

ارائه یک روش نوین در طبقه‌بندی انواع گونه‌های پروانه با استفاده از پردازش تصویر

محمد قاسمی شرف^۱ و منصور اسماعیل پور^۲

چکیده

در زمینه تشخیص و طبقه‌بندی جانوران همواره مشکلات بسیاری وجود دارد که مانع از به وجود آمدن پیشرفت‌های سریع و مؤثر در این حوزه هستند. در سال‌های اخیر روش‌های جدیدی که بر شبکه‌های عصبی مصنوعی و پردازش تصویر مبتنی هستند، پیشنهاد شده‌اند که می‌توانند به تشخیص و بازشناسی گونه‌های پروانه‌ها بپردازند. در این مقاله به‌طور خاص، تشخیص گونه‌های پروانه را با استفاده از پردازش تصویر و روش‌های طبقه‌بندی هوشمند بررسی خواهیم نمود و به دنبال بهبود عملکرد از طریق به‌کارگیری ویژگی‌های بافت بال پروانه‌ها هستیم. در این راستا از روش استخراج ویژگی کوانتیزه‌سازی فاز محلی استفاده شده است که در مقابل ماتی موجود در تصاویر پروانه مقاومت نشان می‌دهد. برای طبقه‌بندی نیز از دو نوع شبکه عصبی MLP و موجکی استفاده گردید که در بین این دو، شبکه عصبی موجکی موفق به رسیدن به صحت ۱۰۰٪ در طبقه‌بندی ۱۴ گونه پروانه شد.

کلیدواژه‌ها

بازشناسی، شبکه عصبی مصنوعی، استخراج ویژگی، کوانتیزه‌سازی فاز محلی و شبکه عصبی موجکی

است [۱، ۲]. حشرات در زندگانی انسان نقش مهمی را ایفا می‌نمایند و می‌توان گفت حیات بدون حشرات مفهوم خاصی پیدا نخواهد نمود. بقای بسیاری از زیست‌بوم‌های^۲ طبیعی موجود بر روی زمین با زندگی بندپایان و به‌خصوص حشرات گره‌خورده است. شاید بزرگ‌ترین نقش این موجودات در احیای مراتع و جنگل‌ها است که ریه‌های کره زمین به شمار می‌آیند [۳]. علاوه بر همه این‌ها، استفاده از حشرات به‌عنوان منابع خوراکی، مطالعات ژنتیکی، شاخص‌های اکولوژیکی و بیولوژیکی، علم بیونیک^۳ و ... بر اهمیت شناسایی بیشتر این مخلوقات به‌ظاهر کوچک می‌افزاید. پروانه حشره‌ای است از راسته پولک‌بالان^۴ که امروزه در جهان در حدود ۲۰۰۰۰ گونه از این حشره شناسایی شده است که از این میان در حدود ۴۰۰ گونه تاکنون در ایران یافت شده است و احتمالاً با مطالعات وسیع‌تر و گسترده‌تر در آینده این رقم افزایش یابد [۲]. هدف رده‌بندی نه‌تنها توصیف، تشخیص و مرتب کردن موجودات در سطوح مناسب است، بلکه شامل درک تاریخ تکامل

۱ مقدمه

بندپایان^۱ با بیش از ۱/۵۰۰/۰۰۰ گونه شناسایی شده بزرگ‌ترین شاخه جانوری محسوب می‌گردند. در این میان رده حشرات با بیش از ۱/۰۰۰/۰۰۰ گونه نام‌گذاری شده بزرگ‌ترین و پرتنوع‌ترین رده در میان همه موجودات زنده هستند... دانشمندان تخمین می‌زنند که تعداد انواع حشرات موجود در جهان به بیش از ۱۰ برابر انواع شناخته‌شده کنونی برسد. در کشور ایران شاید بیش از بیست هزار گونه حشره وجود داشته باشد که حدود یک‌چهارم آن شناخته‌شده

این مقاله در مردادماه سال ۱۳۹۵ دریافت، در بهمن‌ماه بازنگری و در خردادماه سال ۱۳۹۶ پذیرفته شد.

^۱ دانش‌آموخته‌ی مهندسی کامپیوتر، واحد همدان، دانشگاه آزاد اسلامی.

رایانامه: m8148900@yahoo.com

^۲ گروه مهندسی کامپیوتر، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران.

رایانامه: esmaeilpour@iauh.ac.ir

نویسنده مسئول: منصور اسماعیل پور

^۲ Ecosystems

^۳ Bionics

^۴ Lepidoptera

^۱ Arthropods

Archive of SID

شبکه‌های عصبی مصنوعی^۶ (ANN) می‌توانند مورد استفاده قرار قرار گیرند [۵].

در [۶] قبل از تشکیل هیستوگرام ویژگی، تصویر رنگی از فضای RGB (قرمز، سبز، آبی) به فضای HSV^۷ (رنگ، اشباع، ارزش)، انتقال داده می‌شود. برای کاهش اثر روشنایی^۸ تصاویر، فقط مقادیر (رنگ، اشباع) مورد استفاده قرار گرفتند. به این ترتیب هیستوگرام برای این مقادیر تشکیل شد. از این هیستوگرام نتیجه می‌گیریم که هیستوگرام‌های به دست آمده برای گونه‌های حشره یکسان، دارای توزیع یکسانی هستند. GLCM^۹ نیز مشخصات مربوط به ثابت‌های سطح دوم از جمله انرژی، آنتروپی، همبستگی و همگنی^{۱۰} را تخمین می‌زند. با استفاده از این تکنیک می‌توان بال حشرات را به طور مؤثر از تصاویری با رزولوشن کم تشخیص داد. در پژوهشی دیگر، روشی متفاوت مطرح شده است. تئوری توسعه^{۱۱} روشی است که ماتریس عنصر-ماده^{۱۲} حشره را بر اساس ویژگی‌های تصویر میانی^{۱۳} و واریانس^{۱۴} ایجاد می‌کند. ماتریس عنصر-ماده از یک شیء، ویژگی و مقادیر ویژگی شیء (در اینجا شیء حشره است) تشکیل می‌شود. اولین گامی که در طبقه‌بندی حشرات در روش تئوری توسعه باید برداشته شود، استخراج ویژگی حشرات است. تصویر بلافاصله پس از گرفته شدن سیاه‌وسفید شده و از طریق روش انطباقی^{۱۵} قطعه‌بندی می‌شود. به این ترتیب تصویر باینری حشره از پس زمینه جدا می‌شود. هفده ویژگی مورفولوژیکی از تصاویر باینری استخراج شده و سپس نرمال‌سازی^{۱۶} می‌شوند. سپس ماتریس عنصر-ماده برای حشرات ایجاد می‌شود [۷].

