

طبقه‌بندی مکانی-طیفی تصاویر چندطیفی مبتنی بر خوشه‌بندی پیشینه‌سازی انتظار بهبود یافته

فرشته پورا‌هنگریان^۱، حسن قاسمیان^۲

۱دانشگاه آزاد اسلامی، واحد علوم و تحقیقات تهران، گروه مهندسی برق، f.ahangaryan@gmail.com

۲استاد دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس

تاریخ دریافت: ۹۳/۱/۱۷ تاریخ پذیرش: ۹۴/۳/۲۳

چکیده

امروزه، با افزایش دقت مکانی تصاویر سنجش از راه دور، امکان بکارگیری اطلاعات مکانی در فرآیند طبقه‌بندی وجود دارد. این امر منجر به افزایش دقت طبقه‌بندی تصاویر چندطیفی می‌گردد. یکی از روش‌های گنجاندن اطلاعات مکانی در طبقه‌بندی، بخش‌بندی بدون نظارت تصویر است که می‌تواند از طریق خوشه‌بندی پیشینه‌سازی انتظار (EM) و تخصیص برچسب به اجزای متصل انجام شود. اما EM همواره در معرض خطر قرار گرفتن در بهینه محلی قرار دارد. بنابراین در این مقاله، روش جدیدی به منظور بهبود روش خوشه‌بندی EM مطرح شده است که علاوه بر حل مشکل مذکور، دارای کارایی بهتری در طبقه‌بندی تصاویر چندطیفی می‌باشد. در این مقاله، پس از اعمال کاهش بعد LPP و کاهش باندهای طیفی، نتایج طبقه‌بندی مبتنی بر پیکسل و نقشه بخش‌بندی بدست آمده از روش ارائه شده، با استفاده از آرای اکثریت ترکیب می‌شوند تا طبقه‌بندی مکانی-طیفی شکل بگیرد. نتایج شبیه‌سازی نشان می‌دهد که طبقه‌بندی مکانی-طیفی ارائه شده منجر به بهبود قابل ملاحظه‌ای در دقت و اعتبار طبقه‌بندی تصاویر چندطیفی F210، نسبت به طبقه‌بندی مبتنی بر پیکسل شده است بطوریکه می‌تواند این تصاویر را با دقت ۸۷/۶۸٪ و اعتبار ۸۰/۸٪ طبقه‌بندی نماید.

کلیدواژه

طبقه‌بندی مکانی-طیفی، بخش‌بندی، طبقه‌بندی مبتنی بر پیکسل، روش خوشه‌بندی EM، LPP

مقدمه

احتمال (ML) [۲]، درخت تصمیم‌گیری [۳] و تکنیک‌های مبتنی بر کرنل [۴] مانند ماشین بردار پشتیبان (SVM) [۵]، برای این منظور ارائه شده‌اند.

امروزه با پیشرفت در تکنولوژی‌ها و تجهیزات تصویربرداری ابرطیفی، دقت مکانی تصاویر افزایش یافته است. چنانچه اطلاعات مکانی در فرآیند طبقه‌بندی مشارکت داده شوند، نتایج طبقه‌بندی بهبود می‌یابد [۶]. هدف از طبقه‌بندی مکانی-طیفی، تخصیص یک کلاس به هر پیکسل تصویر با استفاده از مقدار طیفی همان پیکسل (اطلاعات طیفی) و اطلاعات استخراج شده از همسایگی پیکسل (اطلاعات مکانی) می‌باشد. ایده اصلی این است که یک پیکسل، احتمالاً حاوی اطلاعات مشابهی با پیکسل‌های همسایه است. چنین طبقه‌بندی‌هایی نسبت به طبقه‌بندی‌هایی که فقط اطلاعات طیفی را بکار می‌گیرند مؤثرتر، مناسب‌تر و پایدارتر می‌باشند [۵]. میدان تصادفی مارکوف (MRF) [۷] و فیلترهای شکل-شناسی مبتنی بر پنجره ثابت [۸]، مدل‌هایی هستند که برای گنجاندن محتوای مکان در تحقیقات گذشته بکار گرفته شده‌اند.

