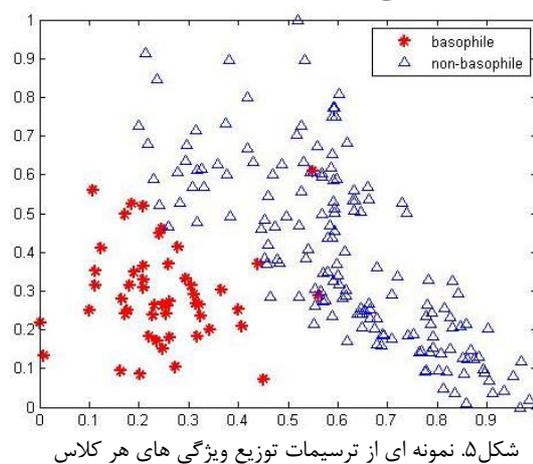
در روش یادگیری این شبکه که به روش هیبرید (Hybrid) موسوم است، ابتدا با فرض ثابت بودن پارامترهای لایه اول، توسط الگوریتم LMS پارامترهای لایه چهارم بدست می آیند و سپس با جایگذاری این پارامترها و فرض ثابت بودن آنها با الگوریتم پس

که ما را در جمع آوری این تصاویر یاری نمودند، کمال سپاسگزاری را داریم.

مراجع

- [1] G. Guyton, G. E. Hall, "Textbook Of Medical Physiology," *E-Book*, 2005.
- [2] J. Angulo, G. Flandrin, "Automated detection of working area of peripheral blood smears using mathematical morphology," *Analytical Cellular Pathology*, vol. 25, pp. 37-49, 2003.
- [3] J. WU, P. Zeng, Y. Zhou, C. Oliver, "A novel color image segmentation method and its application to white blood cell image analysis," *ICSP*, 2006.
- [4] D. M. U. Sabino, L. d. F. Costa, E. G. Rizzatti, M. A. Zago, "A texture approach to leukocyte recognition," *Real-Time Imaging*, vol. 10, pp. 205-216, 2004.
- [5] N. T. Umpon, "Patch-based white blood cell nucleus segmentation using fuzzy clustering," *ECTI Trans. Electrical. Electronic. Communications*, vol. 3, No. 1, pp. 5-10, 2005.
- [6] N. Guo, L. Zeng, Q. Wu, "A method based on multi-spectral imaging technique for white blood cell segmentation," *Computers in Biology and Medicine*, vol. 37, pp. 70-76, 2006.
- [7] K. Jiang, Q. M. Liao, S. Y. Dai, "A novel white blood cell segmentation scheme using scale-space filtering and watershed clustering," *Proceedings of the Second International Conference on Machine Learning and Cybernetics*, pp. 2820-2825, 2003.
- [8] F. Zamani, R. Safabakhsh, "An unsupervised GVF snake approach for white blood cell segmentation based on nucleus," *ICSP*, 2006.
- [9] J. Park, J. M. Keller, "Snakes on the watershed," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 23, No. 10, 2001.
- [10] E. Montseny, P. Sobrevilla, S. Romani, "A fuzzy approach to white blood cells segmentation in color bone marrow images," *IEEE Int. Conf. on Fuzzy Systems*, pp. 173-178, 2004.
- [11] W. Shitong, W. Min, "A new detection algorithm (NDA) based on fuzzy cellular neural networks for white blood cell detection," *IEEE Trans. Inf. Technol. Biomed.*, vol. 10, No. 1, pp. 5-10, 2006.
- [12] J. P. Thiran, B. Macq, "Morphological feature extraction for the classification of digital images of cancerous tissues," *IEEE Trans. Bio. Med. Eng.*, vol. 43, No. 10, pp. 1011-1020, 1996.
- [13] W. He, J. Wilder, "Nucleus shape recognition for an automated hematology analyzing system," *Proceeding of the second Joint EMBS/BMES conference*, pp. 1043-1044, 2002.
- [14] N. T. Umpon, S. Dhompongsa, "Morphological granulometric features of nucleus in automatic bone marrow white blood cell classification," *IEEE Trans. Inf. Technol. Biomed.*, vol. 11, No. 3, pp. 353-359, 2007.
- [15] R. Farjam, H. Soltanian-Zadeh, K. Jafari-Khouzani, R. A. Zoroofi, "An image analysis approach for automatic malignancy determination of prostate pathological images," *Cytometry. B Clin. Cytom.*, vol. 72, No. 4, pp. 227-240, 2007.

همانطور که از نتایج مشخص است، در هر دو دسته بندی کننده بعضی از نمونه های کلاس بازوفیل به اشتباه جزء کلاس غیر بازوفیل شناخته شده اند ولی تمامی نمونه های کلاس غیر بازوفیل به درستی تشخیص داده شده اند و این به دلیل شباهت بسیار زیاد شکلی و بافتی برخی از این بازوفیل ها با نمونه های غیر بازوفیل می باشد. همچنین برای ارزیابی دقیق تر، ما این ویژگی ها را دو به دو نسبت به هم رسم کردیم و این نمونه ها را در فضای ویژگی با هم مقایسه کردیم. این ارزیابی نیز صحت این موضوع را تصدیق می کند. شکل ۵، بیانگر یکی از این ترسیمات در فضای دو بعدی می باشد.



شکل ۵. نمونه ای از ترسیمات توزیع ویژگی های هر کلاس

همانطور که از جدول مشخص است، دسته بندی ANFIS نتیجه بهتری نسبت به دسته بندی کننده MLP در این کاربرد داشته است.

۵- نتیجه گیری و کارهای آینده

در این مقاله، توانایی روش گرام اشمیت برای بخش بندی هسته گلبول های سفید و استفاده از ویژگی های بافتی و شکلی به همراه دسته بندی کننده های عصبی و عصبی-فازی برای جداسازی بازوفیل ها از سایر انواع گلبول های سفید، مورد بررسی قرار گرفت. نتایج بدست آمده حاکی از موثر بودن این روش ها در بخش بندی و همچنین در شناسایی و جداسازی بازوفیل ها از سایر گلبول های سفید، بویژه بوسیله دسته بندی کننده عصبی - فازی بوده است. اما استفاده از ویژگی های شکلی و بخصوص بافتی دقیق تر و سریعتر نظیر Local Binary Pattern (LBP) و همچنین دسته بندی کننده های فازی قدرتمندتر نظیر Wavelet-Based Neuro-Fuzzy و Lolimot می تواند سبب بهبود نتایج و افزایش سرعت برنامه شوند.

سپاسگزاری

از اعضای پرسنل بخش هماتولوژی، انکولوژی بیمارستان امام خمینی بخصوص جناب آقای دکتر صفایی و خانم دکتر میرمنگره

- [16] T. W. Nattkemper, H. J. Ritter, W. Schubert, "A neural classifier enabling high-throughput topological analysis of lymphocytes in tissue sections," *IEEE Trans Inf. Technol. Biomed.*, vol. 5, No. 2, pp. 138–149, 2001.
- [17] H. Soltanian-Zadeh, D. J. Peck, D. O. Hearshen, and R. R. Lajiness-O'Neill, "Model Independent Method for fMRI Analysis," *IEEE Trans. Med. Imag.*, vol. 23, NO. 3, 2004.
- [18] S. Theodoridis, K. Koutroumbas, "Pattern Recognition," *Elsevier academic press*, 2007.
- [19] A. Yazdani, P. Atace, S. K. Setarehdan, B. N. Araabi, C. Lucas, "Neural, Fuzzy And Neurofuzzy Approach To Classification Of Normal And Alcoholic Electroencephalograms," 2007.