در روش ترکیبی، لو^{۱۷} و همکاران از یک روش ترکیبی برای طبقه‌بندی حشرات به نام کدینگ نرم افتراقی محلی^{۱۸} (DLsoft) استفاده می‌کنند. در استراتژی‌های کدینگ نرم، یک بردار ویژگی از تصویر حشره توسط تابع کرنل مسافت^{۱۹} رمزگذاری می‌شود. به عنوان بخش افتراقی، یادگیری چند هسته‌ای^{۲۰} (MKL) برای طبقه‌بندی، جهت رفع اشکالات کدینگ به کار می‌رود. این روش بر گروهی از کرم‌ها و مگس‌های میوه آزمایش شد. دادگان به دو بخش عمده تقسیم شد؛ مجموعه داده‌های یادگیری و مجموعه داده‌های آزمایش. ابتدا تمامی تصاویر سیاه‌وسفید شدند، سپس

و مکانیسم‌های آن‌ها نیز می‌شود. روش‌های اولیه به طور عمده تنها بر خصوصیات مشاهده شده استوار بودند و به تفاوت‌های زیرگونه‌ای توجه نداشتند؛ بنابراین بسیاری از گونه‌ها به وسیله یک یا تعداد محدودی نمونه شناسایی می‌شوند. در حال حاضر توجه زیادی به تقسیم‌بندی فرعی گونه‌ها مانند زیرگونه و جمعیت‌ها مبذول می‌گردد. گونه مورفولوژیکی سابق اکنون گونه بیولوژیکی نامیده می‌شود که خصوصیات اکولوژیکی، ژنتیکی، بیوشیمیایی و سایر خصوصیات را شامل می‌شود. همه این روش‌های جدید در توضیح ساختار واقعی گونه و موقعیت تکاملی آن سهم بزرگی دارند [۴]. در زمینه تشخیص و طبقه‌بندی جانوران همواره مشکلات بسیاری وجود دارد که مانع از به وجود آمدن پیشرفت‌های سریع و مؤثر در این حوزه هستند. در ادامه بر آنیم تا روشی خودکار جهت طبقه‌بندی^۱ گونه‌های پروانه ارائه دهیم؛ تا محققین بتوانند با استفاده از نتایج این تحقیق به دسته‌بندی دقیق این حشره بپردازند؛ بنابراین ابتدا به کارهای پیشین انجام گرفته در زمینه تشخیص خودکار گونه‌های پروانه پرداخته و مزایا و معایب مطالعات پیشین را مورد تجزیه و تحلیل و بررسی قرار می‌دهیم. سپس در قسمت بعدی پژوهش نیز به طور کامل به تشریح داده‌های مورد استفاده و روش‌های موجود می‌پردازیم، همچنین ادامه بحث به روش پیشنهادی و مراحل انجام و پیاده‌سازی آن اختصاص یافته و نتایج به دست آمده از شبیه‌سازی‌ها را با ذکر کامل جزئیات مورد بحث و بررسی قرار می‌دهیم و روش‌های دیگر را با روش پیشنهادی مقایسه کرده و مزیت‌ها و معایب هر یک را ذکر خواهیم کرد. در پایان نیز به نتیجه‌گیری و بحث در زمینه کارهای قابل انجام آتی می‌پردازیم.

۲ پیشینه تحقیق

مبانی مهم تشخیص و طبقه‌بندی حشرات عبارت‌اند از تهیه تصاویر و پردازش تصاویر. برای تهیه تصاویر، تعدادی از گونه‌های مختلف حشره به عنوان نمونه انتخاب شده و تصویربرداری از آن‌ها توسط چند نوع دوربین، انجام می‌گیرد. گام بعدی، پردازش تصاویر است که در مراحل مختلفی انجام می‌پذیرد. ابتدا تصاویر رنگی سیاه‌وسفید می‌شوند؛ سپس، به تصویر باینری تبدیل می‌شوند که تنها شامل دو بخش سفید و سیاه است که طی آن، منطقه مورد علاقه^۲ یا ROI از پس زمینه تصویر جدا می‌شود. پس از این، استخراج ویژگی^۳ صورت می‌گیرد و ویژگی‌های استخراج شده مورد طبقه‌بندی قرار می‌گیرند. در این گام، روش‌های مختلف، خروجی‌های مختلفی ارائه می‌کنند. طبقه‌بندی‌های مختلفی همچون طبقه‌بندی فازی^۴، طبقه‌بندی نزدیک‌ترین همسایه^۵ و یا حتی

⁶ Artificial Neural Network

⁷ Hue, Saturation, Value

⁸ Illumination

⁹ Grey Scale Co-occurrence Matrix

¹⁰ Homogeneity

¹¹ Extension Theory

¹² Matter-Element Matrix

¹³ Mean Features

¹⁴ Variance Features

¹⁵ Adaptive

¹⁶ Normalized

¹⁷ An Lu

¹⁸ Discriminative Local Soft Coding

¹⁹ Kernel Function of Distance

²⁰ Multiple Kernel Learning

¹ Classification

² Region Of Interest

³ Feature Extraction

⁴ Fuzzy Classifier

⁵ Nearest Neighbor Classifier

۳ روش ارائه شده

الگوریتم پیشنهادی دارای دو مرحله آموزش و آزمایش است. در فاز آموزش ویژگی‌های تمام گونه‌های مورد استفاده با استفاده از کوانتیزه‌سازی فاز محلی^۸ (LPQ) در این فاز به دست آمده و یک شبکه عصبی با استفاده از این ویژگی‌ها آموزش داده می‌شود. این روش استخراج ویژگی به دلیل استفاده از اطلاعات فاز فوریه کوتاه مدت در مقابل محوی^۹ و تغییرات موجود در تصاویر پروانه پایدار است و از تصاویر ویژگی‌های بافت را استخراج می‌کند؛ که در شناسایی پروانه‌ها از اهمیت ویژه‌ای برخوردار است. در فاز بعدی برای پیدا کردن گونه یک عکس ورودی، ویژگی‌های این گونه را به شبکه آموزش دیده می‌دهیم و این نوع از پروانه طبقه‌بندی می‌شود. در بخش بازشناسی از چندین نوع شبکه عصبی بهره می‌گیریم که همان‌طور که خواهیم دید شبکه عصبی موجکی^{۱۰} (WNN) به دلیل پارامتریک بودن تابع انتقال از توانایی تعمیم بالاتری نسبت به شبکه عصبی پرسپترون چندلایه^{۱۱} (MLP) برخوردار است. سائز پنجره یک پارامتر اصلی در روش استخراج ویژگی کوانتیزه‌سازی فاز محلی است و در ادامه توضیح داده خواهد شد. در این روش با استفاده از تعدادی پنجره عمل استخراج ویژگی صورت می‌گیرد و سپس مناسب‌ترین پنجره انتخاب می‌شود. لازم به ذکر است.

۳-۱ پیش پردازش

به دلیل اندازه متفاوت تصاویر موجود در دادگان پروانه، پیش از اجرای قسمت‌های اصلی الگوریتم تمام تصاویر به ابعاد یکسان (۹۷۸×۱۲۰۶) تغییر اندازه پیدا می‌کند تا روند الگوریتم بهتر انجام شود. علاوه بر یکسان‌سازی ابعاد، جهت اجرای استخراج ویژگی باید تمام تصاویر به رنگ خاکستری مبدل می‌شوند؛ زیرا عملگر LPQ فقط از اطلاعات بافت استفاده می‌کند و نیازی به اطلاعات رنگ تصویر ندارد.

۳-۲ استخراج ویژگی مبتنی بر LPQ

توصیف‌گر LPQ که توسط اجانسو^{۱۲} و هیکیلا^{۱۳} پیشنهاد شده است، به خاطر عملکرد برجسته خود در تجزیه و تحلیل بافت تصویر در سال‌های اخیر شهرت فراوانی کسب کرده است [۱۲]. کوانتیزه کردن محلی فاز یک روش غیر حساس به محوی است که بر اساس فازهای کوانتیزه شده تبدیل فوریه گسسته^{۱۴} (DFT) در پنجره‌های تصویر عمل می‌کند. کدهای تولید شده به وسیله عملگر LPQ نسبت به محوی مرکزی متقارن غیر حساس هستند که شامل جابجایی‌ها، متمرکز نبودن و تلاطم‌های محیطی می‌شوند

ویژگی‌های SIFT^۱ از هر تصویر استخراج شده و از این مرحله به بعد تمامی تصاویر به وسیله SIFT نمایش داده می‌شوند. یک SIFT از طریق تقسیم تصویر به قسمت‌های کوچک‌تر و تهیه هیستوگرام برای هر یک از این قسمت‌ها به دست می‌آید. پس از تهیه SIFT کدهای افتراقی و محلی محاسبه شده و تصویر در این مرحله یک بردار ادغام هرم فضایی است که می‌تواند توسط هر روش یادگیری ماشین برای طبقه‌بندی استفاده شود [۸].