سنجش از راه دور، دانشی است که روش‌های استخراج اطلاعات از پدیده‌ها بدون تماس فیزیکی آن‌ها را مورد بررسی قرار می‌دهد و هدف کلی آن بهبود این روش‌ها می‌باشد. یکی از کاربردهای مهم علم سنجش از راه دور، تخصیص یک کلاس به هر پیکسل تصویر است که از آن به عنوان طبقه‌بندی یاد می‌شود. پیشرفت‌های اخیر در تکنولوژی سنجش از راه دور، اجازه ضبط و ثبت هم زمان صداها طول موج طیفی را برای هر پیکسل تصویر می‌دهد. هم‌چنین دقت مکانی مناسب، آنالیز ساختارهای مکانی کوچک در تصویر را فراهم ساخته است. دقت طبقه‌بندی تصاویر سنجش از راه دور از اهمیت زیادی در کاربردهای عملی برخوردار است. هر پیکسل در تصاویر چندطیفی شامل مقادیری است که برابر با طیف نور بازتابی می‌باشد. این اطلاعات طیفی، توانایی تشخیص مواد فیزیکی و اشیای مختلف را می‌دهد [۱].

تحقیقات گسترده‌ای در زمینه طبقه‌بندی این تصاویر صورت گرفته است که رنج وسیعی از آن‌ها، تنها از اطلاعات طیفی برای تخصیص کلاس به هر پیکسل استفاده می‌کنند. روش‌های حداکثر

1Maximum Likelihood
2Support Vector Machine
3Markov Random Field

روش خوشه‌بندی سلسله مراتبی، به خوشه‌های نهایی بر اساس میزان عمومیت آن‌ها، ساختاری سلسله مراتبی معمولاً بصورت درخت نسبت داده می‌شود که به این درخت سلسله مراتبی دندوگرام می‌گویند. گروهی از محققین از خوشه‌بندی سلسله مراتبی در طبقه‌بندی بی نظارت تصاویر ابرطیفی استفاده کردند [۱۴]. اگرچه خوشه‌بندی سلسله مراتبی یک تکنیک ساده برای بخش‌بندی تصویر است اما به زمان محاسباتی زیادی نیاز دارد. به همین علت بکارگیری این روش در داده‌هایی با ابعاد بالا به زمان و حافظه قابل توجهی نیاز دارد و در دندوگرام‌های بزرگ به مشکل می‌رسد. بنابراین اغلب از روش خوشه‌بندی مبتنی بر تقسیم‌بندی برای بخش‌بندی تصاویر ابرطیفی استفاده می‌شود. اما مشکل این الگوریتم‌ها تعداد خوشه خروجی است که در داده‌های ابرطیفی با استفاده از نقشه مرجع بدست می‌آید. همچنین نتایج این روش به مقاردهی اولیه بستگی دارد. با اینحال بدلیل پیچیدگی محاسباتی کم‌تر، مطلوب‌تر است [۱].

یکی از روش‌های خوشه‌بندی متداول در سنجش از راه دور، روش خوشه‌بندی بیشینه‌سازی انتظار (EM) است، اما همواره در معرض قرار گرفتن در بهینه محلی قرار دارد [۱۵]. بنابراین، در این مقاله، روش خوشه‌بندی مبتنی بر EM بهبود یافته با قابلیت غلبه بر مشکل مذکور ارائه و از آن در طبقه‌بندی مکانی-طیفی تصاویر F210 استفاده شده است. این روش نسبتاً ساده و کارا، در مقایسه با چند روش طبقه‌بندی، از نظر دقت و اعتبار طبقه‌بندی برتری دارد.

ساختار کلی مقاله بصورت زیر است:

در بخش بعدی، روش خوشه‌بندی EM و بهبود یافته آن، توضیح داده می‌شود. سپس ساختار کلی طبقه‌بندهای مکانی-طیفی مبتنی بر خوشه‌بندی شرح داده شده است. در ادامه، نتایج شبیه‌سازی مورد بحث قرار گرفته‌اند و در نهایت، نتیجه‌گیری بیان شده است.

روش خوشه‌بندی بیشینه‌سازی انتظار (EM)

مدل مخلوط گوسی یک مدل قدرتمند برای خوشه‌بندی داده‌هاست و داده‌ها را به عنوان ترکیبی از توزیع گوسی چندگانه که هر جز گوسی متعلق به یک خوشه می‌باشد، مدل می‌کند. هدف اصلی در این مدل، تخمین پارامترهاست که بطور معمول توسط الگوریتم EM انجام می‌شود. برای خوشه‌بندی یک تصویر چندطیفی به کمک تکنیک EM، فرض می‌کنیم که پیکسل‌های متعلق به خوشه‌های یکسان دارای توزیع احتمال گوسی چند متغیره هستند. اگر تصویر چندطیفی ورودی را به عنوان یک دسته بردار n پیکسلی در نظر بگیریم بطوریکه:

پردازش شکل‌شناسی معمولاً به منظور تحلیل وابستگی پیکسل مورد استفاده قرار می‌گیرد. اگرچه این روش‌ها از نتایج مناسبی برخوردار بودند اما انتخاب سائز پنجره خصوصاً در تصاویری که از ساختارهای پیچیده و کوچک برخوردارند، یک چالش اساسی در روش‌های مذکور است. به همین علت، روش همسایگی وقتی در تصاویر چندطیفی شکل گرفت. تعریف این همسایگی براساس ساختارهایی که پیکسل به آن تعلق دارد صورت می‌گیرد. نمونه‌هایی از این روش در [۱۰]-[۹] ارائه شده‌اند. روش دیگر برای گنجانیدن اطلاعات مکانی در فرآیند طبقه‌بندی با بخش‌بندی تصویر آغاز می‌گردد [۱۳]-[۱۱]. بخش‌بندی یک ابزار قوی برای تعریف وابستگی‌های مکانی است. بخش‌بندی یک تصویر، تقسیم یک تصویر با توجه به بعضی از شاخص‌های موردنظر یا معیار همگنی (به عنوان مثال براساس چگالی یا بافت) به نواحی همگنی است که با یکدیگر تداخل نداشته باشند. بنابراین، هر ناحیه در نقشه بخش‌بندی، یک همسایگی مکانی برای تمام پیکسل‌های درون ناحیه می‌باشد. از آنجا که در بخش‌بندی از همسایگی وقتی استفاده می‌شود در مقایسه با تکنیک‌هایی که از همسایگی محلی استفاده می‌کنند، کارا تر است. همچنین به کمک این روش، به ازای نواحی همگن بزرگ، همسایگی‌های بزرگ استخراج می‌شود و این درحالیست که نواحی کوچک که شامل یک یا چند پیکسل هستند از بین نمی‌روند. اگر چه ایجاد نقشه بخش‌بندی با استفاده از استخراج اشیای همگن از سرعت بیشتری نسبت به روش‌هایی که در آن‌ها پیکسل مورد آنالیز قرار می‌گیرد برخوردار است اما روش‌های آماری بکاررفته در این خصوص بخوبی برای تصاویر ابرطیفی تطبیق داده نمی‌شوند. روش دیگر، استفاده از روش‌های بخش‌بندی بدون نظارت است. سه دسته از تکنیک‌های بخش‌بندی تصویر عبارتند از: ۱- تکنیک‌های مبتنی بر لبه ۲- تکنیک‌های مبتنی بر ناحیه (به عنوان مثال می‌توان به حوضچه آبگیر [۱۱] اشاره کرد) ۳- آستانه‌گذاری یا خوشه‌بندی. تکنیک‌های مبتنی بر لبه و ناحیه در حوزه مکان عمل می‌کنند اما دسته سوم در حوزه طیفی عمل می‌کند. از ویژگی‌های این دسته می‌توان به سهولت پیاده‌سازی و سرعت محاسبات اشاره نمود. هدف از بخش-بندی مبتنی بر خوشه‌بندی، یافتن ساختارهای مجزا در فضای ویژگی طیفی است.

خوشه‌بندی مهم‌ترین مسأله در یادگیری بدون نظارت است. خوشه‌بندی یافتن یک ساختار درون مجموعه‌ای از داده‌های بدون برچسب است. خوشه به مجموعه‌ای از داده‌ها گفته می‌شود که به هم شباهت داشته باشند. در خوشه‌بندی سعی می‌شود تا داده‌ها به خوشه‌هایی تقسیم شوند که شباهت بین داده‌ها درون هر خوشه حداکثر و شباهت بین داده‌های درون خوشه‌های متفاوت حداقل شود. دو گروه اساسی از روش‌های خوشه‌بندی عبارتند از: روش‌های سلسله مراتبی و روش‌های مبتنی بر تقسیم‌بندی. در

اگر m_c^i کمتر از بعد الگوها باشد، آن خوشه حذف می‌شود و نمونه‌هایی که جز خوشه حذف شده هستند باید در تکرارهای بعدی به خوشه‌های دیگر تخصیص داده شوند. در صورتیکه معیار همگرایی حاصل نشد به گام تخمین پارامتر برمی‌گردیم [۱]. تعداد پارامترهایی که باید تخمین زده شود از فرمول زیر بدست می‌آید:

$$P = \frac{B(B+1)}{(2+B+1)C+1} \quad (10)$$

با توجه به فرمول فوق، اگر بعد بردار ویژگی، بزرگ باشد ممکن است منجر به بروز مشکلاتی در منفرد بودن ماتریس کواریانس یا اشتباه در نتایج تخمین پارامتر شود.