در سال‌های اخیر مطالعاتی در سطح مولکولی برای طبقه‌بندی استفاده شده‌اند. تمامی مطالعات انجام گرفته تاکنون، علاوه بر قطعی نبودن، با تمرکز بر ویژگی‌های مورفولوژیکی انجام گرفته‌اند. اخیراً مطالعاتی در زمینه توسعه ابزارهای کامپیوتری در جهت کمک به فرآیند طبقه‌بندی صورت گرفته‌اند [۳]. با این حال، می‌تواند فهمید که سیستم‌های هوشمند به اندازه کافی در این طبقه‌بندی‌ها بکار نرفته‌اند. وانگ^۲ و همکاران یک سیستم مبتنی بر محتوا برای طبقه‌بندی تصاویر پروانه‌ها بر اساس بافت سطوح رنگ و شکل آن‌ها پیشنهاد کردند [۹].

کینگ^۳ و همکاران یک روش تشخیص خودکار برای چهار گونه از پروانه‌ها ارائه کردند [۶]؛ که از ویژگی‌های بافت و رنگ و شکل، توسط یک طبقه‌بندی کننده ماشین بردار پشتیبان^۴ (SVM) استفاده می‌کند. اشمیت^۵ و همکاران [۱۰] یک مدل مبتنی بر ویژگی‌های ثابت محلی را برای خودکار سازی تشخیص پروانه‌ها بر اساس تصاویر طبیعی به شدت بهم ریخته توسعه دادند. این مطالعه در دو مرحله شکل گرفت؛ در مرحله اول، ویژگی‌های رنگ و بافت که از تصاویر پروانه‌ها به دست آمده است تشریح می‌گردند؛ و در مرحله دوم، طبقه‌بندی از طریق شبکه‌های عصبی مصنوعی انجام می‌گیرد.

از دیگر کارهای انجام گرفته در این زمینه می‌توان به پژوهش فنگ و همکاران اشاره کرد. در این مطالعه یک سیستم تشخیص و بازیابی خودکار تصاویر پروانه‌های شب پرواز، مورد آزمایش قرار گرفت [۱۱]. روش ارائه شده در این مطالعه مبتنی بر ویژگی‌های معنایی موجود بر روی بال‌های پروانه است. این روش بانام SRV^۶ یا ویژگی‌های معنایی وابسته بصری شناخته می‌شود. در سیستم ارائه شده ابتدا این ویژگی‌های SRV در پروانه‌های مختلف تشخیص داده می‌شود و از مقایسه الگوی هم رخدادی^۷ SRV های مختلف، گونه پروانه قابل تشخیص است. دقت تشخیص گونه‌های پروانه با استفاده از این روش به ۸۵٪ رسیده است [۱۱].

⁸ Local Phase Quantization

⁹ Blur

¹⁰ Wavelet Neural Network

¹¹ Multi-Layer Perceptron

¹² Ojansivu

¹³ Heikilla

¹⁴ Discrete Fourier Transform

¹ Scale Invariant Feature Transform

² Wang

³ Qing

⁴ Support Vector Machine

⁵ Schmidet

⁶ Semantically-Related Visual Attributes

⁷ Co-Occurrence Patterns

Archive of SID

که در آن Re و Im به ترتیب بیانگر اجزاء حقیقی و موهومی عدد مختلط هستند. ماتریس تبدیل متناظر ۸ در M^2 به صورت زیر محاسبه می‌شود:

$$W = [\text{Re}\{w_{u_1}, w_{u_2}, w_{u_3}, w_{u_4}\}, \text{Im}\{w_{u_1}, w_{u_2}, w_{u_3}, w_{u_4}\}]^T \quad (4)$$

بنابراین:

$$F_x = W \cdot f_x \quad (5)$$

۳-۱-۲-۲ تحلیل آماری ضرایب

فرض می‌کنیم که تابع تصویر $f(x)$ نتیجه یک فرآیند مارکوف مرتبه اول^۷ است که در آن ضریب همبستگی^۸ بین مقدار پیکسل‌های مجاور p و واریانس هر نمونه δ^2 است. بدون نقصان تعمیم، می‌توانیم فرض کنیم که $\delta^2 = 1$ ، در نتیجه، کوواریانس بین پیکسل‌های x_i و x_j از قرار زیر خواهد بود:

$$\sigma_{ij} = \rho^{|x_i - x_j|} \quad (6)$$

که در آن $|| \cdot ||$ نشان‌دهنده نرم L_2 است و ماتریس کوواریانس تمام نمونه‌های M در N_x را می‌توان به صورت زیر بیان نمود:

$$C = \begin{bmatrix} 1 & \sigma_{12} & \dots & \sigma_{1M} \\ \sigma_{21} & 1 & \dots & \sigma_{2M} \\ \dots & \dots & \dots & \dots \\ \sigma_{M1} & \sigma_{M2} & \dots & 1 \end{bmatrix} \quad (7)$$

از این رو، ماتریس کوواریانس بردار ضریب تبدیل F_x را می‌توان از رابطه زیر به دست آورد:

$$D = WCW^T \quad (8)$$

به راحتی می‌توان دریافت که برای $\rho > 0$ ، D یک ماتریس قطری نیست، به این معنی که ضرایب همبسته هستند [۱۲].

۳-۳ ناهمبسته‌سازی^۹ و کوانتیزاسیون

قبل از کوانتیزاسیون ضرایب ناهمبسته می‌گردند، زیرا می‌توان نشان داد که اگر نمونه‌هایی که قرار است کوانتیزه شوند، از لحاظ آماری مستقل^{۱۰} باشند، اطلاعات در کوانتیزاسیون عددی به طور حداکثر حفظ می‌شوند. با فرض توزیع گوسی، مستقل بودن نمونه‌ها را می‌توان با استفاده از یک تبدیل سفیدکردن^{۱۱} به دست آورد:

$$G_x = V^T F_x \quad (9)$$

که در آن V یک ماتریس متعامد^{۱۲} مستخرج از تجزیه مقدار تکین^{۱۳} (SVD) ماتریس D است، یعنی:

[۱۳]. عملگر LPQ برای شناسایی بافت اعمال می‌شود و به وسیله محاسبه منطقه‌ای در محل هر پیکسل^۱ موجود و تولید کد، یک هیستوگرام^۲ تشکیل می‌دهد.

تولید کدها و هیستوگرام آن‌ها شبیه به روش الگوی دودویی محلی^۳ محلی^۴ (LBP) است [۱۴]. آنالیز فرکانس‌های محلی که اغلب به عنوان روش‌های پردازش سیگنال شناخته می‌شوند همچنین برای آنالیز بافت در گذشته مورد استفاده قرار گرفته بوده است [۱۵]. یکی از بهترین روش‌های شناخته شده استفاده از فیلترهای گابور است [۱۶] و اطلاعات فاز در [۱۷] مورد استفاده بوده و هیستوگرام‌ها در ارتباط با داده‌ها و اطلاعات طیفی مورد استفاده قرار گرفته‌اند [۱۸]. با این وجود حساسیت به محوی به عنوان یک معیار هنگام طراحی این عملگرها در نظر گرفته نشده است. در ادامه روند انجام این روش را می‌توان مشاهده کرد.