عیب روش خوشه‌بندی بیان شده این است که اگر یکی از اجزای ترکیب گوسی، در مقایسه با سایر اجزا از ضریب ترکیبی کوچکی برخوردار باشد، امکان هم‌پوشانی بین اجزای ترکیب وجود دارد [۱۵]. به منظور جلوگیری از گیرافتادن در بهینه محلی و از آنجا که در تصاویر چندطیفی تشخیص خوشه‌ها یا ساختارهای کوچک از اهمیت زیادی برخوردار است، در این مقاله، روشی برای بهبود روش خوشه‌بندی EM پیشنهاد شده است که در بخش بعدی به توضیح آن پرداخته می‌شود.

الگوریتم پیشنهادی به منظور بهبود روش خوشه‌بندی EM

این الگوریتم برگرفته از الگوریتم EM است و گام تخمین پارامتر را با استفاده از پارامتر β بهبود می‌بخشد. در الگوریتم خوشه بندی EM متداول که در آن β همواره برابر یک است، به ازای خوشه های بسیار کوچک، تخمین پارامترها حتی به ازای تکرار زیاد نیز هم پوشانی زیادی دارد. در $\beta \rightarrow 0$ تمام خوشه ها با هم تداخل دارند و احتمال پیشین یکسان می‌شود. بنابراین با افزایش β از صفر تا یک هم پوشانی کم تر و کم تر خواهد شد. در آغاز الگوریتم، پارامتر β تقریباً برابر صفر است و به آرامی افزایش می‌یابد تا به یک برسد. در هر مقدار از β ، مراحل تخمین پارامتر و تخصیص خوشه انجام می‌شود و سایر مراحل مانند الگوریتم EM است. تخصیص خوشه با توجه به رابطه زیر و بر اساس قاعده ذکر شده در الگوریتم EM صورت می‌گیرد.

$$\Pr(c|X_j) = \frac{(w_c^i \theta_c(X_j; \mu_c^i, \Sigma_c^i))^\beta}{\sum_{c=1}^C (w_c^i \theta_c(X_j; \mu_c^i, \Sigma_c^i))^\beta} \quad (11)$$

طبقه‌بندی مکانی-طیفی مبتنی بر خوشه‌بندی

همانطور که در تشریح روش خوشه‌بندی بیان شد، تعداد پارامترهایی که باید تخمین زده شود با بعد بردار ویژگی ارتباط مستقیم دارد. همچنین اگرچه به نظر می‌رسد وجود داده‌هایی با ابعاد بالاتر، منجر به افزایش دقت طبقه‌بندی می‌شود، با این وجود به دلیل پدیده هیوز، چنانچه تعداد نمونه‌های آموزشی ثابت باشد،

$$x = \{x_j \in R^B \quad j = 1, 2, \dots, n\} \quad (1)$$

و B تعداد باندهای طیفی فرض شود، آنگاه هر پیکسل تصویر می‌تواند بصورت آماری با تابع چگالی زیر مدل شود:

$$P(x) = \sum_{c=1}^C w_c \varphi_c(x; \mu_c, \Sigma_c) \quad (2)$$

در فرمول فوق، تعداد خوشه‌ها، μ_c و Σ_c به ترتیب بردار میانگین و ماتریس کواریانس خوشه‌ها و w_c بیانگر وزن سهم خوشه‌ها در ترکیب می‌باشد که متعلق به بازه [۰، ۱] است. در انتخاب این اوزان باید دقت نمود که رابطه (۳) برقرار باشد. φ_c نیز از رابطه (۴) بدست می‌آید.

$$\sum_{c=1}^C w_c = 1 \quad (3)$$

$$\varphi_c(x; \mu_c, \Sigma_c) = \frac{1}{(2\pi)^{\frac{B}{2}}} \cdot \frac{1}{|\Sigma_c|^{\frac{1}{2}}} e^{-\frac{1}{2}(x-\mu_c)^T \Sigma_c^{-1} (x-\mu_c)} \quad (4)$$

الگوریتم خوشه‌بندی EM بصورت زیر است:

مجموعه n بردار ویژگی را X در نظر بگیرید. تعداد خوشه‌ها را برابر با تعداد کلاس‌ها در نظر می‌گیریم که تعداد کلاس‌ها از نقشه مرجع بدست می‌آید. مراکز خوشه‌ها بصورت تصادفی از مجموعه داده‌ها انتخاب می‌گردد.

مقداردهی اولیه (تکرار صفرام): در تکرار صفرام c_{max} در نظر گرفته می‌شود و داده‌هایی که جز مراکز خوشه‌ها نیستند بر اساس فاصله اقلیدسی به مراکز خوشه‌ها تخصیص داده می‌شوند. منظور از c_{max} حداکثر تعداد خوشه‌هاست.

برای هر تکرار $i > 0$ ، مراحل زیر صورت می‌گیرد:

تخمین پارامتر: پارامترهای μ_c^i و Σ_c^i ($c = 1, 2, \dots, C$) با استفاده از فرمول‌های زیر تقریب زده می‌شوند:

$$\mu_c^i = \frac{1}{m_c^{i-1}} \sum_{j=1}^{m_c^{i-1}} X_{j,c}^{i-1} \quad (5)$$

$$\Sigma_c^i = \frac{1}{m_c^{i-1}} \sum_{j=1}^{m_c^{i-1}} (X_{j,c}^{i-1} - \mu_c^i)(X_{j,c}^{i-1} - \mu_c^i)^T \quad (6)$$

$$w_c^i = \frac{m_c^{i-1}}{n} \quad (7)$$

در فرمول‌های فوق، m_c^i معرف تعداد پیکسل‌های خوشه c ام در تکرار i ام است. همچنین، μ_c^i و Σ_c^i به ترتیب بیانگر بردار میانگین و ماتریس کواریانس خوشه c ام در تکرار i ام می‌باشند. تخصیص خوشه: هر نمونه از X به یکی از خوشه‌ها بر اساس معیار ماکزیمم احتمال قبلی تخصیص می‌یابد.

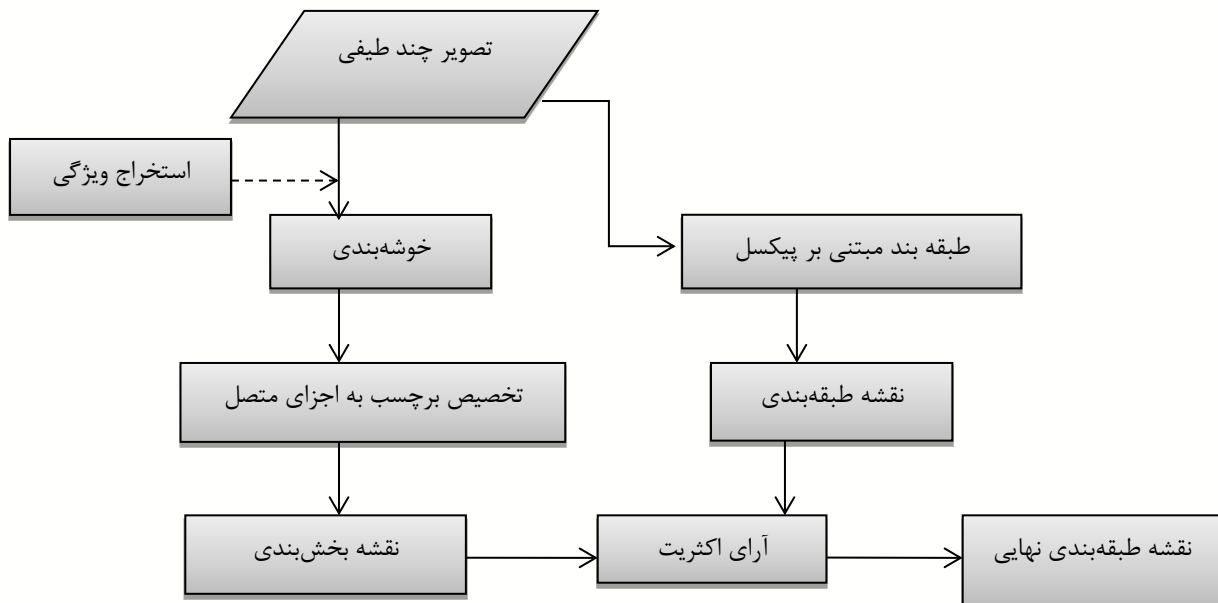
$$X_j \in Q_c^i : \Pr(c|X_j) = \max \Pr(l|X_j) \quad (8)$$

$$\Pr(c|X_j) = \frac{w_c^i \theta_c(X_j; \mu_c^i, \Sigma_c^i)}{\sum_{c=1}^C w_c^i \theta_c(X_j; \mu_c^i, \Sigma_c^i)} \quad (9)$$