۳-۲-۱ کوانتیزاسیون فاز محلی برای طبقه‌بندی بافت

۳-۱-۲-۳ تبدیل فوری کوتاه مدت^۴ (STFT)

روش کوانتیزاسیون فاز محلی بر پایه خاصیت پایداری در برابر محوی طیف فاز فوری^۵ است که از اطلاعات فاز محلی استخراج شده با استفاده از تبدیل فوری گسسته دوبعدی یا دقیق‌تر، تبدیل فوری کوتاه مدت محاسبه شده بر روی یک همسایگی M در M مستطیلی N_x در هر موقعیت پیکسلی x از تصویر $f(x)$ به صورت زیر تعیین می‌شود [۱۹]:

$$F(u, x) = \sum_{y \in N_x} f(x-y) e^{-j2\pi u^T y} = w_u^T f_x \quad (1)$$

که در آن w_u بردار پایه تبدیل دوبعدی در فرکانس u است و f_x بردار دیگری شامل تمام M^2 پیکسل از N_x است. همان‌طور که می‌توان از رابطه بالا متوجه شد، یک راه کارآمد اجرای این تبدیل استفاده از کانولوشن^۶ دوبعدی $f(x) \times e^{-j2\pi u^T x}$ برای کل u است. از آنجا که توابع پایه قابل تفکیک هستند، محاسبه را می‌توان با استفاده از کانولوشن‌های تک‌بعدی برای سطرها و ستون‌های متوالی انجام داد.

در LPQ تنها چهار ضریب مختلط در نظر گرفته می‌شوند که مطابق فرکانس‌های دوبعدی $u_1 = [a, 0]^T$ ، $u_2 = [0, a]^T$ ، $u_3 = [a, a]^T$ و $u_4 = [a, -a]^T$ هستند که در آن‌ها، a یک فرکانس اسکالر پایین‌تر از اولین صفر عبوری از $H(u)$ است [۱۲]. فرض می‌کنیم:

$$F_x^c = [F(u_1, x), F(u_2, x), F(u_3, x), F(u_4, x)] \quad (2)$$

و

$$F_x = [\text{Re}\{F_x^c\}, \text{Im}\{F_x^c\}]^T \quad (3)$$

⁷ First Order Markov Process

⁸ Correlation Coefficient

⁹ Decorrelation

¹⁰ Statistical Independent

¹¹ Whitening Transform

¹² Orthonormal Matrix

¹³ Singular Value Decomposition

¹ Pixel


² Histogram

³ Local Binary Pattern

⁴ Short Term Fourier Transform

⁵ Fourier Phase Spectrum

⁶ Convolution




شکل ۱ (a) تصویر گونه پروانه و (b-h) ویژگی‌های فاز کوانتیزه مربوطه به دست آمده به وسیله مقیاس‌های پنجره محلی LPQ مختلف، به ترتیب از پنجره کوچک‌تر به بزرگ‌تر.

۲-۳-۲ بازشناسی در الگوریتم پیشنهادی


۱-۲-۳-۲ شبکه عصبی پرسپترون چندلایه

شبکه عصبی MLP از لایه ورودی، لایه‌های مخفی و لایه خروجی که هر یک شامل تعداد نرون‌های مشخصی است تشکیل می‌شود. تعداد نرون‌های لایه ورودی برابر تعداد ویژگی‌های بردار ورودی به علاوه یک نرون بایاس و تعداد نرون‌های لایه خروجی برابر تعداد کلاس‌های تعریف شده برای طبقه‌بندی کننده است. انتخاب تعداد لایه‌های مخفی و تعداد نرون‌ها در هر یک از آن‌ها بسیار مهم است؛ چراکه اگر تعداد آن‌ها کم باشد شبکه برای حل مسائل غیرخطی و پیچیده با کمبود منابع یادگیری مواجه می‌شود و اگر زیاد باشد موجب ایجاد دو مشکل خواهد شد؛ اول آن‌که زمان آموزش شبکه افزایش می‌یابد و دوم آن‌که ممکن است شبکه نظام بی‌اهمیت داده‌های آموزش را یاد بگیرد و در حل مسائل ضعیف عمل نماید [۲۰].



شکل ۲ نمایش ساختار شبکه عصبی MLP

در شکل ۳ شاهد نوع اول از شبکه عصبی MLP مورد استفاده در این تحقیق هستیم. در این نوع ما تنها یک نرون در لایه خروجی با تابع خطی هستیم که گونه یک پروانه را تخمین می‌زند. لازم به ذکر است که تعداد ورودی‌ها به اندازه بردار ویژگی وابسته است (۲۵۶)، طول هیستوگرام (LPQ).



شکل ۳ شبکه عصبی MLP نوع اول

$$D = U \Sigma V^T \quad (10)$$

توجه کنید که V را می‌توان از پیش برای یک مقدار ثابت ρ به دست آورد.

در مرحله بعدی، G_x برای تمام موقعیت‌های تصویر یعنی

$x = \{x_1, x_2, \dots, x_N\}$ محاسبه می‌شود و بردارهای حاصل با استفاده از یک کوانتیزه‌ساز عددی ساده کوانتیزه می‌شوند:

$$q_j = \begin{cases} 1, & \text{if } g_j \geq 0 \\ 0, & \text{otherwise} \end{cases} \quad (11)$$

که در آن g_j جزء z ام از G_x است. ضرایب کوانتیزه با استفاده از کدگذاری دودویی^۲ به صورت مقادیر صحیح بین ۰-۲۵۵ ارائه می‌شوند:

$$b = \sum_{j=1}^8 q_j 2^{j-1} \quad (12)$$

در پایان، یک هیستوگرام از این مقادیر صحیح برای کل موقعیت‌های تصویر تشکیل می‌شود و به عنوان یک بردار ویژگی ۲۵۶ عضوی در طبقه‌بندی استفاده می‌شود.

اعداد صحیح b نسبت به محوی متقارن مرکزی تغییرناپذیر هستند به شرطی که پنجره N_x بی‌نهایت بزرگ باشد و طیف فرکانسی محوی در مکان‌های نمونه u_1 تا u_4 مثبت باشد. شرط دوم به راحتی برآورده می‌شود در صورتی که a به اندازه کافی کوچک باشد. با این حال، شرط اول در عمل تأمین نمی‌شود و در نتیجه، تغییرناپذیری کامل قابل استحصال نیست.

ناهمبستگی و کوانتیزاسیون هیچ‌گونه تأثیری بر خاصیت تغییرناپذیری محوی یا تاری ندارند. در تبدیل سفیدکردن، بردارهای ضریب در معرض یک چرخش هشت بعدی هستند که فقط باعث یک جابجایی فاز یکنواخت برای همه بردارها می‌شود. در کوانتیزاسیون، فضای هشت بعدی به ۲۵۶ ابرمکعب^۳ تقسیم شده و تخصیص یک بردار به یکی از این ابرمکعب‌ها تنها به اطلاعات فاز بستگی دارد [۱۲].

۱-۳-۳ کوانتیزاسیون فاز محلی در بازشناسی گونه‌های پروانه

در این تحقیق تصویر گونه پروانه به عنوان تصویر اصلی به علاوه نویز در نظر گرفته می‌شود و فرض می‌گردد که نویز به عنوان تابع h در رابطه (۱) به تابع تصویر یا f اضافه شده است و در نهایت تصویر g جهت بازشناسی در اختیار ماست و ما بدون اطلاع دقیق از تابع h قصد داریم خانواده تابع f را پیدا کنیم. در شکل زیر ویژگی‌های هر پیکسل تصویر به ازای اندازه پنجره‌های مختلف نمایش داده شده است:

¹ Scalar Quantizer

² Binary Coding

³ Hypercube

Archive of SID

شبیه‌سازی را بر مبنای الگوریتم‌های موجود در ساختار شبکه عصبی کاهش می‌دهد. هر واحد لایه مخفی با وجود یک موجک در ساختار خود به‌عنوان تابع تحریک که یک پنجره مربعی زمان در ساختار خود دارد با تغییر در مقادیر پنجره نسبت به استفاده از قانون بهینه‌سازی اقدام می‌نماید و با تغییر در موقعیت زمانی و مکانی به فشرده و یا باز شدن موجک اقدام می‌نماید.




شکل ۵ شبکه عصبی موجکی

در این نوع از شبکه‌ها عموماً از تابع مورلت^۲ به‌عنوان تابع انتقال استفاده می‌شود (شکل ۵)؛ که از رابطه ۱۳ محاسبه می‌گردد:

$$y = \cos(4x) \times e^{-\frac{x^2}{2}} \quad (13)$$

در شبکه عصبی موجکی تابع مورلت به شکل رابطه ۱۴ درمی‌آید و دو پارامتر به نام‌های انتقال^۳ (D) و اتساع^۴ (λ) به آن اضافه می‌شوند که با تغییر آن‌ها شکل تابع عوض می‌شود.

$$y = \cos\left(4 \frac{(x-D)}{\lambda}\right) \times e^{-\frac{\left(\frac{(x-D)}{\lambda}\right)^2}{2}} \quad (14)$$




شکل ۶ از راست به چپ: تابع اصلی مورلت، تابع مورلت با انتقال $D = 10$ ، تابع مورلت با اتساع $\lambda = 5$

شبکه عصبی موجکی علاوه بر تنظیم وزن‌ها، مقادیر انتقال و اتساع را برای تمامی نرون‌های لایه پنهان با الگوریتم پس انتشار خطا تنظیم می‌کند تا خطا را به حداقل رساند [۲۱].

بنابراین می‌توان گفت که این نوع از شبکه عصبی توانایی بالایی در تخمین توابع غیرخطی دارد و حتی با تعداد نرون‌های مساوی با شبکه MLP عملکرد بهتری نسبت به این نوع شبکه از خود نشان می‌دهد. همچنین شبکه عصبی موجکی در مقایسه با MLP همگرایی بالاتری دارد و این خصوصیت شبکه موجکی به دلیل توابع مورلت قابل تنظیم درون لایه پنهان است. به‌منظور بازشناسی گونه‌های پروانه، الگوریتمی بر اساس استخراج ویژگی LPQ در این مطالعه ارائه شد. روش LPQ برای استخراج ویژگی آماری مورد استفاده قرار می‌گیرد. در روش LPQ، طیف فاز فوریه برای

در شکل ۴ نوع دوم شبکه عصبی MLP را می‌بینیم. تنها تفاوت این شبکه با قبلی در خروجی است؛ به‌طوری‌که به‌جای استفاده از مقدار داده‌ی کلاس پروانه از مقدار دودویی آن بهره می‌گیریم و همان‌طور که در ادامه توضیح خواهیم داد، ۱۴ کلاس پروانه در اختیار داریم و $\lceil \log_2(14) \rceil = 4$ بنابراین به چهار نرون در لایه خروجی نیازمندیم. با توجه به این‌که خروجی تابع تانژانت سیگموئید عددی بین -۱ و ۱ است ما ابتدا خروجی شبکه را به بازه ۰ و ۱ منتقل و آن را به نزدیک‌ترین عدد صحیح گرد می‌نماییم. کلاس‌های پروانه‌ها به‌صورت باینری از مقدار (۰۰۰۱ = کلاس اول) تا کلاس (۱۱۰۰ = کلاس چهاردهم) طبقه‌بندی شده است.



شکل ۴ شبکه عصبی MLP نوع دوم

این شبکه عصبی سعی در کمینه‌سازی خطا و تخمین تابع با تنظیم وزن ارتباطات نرون‌ها دارد؛ ولی ممکن است در بعضی شرایط خطا افزایش پیدا کند که می‌توان این مشکل را با افزایش تعداد نرون‌های لایه پنهان رفع نمود.

۳-۲-۲-۳-۳ شبکه عصبی مصنوعی موجکی^۱

ترکیب موجک و شبکه عصبی مصنوعی، الگوی جدیدی از هوش مصنوعی با نام شبکه عصبی موجکی را تشکیل می‌دهد و می‌تواند جایگزین مناسبی برای شبکه‌های عصبی انتشار برگشتی باشد؛ که تقریباً می‌توان در آن از هر تابع غیرخطی استفاده نمود.

۳-۲-۲-۳-۳ موجک

موجک دسته‌ای از توابع ریاضی هستند که برای تجزیه سیگنال پیوسته به مؤلفه‌های فرکانسی آن بکار می‌رود که رزولوشن هر مؤلفه برابر با مقیاس آن است. تبدیل موجک تجزیه یک تابع بر مبنای توابع موجک است. موجک‌ها نمونه‌های انتقال‌یافته و مقیاس‌شده یک تابع موجک مادر با طول متناهی و نوسانی شدیداً میرا هستند [۲۱].

۳-۲-۲-۳-۳ یادگیری در شبکه عصبی موجکی

الگوریتم این شبکه از دو فرایند اساسی شامل خودسامان‌دهی شبکه و کاهش خطا تشکیل شده است. در فرایند اول ساختار شبکه با استفاده از موجک به‌عنوان تابع تحریک تعیین می‌شود. شبکه به‌تدریج با تعیین مقدار مناسب واحدهای مخفی خود با در نظر گرفتن ورودی و خروجی (هدف) به‌طور هم‌زمان، پارامترهای شبکه را تجدید کرده و ساختار شبکه را حفظ نموده و فرایند بعدی را طی می‌نماید. در ساختار دوم برآوردکننده شبکه خطای

² Morlet

³ Translation

⁴ Dialation

¹ Wavelet Neural Network

Archive of SID

با توجه به نتایج به دست آمده از جدول فوق، روش دوم یعنی شبکه عصبی MLP با خروجی باینری (تابع Tansig)، در بر دارنده نتایج بهتری است. به همین دلیل برای به دست آوردن مقادیر میانگین صحت آموزش و آزمایش و نیز انحراف معیارهای آموزش و آزمایش، به ازای سایز پنجره‌های مختلف، از روش دوم استفاده می‌کنیم.

۴-۱-۱ تعیین اندازه بهینه پنجره

در جدول ۲ میانگین صحت آزمایش به وسیله شبکه عصبی MLP با خروجی باینری را به ازای سایز پنجره‌های مختلف شاهد هستیم.