افزایش ویژگی منجر به کاهش دقت طبقه‌بندی می‌گردد [۲]. با توجه به دلایل ذکر شده، کاهش بعد، کاهش بعد، یک مسأله اساسی در طبقه‌بندی تصاویر چندطیفی محسوب می‌گردد. کاهش بعد، تبدیل تصویر چندطیفی از فضای M بعدی به فضای N بعدی است که $N < M$ می‌باشد. در نتیجه اولین مرحله استفاده از روش‌های کاهش بعد مانند LPP^o است. از آنجا که استفاده از اولین مؤلفه اساسی ممکن است موجب از دست دادن بعضی از اطلاعات شود، لذا بکارگیری چند مؤلفه، ضریب اطمینان بیشتری را ایجاد می‌کند.

در این مرحله، الگوریتم خوشه‌بندی پیشنهاد شده بر باندهای انتخابی صورت می‌گیرد و نقشه خوشه‌بندی حاصل می‌شود. در نقشه خوشه‌بندی، هر پیکسل دارای برچسبی است که نشان‌دهنده خوشه‌ای است که پیکسل متعلق به آن است. از آنجا که از هیچ‌گونه اطلاعات مکانی در فرآیند خوشه‌بندی استفاده نشده است، پیکسل‌هایی که به خوشه یکسانی تعلق دارند ممکن است به نواحی مجزا در مختصات مکانی تعلق پیدا کنند. بنابراین برای ایجاد نقشه بخش‌بندی از نتایج خوشه‌بندی باید از الگوریتم برچسب‌گذاری اجزای متصل [۱۶]، استفاده کنیم. پس می‌توان گفت بخش‌بندی به کمک خوشه‌بندی شامل دو مرحله است:

۱- خوشه بندی ۲- تخصیص برچسب به اجزای متصل



شکل ۱. ساختار کلی طبقه‌بندی مکانی-طیفی مبتنی بر خوشه‌بندی

زیر تعریف می‌شود:

$$D_{ii} = \frac{1}{N} \sum_{j=1}^N A_{ij} \quad (15)$$

همچنین، ماتریس پراکندگی محلی S^L ، به کمک رابطه (15) محاسبه می‌شود:

$$S^L = \frac{1}{2} \sum_{i,j=1}^N W_{ij} (x_i - x_j)(x_i - x_j)^T \quad (16)$$

در رابطه فوق، N تعداد است و W_{ij} را می‌توان به کمک رابطه زیر محاسبه نمود:

$$W_{ij} = \frac{1}{N} A_{ij} \quad (17)$$

در این روش، ماتریس انتقال با استفاده از بهینه سازی رابطه (18) تعیین می‌گردد:

$$J_{LPP} = \text{tr}((S)^{-1} - S^L) \quad (18)$$

رابطه فوق نشان می‌دهد که اگر دو نمونه در فضای اولیه نزدیک باشند، ماتریس انتقال بدست آمده از LPP به گونه‌ای است که دو نمونه در فضای انتقال یافته به یکدیگر نزدیکتر خواهند شد. بنابراین LPP می‌تواند شباهت درون کلاسی را افزایش دهد.

طبقه‌بند مبتنی بر پیکسل حداکثر احتمال (ML)

طبقه‌بند مبتنی بر پیکسل، طبقه‌بندی است که هر پیکسل تصویر را بطور مستقل و بدون در نظر گرفتن هم‌بستگی بین پیکسل‌های همسایه مورد پردازش قرار می‌دهد. طبقه‌بند حداکثر احتمال، یکی از طبقه‌بندهای بانظرات است که بر پایه تئوری بیزین بوده و تابع توزیع کلاس‌ها بصورت نرمال فرض می‌شود. بنابراین با وجود نمونه‌هایی با n باند طیفی یا ویژگی، اگر μ_i و C_i به ترتیب بردار میانگین و ماتریس کواریانس کلاس λ_m باشند، تابع توزیع کلاس‌ها بصورت رابطه زیر خواهد بود:

$$P(X|C_i) = (2\pi)^{\frac{n}{2}} |C_i|^{-\frac{1}{2}} \exp\left(-\frac{1}{2} (x - \mu_i)^T C_i^{-1} (x - \mu_i)\right) \quad (19)$$

در این رابطه $P(x | c_i)$ احتمال پسین است. می‌توان با استفاده از اپراتور لگاریتم به تابع ساده‌تری مانند رابطه زیر دست یافت.


$$g_i(x) = \ln|C_i| + (x - \mu_i)^T C_i^{-1} (x - \mu_i) \quad (20)$$

با در نظر گرفتن تابع فوق، کلاسی که تابع ممیز مربوط به آن حداقل باشد به نمونه تخصیص داده می‌شود [18].

طبقه‌بند ماشین بردار پشتیبان (SVM)

SVM خطی به دنبال یافتن یک ابر صفحه است که نمونه‌ها را به دو کلاس با بیشینه کردن حاشیه بین آن‌ها طبقه‌بندی کند. یافتن ابر صفحه باید به گونه‌ای باشد که حاشیه بین دو کلاس بیشینه و مقدار خطا کمینه باشد. از آنجا که جدا کردن کلاس‌هایی که هم-پوشانی داشته باشند با استفاده از مرز خطی فوق مشکل است،

عملکرد الگوریتم آرای اکثریت به این صورت است که در هر ناحیه از تصویر بخش‌بندی، شایع‌ترین کلاس در آن ناحیه به تمام پیکسل‌های آن ناحیه تخصیص می‌یابد. شکل ۲ به تشریح این الگوریتم می‌پردازد. جزئیات مطالب فوق در بخش‌های بعدی توضیح داده شده است:



شکل ۲. تشریح عملکرد الگوریتم آرای اکثریت

روش کاهش بعد LPP

LPP یک الگوریتم کاهش بعد است که می‌تواند بردارهای ویژگی را با حفظ روابط محلی در فضای غیرخطی مدل کند و به همین علت نسبت به الگوریتم‌های کاهش بعد متداول مانند PCA برتری دارد. اساس کار این الگوریتم به این صورت است که اگر A ماتریس نزدیکی تعریف شود و نزدیکی بین دو نمونه x_i و x_j را محاسبه نماید، آنگاه درایه‌های متناظر دو نمونه در این ماتریس، مقداری بین صفر و یک خواهند داشت. در صورتیکه که دو نمونه به یکدیگر نزدیک باشند، مقدار درایه متناظر به سمت یک و هر چقدر که دور باشند مقدار آن، به سمت صفر میل خواهد کرد. روش‌های متفاوتی برای محاسبه این ماتریس وجود دارد. روش بکار رفته در این مقاله، براساس فرمول (12) است [17].

$$A_{ij} = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma_i \sigma_j}\right) \quad (12)$$

اگر k امین همسایگی از x_i بصورت $x_i^{(k)}$ تعریف شود، پارامتر σ_i یک مقیاس محلی در اطراف x_i است که از رابطه (13) بدست می‌آید. همچنین مقدار $x_i^{(k)}$ ، بطور شهودی انتخاب می‌گردد.

$$\sigma_i = \|x_i - x_i^{(k)}\| \quad (13)$$

ماتریس پراکندگی S بصورت زیر محاسبه می‌شود:

$$S = XDX^T \quad (14)$$

در رابطه فوق، D یک ماتریس قطری است که رابطه آن بصورت

پیکسل، کلاسی است که تعداد دفعات بیش‌تری به آن پیکسل تعلق یافته است.

- یکی در برابر همه $(OAA)^Y$: در این روش برای هر پیکسل یک طبقه‌بندی کننده وجود دارد. بنابراین اگر تعداد کلاس‌ها n باشد، n بار SVM بکار گرفته می‌شود. جهت آموزش n امین طبقه‌بند از نمونه‌های آموزشی کلاس n ام در برابر سایر نمونه‌های آموزشی استفاده می‌شود.

نتایج آزمایش‌ها

مجموعه داده F210 از تصاویر چندطیفی برای انجام آزمایش‌ها در این بخش مورد استفاده قرار گرفته‌اند. این داده، مربوط به یک ناحیه کشاورزی در ایندیانا است و شامل ۱۲ باند و ۹ کلاس می‌باشد. اطلاعات این باندها بصورت یک ماتریس 140×220 قابل دسترسی است. شبیه‌سازی به کمک نرم‌افزار MATLAB انجام شده است.