جدول ۲ تعیین سایز پنجره بهینه برای MLP

سایز پنجره	میانگین صحت آموزش (%)	میانگین صحت آزمایش (%)	انحراف معیار آموزش	انحراف معیار آزمایش
۳×۳	۸۵/۳۴	۵۳/۸۹	۳/۳۴	۱۰/۵۵
۵×۵	۹۳/۱۳	۷۷/۲۲	۲/۳۷	۱۰/۰۷
۷×۷	۹۶/۳۹	۸۷/۳۶	۱/۹۱	۸/۰۸
۹×۹	۹۵/۸۲	۹۰/۴۲	۳/۳۳	۶/۴۹
۱۱×۱۱	۹۷/۵۲	۹۳/۳۳	۳/۷۳	۶/۴۴
۱۳×۱۳	۹۷/۳۸	۹۳/۰۶	۲/۹۶	۸/۶۴
۱۵×۱۵	۹۸/۷۱	۹۵/۶۹	۱/۶۳	۶/۲۴
۱۷×۱۷	۹۷/۷۶	۹۲/۹۲	۲/۵۲	۷/۲۷
۱۹×۱۹	۹۷/۶۵	۹۴/۷۲	۳/۶۱	۷/۳۳
۲۱×۲۱	۹۸/۲۰	۹۶/۲۵	۲/۰۴	۵/۴۰
۲۳×۲۳	۹۷/۹۶	۹۵/۱۴	۲/۴۷	۷/۱۰
۲۵×۲۵	۹۷/۵۲	۹۵/۱۴	۳/۶۹	۵/۶۹
۲۷×۲۷	۹۷/۷۲	۹۴/۰۳	۳/۲۹	۷/۳۱
۲۹×۲۹	۹۸/۲۰	۹۶/۳۹	۱/۹۱	۴/۳۴
۳۱×۳۱	۹۸/۱۳	۹۲/۳۶	۲/۱۹	۸/۱۲

با توجه به نتایج به دست آمده از جدول فوق، سایز پنجره ۲۹×۲۹ بهترین عملکرد را از خود نشان می‌دهد. در جدول ۳ ماتریس درهم‌ریختگی را برای این سایز پنجره را می‌بینیم:

جدول ۳ ماتریس درهم‌ریختگی MLP

کلاس پیش‌بینی شده													
۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲	۱۳	۱۴
۸	۰	۰	۰	۰	۲	۰	۰	۰	۰	۰	۰	۰	۰
۲	۱۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
۳	۰	۰	۹	۰	۰	۰	۰	۰	۱	۰	۰	۰	۰
۴	۰	۰	۰	۱۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
۵	۰	۰	۰	۰	۸	۰	۱	۰	۰	۰	۰	۰	۱
۶	۰	۰	۰	۰	۰	۱۰	۰	۰	۰	۰	۰	۰	۰
۷	۰	۰	۰	۰	۰	۰	۹	۰	۰	۰	۱	۰	۰
۸	۰	۰	۰	۰	۰	۰	۰	۱۰	۰	۰	۰	۰	۰
۹	۰	۰	۰	۰	۰	۰	۰	۰	۹	۰	۰	۰	۰
۱۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۰	۰	۰
۱۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۹	۰	۰
۱۲	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۸	۰
۱۳	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰
۱۴	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰

استخراج ویژگی‌های قوی به کار گرفته می‌شود. در روش بازشناسی ارائه شده، ویژگی LPQ به عنوان یک ویژگی مؤثر و پایدار استخراج می‌شود، سپس هیستوگرامی از این مقادیر صحیح ویژگی و با استفاده از همه پیکسل‌ها تشکیل شده و به عنوان یک بردار ویژگی مورد استفاده قرار می‌گیرد و در نهایت عمل بازشناسی گونه پروانه با استفاده از شبکه‌های عصبی MLP و موجکی اجرا می‌گردد.

۴ آزمایش‌ها و نتایج

برای انجام آزمایش‌های تشخیص خودکار گونه‌های پروانه، ابتدا نیاز است تعدادی پروانه از گونه‌های مختلف جمع‌آوری شده و تصویر آن‌ها تهیه گردد. برای انجام این کار می‌بایست مطالعات میدانی وسیعی صورت گیرد. به عنوان مثال در تحقیق پیش‌رو از داده‌های جمع‌آوری شده در [۲۲] استفاده می‌شود. در این تحقیق، مطالعات میدانی در فاصله می ۲۰۰۲ تا آگوست ۲۰۰۳، در محیطی به وسعت ۳۲۰۰ مترمربع صورت گرفت که در نتیجه آن ۱۴ پروانه از ۱۴ گونه مختلف جمع‌آوری شد.



شکل ۷ نمونه‌ای انتخاب شده از خانواده استریدا [۲۲].

حدود ۷۰٪ این دادگان برای آموزش و ۳۰٪ برای آزمون استفاده می‌شوند؛ بدین ترتیب که از هر گونه، تصویر ۱۰ پروانه به صورت تصادفی انتخاب می‌شوند (جمعاً ۱۰۰ تصویر) و در هر بار اجرا برای آموزش در اختیار الگوریتم قرار می‌گیرند و مابقی تصاویر جهت آزمون استفاده می‌شوند.

۴-۱ بازشناسی با استفاده از MLP

در ابتدا پارامترهای این شبکه (وزن‌ها) به صورت تصادفی تعیین می‌شوند و سپس با استفاده از فرایند یادگیری تنظیم می‌شوند؛ تا به بهترین عملکرد (حداقل خطا) برسیم. در جدول ۱ عملکرد دو شبکه MLP را ملاحظه می‌کنیم:

جدول ۱ عملکرد شبکه عصبی MLP به ازای تابع خروجی‌های مختلف (سایز پنجره ۳×۳)

میانگین صحت آموزش (%)	میانگین صحت آزمایش (%)	انحراف معیار آموزش	انحراف معیار آزمایش
۵۵/۹۲	۸/۶۱	۲۲/۴۳	۴/۷۶
۸۵/۳۴	۵۳/۸۹	۳/۳۴	۱۰/۵۵


شبکه عصبی MLP با خروجی اعداد صحیح (تابع Purelin)

شبکه عصبی MLP با خروجی باینری (تابع Tansig)

Archive of SID

۴-۳ آزمایش روش در شرایط وجود نویز

در این بخش قصد داریم عملکرد روش را در شرایطی سخت‌تر از بازشناسی در حالت استاندارد بسنجیم؛ بدین منظور ابتدا به تصاویر موجود در پایگاه داده نویز (محو) می‌افزاییم؛ بدین منظور از فیلتر میانگین با پنجره‌های متفاوت استفاده می‌کنیم (شکل ۸).



شکل ۸ به ترتیب از راست به چپ: تصویر اصلی، تصویر محوشده با پنجره ۵×۵، تصویر محوشده با پنجره ۱۰×۱۰ و تصویر محوشده با پنجره ۱۵×۱۵.

در این آزمایش نیز مانند سایر آزمایش‌ها، تمامی تصاویر با استفاده از روش LPQ به بردار ویژگی معادلشان تبدیل و به یک شبکه عصبی آموزش‌دیده ارائه می‌شوند و پس از طبقه‌بندی تمامی تصاویر مجموعه آزمون معیارهای عملکرد محاسبه می‌گردند. در جدول ۶ شاهد عملکرد روش پیشنهادی در حضور نویز محوی هستیم:

جدول ۶ عملکرد روش در حضور نویز محوی.

شبکه عصبی MLP			طبقه‌بند		
۱۵×۱۵	۱۰×۱۰	۵×۵	۱۵×۱۵	۱۰×۱۰	۵×۵
۹۹/۹۸	۱۰۰	۱۰۰	۹۵/۱۲	۹۵/۵۵	۹۵/۹۸
شبکه عصبی موجکی			پنجره فیلتر میانگین		
۱۵×۱۵	۱۰×۱۰	۵×۵	۱۵×۱۵	۱۰×۱۰	۵×۵
۹۹/۹۸	۱۰۰	۱۰۰	۹۵/۱۲	۹۵/۵۵	۹۵/۹۸
شبکه عصبی موجکی			میانگین صحت (%)		
۹۹/۹۸	۱۰۰	۱۰۰	۹۵/۱۲	۹۵/۵۵	۹۵/۹۸

همان‌طور که از نتایج پیداست، نویز حاصل از میانگین‌گیری که به شکل محوی در تصاویر دیده می‌شود تأثیری بسزایی بر عملکرد روش پیشنهادی ندارد.

۴-۴ مقایسه روش پیشنهادی با روش‌های پیشین

در سال‌های اخیر محققان چندین روش کارا در جهت بازشناسی پروانه ارائه کرده‌اند؛ که بر روی دادگان مورد استفاده در این پژوهش آزموده و نتایج گزارش شده‌اند. به‌عنوان مثال در [۳] از LBP جهت استخراج ویژگی و شبکه عصبی برای بازشناسی پنج گونه پروانه بکار رفتند. در [۲۲] محققان همین آزمایش را با ۱۴ گونه پروانه انجام دادند و از ویژگی GLCM نیز بهره گرفتند که توانایی بالاتری در بازشناسی داشت. در [۲۳] روش‌های متنوع بازشناسی بر روی ویژگی‌های LBP و GLCM بکار گرفته شدند و بهترین روش از لحاظ درصد صحت ترکیب GLCM با ELM^۱ عنوان شد. در جدول ۷ روش پیشنهادی با سایر روش‌های ارائه‌شده مقایسه شده است؛ همان‌گونه که مشخص است روش پیشنهادی عملکرد بسیار خوبی نسبت به سایر روش‌ها را از خود نشان

۴-۲ بازشناسی با استفاده از شبکه عصبی موجکی

در این شبکه نیز مانند شبکه قبلی، پارامترهای شبکه (وزن‌ها، اتساع و انتقال) در ابتدا تصادفی‌اند و طی فرایند یادگیری به مقدار بهینه آن‌ها دست می‌یابیم. در جدول ۴ صحت شبکه عصبی موجکی به ازای پنجره‌های مختلف را شاهد هستیم:

جدول ۴ تعیین ساین پنجره بهینه برای شبکه عصبی موجکی

ساین پنجره	میانگین صحت آموزش (%)	میانگین صحت آزمایش (%)	انحراف معیار آموزش	انحراف معیار آزمایش
۳×۳	۸۹/۵۳	۶۶/۹۹	۳/۳۳	۹/۸۵
۵×۵	۹۷/۱۲	۷۹/۳۴	۱/۳۱	۱۰/۴۱
۷×۷	۹۹/۴۰	۸۳/۵۹	۲/۹۲	۱۰/۷۶
۹×۹	۹۹/۵۱	۸۹/۴۴	۲/۳۶	۶/۶۶
۱۱×۱۱	۹۹/۵۲	۹۰/۲۵	۲/۷۵	۷/۰۱
۱۳×۱۳	۹۹/۶۳	۹۸/۱۴	۳/۶۴	۸/۰۳
۱۵×۱۵	۹۹/۷۱	۹۹/۲۷	۲/۵۲	۷/۱۲
۱۷×۱۷	۹۹/۹۷	۹۹/۶۸	۲/۳۳	۸/۳۲
۱۹×۱۹	۱۰۰	۹۹/۷۷	۰	۶/۴۴
۲۱×۲۱	۱۰۰	۹۹/۸۲	۰	۵/۳۵
۲۳×۲۳	۱۰۰	۹۹/۹۴	۰	۷/۰۸
۲۵×۲۵	۱۰۰	۱۰۰	۰	۰
۲۷×۲۷	۱۰۰	۱۰۰	۰	۰
۲۹×۲۹	۱۰۰	۱۰۰	۰	۰
۳۱×۳۱	۱۰۰	۱۰۰	۰	۰

با توجه به نتایج به‌دست‌آمده از جدول فوق، ساین‌های پنجره ۲۵×۲۵، ۲۷×۲۷، ۲۹×۲۹ و ۳۱×۳۱ بهترین عملکرد را از خود نشان می‌دهند. به دلیل حداکثر بودن صحت شبکه عصبی موجکی، ماتریس درهم‌ریختگی آن یک ماتریس کاملاً قطری است (جدول ۵).

جدول ۵ ماتریس درهم‌ریختگی شبکه عصبی موجکی.

کلاس پیش‌بینی شده														کلاس واقعی	
۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲	۱۳	۱۴		
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۱
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۲
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۳
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۴
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۵
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۶
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۷
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۸
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۹
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۱۰
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۱۱
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۱۲
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۱۳
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۱۴

^۱ Extreme Learning Machine

Archive of SID

ورودی، ویژگی‌های هرگونه را به شبکه آموزش داده فرستادیم و گونه طبقه‌بندی شد. همان‌طور که مشاهده شد، برای استخراج ویژگی‌های موردنیاز از روش کوانتیزاسیون فاز محلی که در مقابل تغییرات از خود پایداری نشان می‌دهد استفاده شد و در بخش بازشناسی از چندین نوع شبکه عصبی بهره بردیم. سائز پنجره که پارامتری اصلی در روش استخراج ویژگی کوانتیزاسیون فاز محلی است موردبررسی قرار گرفت. در این روش با استفاده از تعدادی پنجره عمل استخراج ویژگی صورت پذیرفت و سپس مناسب‌ترین پنجره انتخاب شد. با سائز پنجره 29×29 بیشترین مقدار میانگین صحت آزمایش برای MLP، $96/39\%$ و با سائز پنجره‌های بالاتر از 25×25 مقدار میانگین صحت آزمایش برای شبکه موجکی، 100% به دست آمد. آزمایش در شرایط وجود نویز محوی و مقایسه با سایر روش‌های ارائه‌شده نشان داد که روش پیشنهادی دارای عملکرد بسیار خوبی در طبقه‌بندی گونه‌های پروانه است.

۱-۵ پیشنهادها

- (۱) استفاده از روش پیشنهادی برای طبقه‌بندی سایر گونه‌های حشرات، جانوران و گیاهان.
- (۲) استفاده از دادگان ملی در صورت امکان تهیه.
- (۳) ترکیب پنجره‌ها در LPQ جهت ارتقا عملکرد.

مراجع


- [1] D. Grimaldi and M. S. Engel, *Evolution of the Insects*: Cambridge University Press, 2005.
- [2] نظری. "پروانه‌های ایران." ۱۳۸۲.
- [3] Y. Kaya, L. Kayci, and M. Uyar, "Automatic identification of butterfly species based on local binary patterns and artificial neural network," *Applied Soft Computing*, vol. 28, pp. 132-137, 2015.
- [4] و. س. کاپور، اصول رده‌بندی جانوری. رشت: دانشگاه گیلان، ۱۳۷۹.
- [5] S. N. Ghaiwat and P. Arora, "Detection and classification of plant leaf diseases using image processing techniques: A review," *International Journal of Recent Advances in Engineering and Technology (IJRAET)*. ISSN (Online), pp. 2347-2812, 2014.
- [6] L.-Q. Zhu and Z. Zhang, "Auto-classification of insect images based on color histogram and GLCM," in *Fuzzy Systems and Knowledge Discovery (FSKD), 2010 Seventh International Conference on*, 2010, pp. 2589-2593.
- [7] H. Zhang and Y. Hu, "Extension Theory for Classification of the Stored-Grain Insects," in *Machine Vision and Human-Machine Interface (MVHI), 2010 International Conference on*, 2010, pp. 758-760.
- [8] A. Lu, X. Hou, C.-L. Liu, and X. Chen, "Insect species recognition using discriminative local soft coding," in *Pattern Recognition (ICPR), 2012 21st International Conference on*, 2012, pp. 1221-1224.

می‌دهد؛ که حاکی از توانایی بالای روش LPQ در استخراج ویژگی و شبکه عصبی موجکی در بازشناسی است.

جدول ۷ مقایسه روش پیشنهادی با سایر روش‌های ارائه‌شده

شماره	روش	استخراج ویژگی	بازشناسی	تعداد گونه‌ها	صحت (%)
۱	[۳]	LBP	ANN	۵	۹۶
۲	[۲۲]	GLCM	ANN	۱۴	۹۵/۸۵
۳	[۲۲]	LBP	ANN	۱۴	۸۸/۰۹
۴	[۲۳]	GLCM	LR	۱۹	۹۶/۳۱
۵	[۲۳]	GLCM	ANN	۱۹	۹۳/۱۵
۶	[۲۳]	GLCM	SVM	۱۹	۷۱/۵۷
۷	[۲۳]	GLCM	PART	۱۹	۸۱/۵۷
۸	[۲۳]	GLCM	J48	۱۹	۸۱/۵۷
۹	[۲۳]	GLCM	NB	۱۹	۸۵/۲۶
۱۰	[۲۳]	GLCM	ELM	۱۹	۹۸/۲۵
۱۱	[۲۳]	LBP	LR	۱۹	۹۴/۲۱
۱۲	[۲۳]	LBP	ANN	۱۹	۸۹/۴۷
۱۳	[۲۳]	LBP	SVM	۱۹	۵۰/۵۲
۱۴	[۲۳]	LBP	PART	۱۹	۸۰/۰۰
۱۵	[۲۳]	LBP	J48	۱۹	۷۶/۳۱
۱۶	[۲۳]	LBP	NB	۱۹	۷۲/۱۰
۱۷	[۲۳]	GLCM	ELM	۱۹	۹۶/۴۹
۱۸	روش پیشنهادی	LPQ	MLP	۱۴	۹۶/۳۹
۱۹	روش پیشنهادی	LPQ	WANN	۱۴	۱۰۰

نتایج حاصل از آزمایش‌ها بیانگر این مطلب است که شبکه عصبی MLP با خروجی باینری (تابع Tansig)، دربردارنده نتایج مطلوبی است و شبکه عصبی موجکی عملکرد بهتری از سایر شبکه‌ها و طبقه‌بندی‌ها دارد.



شکل ۹ نمودار مقایسه صحت الگوریتم‌های مختلف.

۵ نتیجه‌گیری و پیشنهادهای آتی

الگوریتم پیشنهادی دارای دو مرحله آموزش و آزمایش است. در فاز آموزش ویژگی‌های تمام گونه‌های مورد استفاده در این فاز به‌دست‌آمده و یک شبکه عصبی با استفاده از این ویژگی‌ها آموزش داده شد. سپس در فاز بعدی برای پیدا کردن گونه عکس‌های

Archive of SID

"butterfly species using extreme learning machine," *Journal of Experimental & Theoretical Artificial Intelligence*, vol. 26, pp. 267-281, 2014.



محمد قاسمی شرف مدرک کارشناسی و کارشناسی ارشد خود را به ترتیب در رشته مهندسی کامپیوتر، گرایش نرم افزار و هوش مصنوعی از دانشگاه آزاد اسلامی واحد همدان در سال‌های ۱۳۸۶ و ۱۳۹۵ دریافت نمود. از سال ۱۳۸۱ تاکنون بعنوان کارشناس مسئول اتوماسیون اداری سازمان جهاد کشاورزی استان همدان مشغول بکار می‌باشند. زمینه پژوهشی مورد علاقه ایشان پردازش تصویر و شبکه‌های عصبی مصنوعی است.



منصور اسماعیل پور مدرک کارشناسی و کارشناسی ارشد خود را در رشته مهندسی کامپیوتر-نرم افزار در سال‌های ۱۳۸۱ و ۱۳۸۳ دریافت نمود. وی مدرک دکتری را در رشته مهندسی کامپیوتر، گرایش هوش مصنوعی از

دانشگاه ملی مالزی در سال ۲۰۱۲ اخذ و از سال ۲۰۱۲ تا ۲۰۱۴ به عنوان فوق دکتری در همان دانشگاه به تحقیق و پژوهش پرداخت و همچنین از سال ۱۳۸۱ تاکنون عضو هیات علمی گروه مهندسی کامپیوتر دانشگاه آزاد اسلامی واحد همدان می‌باشد. زمینه پژوهشی مورد علاقه ایشان داده‌کاوی، فرآیندکاوی، پردازش تصویر و سیستم‌های یادگیر است.

- [9] J. Wang, L. Ji, A. Liang, and D. Yuan, "The identification of butterfly families using content-based image retrieval," *Biosystems engineering*, vol. 111, pp. 24-32, 2012.
- [10] K. M. Iftekharuddin and A. A. Awwal, *Field guide to image processing*: SPIE Press Bellingham, WA, 2012.
- [11] L. Feng and B. Bhanu, "Automated identification and retrieval of moth images with semantically related visual attributes on the wings," in *Image Processing (ICIP), 2013 20th IEEE International Conference on*, 2013, pp. 2577-2581.
- [12] V. Ojansivu and J. Heikkilä, "Blur insensitive texture classification using local phase quantization," in *Image and signal processing*, ed: Springer, 2008, pp. 236-243.
- [13] M. R. Banham and A. K. Katsaggelos, "Digital image restoration," *Signal Processing Magazine, IEEE*, vol. 14, pp. 24-41, 1997.
- [14] T. Ojala, M. Pietikainen, and T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 24, pp. 971-987, 2002.
- [15] T. Randen and J. H. Husoy, "Filtering for texture classification: A comparative study," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 21, pp. 291-310, 1999.
- [16] B. S. Manjunath and W.-Y. Ma, "Texture features for browsing and retrieval of image data," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 18, pp. 837-842, 1996.
- [17] A. Vo, S. Orintara, and T. T. Nguyen, "Using phase and magnitude information of the complex directional filter bank for texture image retrieval," in *Image Processing, 2007. ICIP 2007. IEEE International Conference on*, 2007, pp. IV-61-IV-64.
- [18] X. Liu and D. Wang, "Texture classification using spectral histograms," *Image Processing, IEEE Transactions on*, vol. 12, pp. 661-670, 2003.
- [19] F. Jurado and J. R. Saenz, "Comparison between discrete STFT and wavelets for the analysis of power quality events," *Electric Power Systems Research*, vol. 62, pp. 183-190, 2002.
- [20] M. Anthony and P. L. Bartlett, *Neural network learning: Theoretical foundations*: cambridge university press, 2009.
- [21] A. K. Alexandridis and A. D. Zapanis, "Wavelet neural networks: A practical guide," *Neural Networks*, vol. 42, pp. 1-27, 2013.
- [22] Y. Kaya and L. Kayci, "Application of artificial neural network for automatic detection of butterfly species using color and texture features," *The visual computer*, vol. 30, pp. 71-79, 2014.
- [23] Y. Kaya, L. Kayci, R. Tekin, and Ö. Faruk Ertuğrul, "Evaluation of texture features for automatic detecting