از روش کاهش بعد LPP به منظور کاهش بعد و از طبقه‌بند مبتنی بر پیکسل ML و طبقه‌بند معروف و پرکاربرد SVM در حالت چندکلاسه با استفاده از روش یکی در برابر یکی برای طبقه‌بندی اولیه داده، استفاده شده است. پس از اعمال روش‌های کاهش بعد بر تصاویر و کاهش باندهای طیفی، باندهای انتخاب شده، تحت خوشه‌بندی پیشنهاد شده قرار می‌گیرند. سپس برچسب گذاری اجزای متصل صورت می‌گیرد تا نقشه بخش‌بندی بدست آید. این نقشه و نقشه ایجاد شده توسط طبقه‌بند مبتنی بر پیکسل توسط الگوریتم آرای اکثریت ترکیب می‌شود و نقشه طبقه‌بندی نهایی بدست می‌آید. روند انجام شبیه‌سازی مطابق نمودار نشان داده شده در شکل ۱ است.

به منظور ارزیابی کارایی سیستم پیشنهادی از دو معیار صحت و اعتبار استفاده شده است. منظور از دقت یا صحت طبقه‌بند در هر کلاس، نسبت تعداد نمونه‌ها یا پیکسل‌هایی که درست در کلاس مربوطه طبقه‌بندی شده‌اند به تعداد کل نمونه‌هایی که به کلاس مربوطه تعلق داشته‌اند، می‌باشد و منظور از اعتبار طبقه‌بند در هر کلاس نسبت تعداد نمونه‌ها یا پیکسل‌هایی که درست در کلاس مربوطه طبقه‌بندی شده‌اند به تعداد کل نمونه‌هایی که در کلاس مربوطه طبقه‌بندی شده‌اند، است. همچنین دقت متوسط و اعتبار متوسط طبقه‌بندی نیز ارائه شده است. دقت متوسط، میانگین دقت به دست آمده برای تمام کلاس‌ها و اعتبار متوسط نیز برابر میانگین اعتبار به دست آمده برای تمام کلاس‌ها می‌باشد.

در جدول ۱، دقت و اعتبار طبقه‌بندی کلاس‌ها در سه روش نشان داده شده است. روش اول، طبقه‌بند مبتنی بر پیکسل است که بدون استفاده از اطلاعات مکانی به طبقه‌بندی می‌پردازد. برای این منظور SVM و ML بکار گرفته شده است. روش دوم، طبقه‌بند

بنابراین ابتدا داده‌ها از فضای اصلی R^n با تابع غیرخطی به فضایی با بعد بیشتر منتقل می‌شود [۱۹]. بردارهای پشتیبان در ساخت ابر صفحه نقش دارند. فرض کنید داده‌ها از دو کلاس تشکیل شده و کلاس‌ها در مجموع دارای $X_i, i = 1, \dots, L$ نقطه آموزشی باشند که X_i یک بردار است. این دو کلاس با $y_i = \pm 1$ برچسب زده می‌شوند. ابرصفحه با حل مسأله بهینه‌سازی قید دار زیر مشخص می‌گردد.

$$\begin{cases} \min \left\{ \frac{1}{2} \|w\|^2 \right\} \\ w, b \\ y_i (wx_i + b) \geq 1 \quad i = 1, \dots, L \end{cases} \quad (21)$$

در فرمول فوق، w ، یک بردار n بعدی عمود بر ابرصفحه و $\frac{b}{\|w\|}$ فاصله مبدا تا ابرصفحه است. برای ساده‌تر شدن مسأله بهینه‌سازی (۲۱) می‌توان آن را با ضرائب لاگرانژ بصورت زیر تبدیل کرد. α_i ها، ضرائب لاگرانژ هستند.

$$\max \left(\sum_{i=1}^L \alpha_i - \frac{1}{2} \sum_{i=1}^L \sum_{j=1}^L \alpha_i \alpha_j y_i y_j K(x_i, x_j) \right) \quad (22)$$

$$\sum_{i=1}^K \alpha_i y_i = 0, \quad 0 < \alpha_i < c, \quad 0 < c < \infty$$

$K(x_i, x_j)$ تابع غیرخطی برای انتقال داده‌ها به فضایی با بعد بیشتر است. بعد از تعیین ضرائب لاگرانژ، w از رابطه زیر بدست می‌آید.

$$w = \sum_{i=1}^K \alpha_i y_i x_i \quad (23)$$

α_i مربوط به بردار پشتیبان، بزرگتر از صفر و α_i مربوط به نقاط دیگر صفر خواهد بود.

برای بدست آوردن مرز تصمیم‌گیری فقط نیاز به تعداد محدودی از نقاط آموزشی که همان بردارهای پشتیبان هستند، می‌باشد و همه آن‌ها لازم نیستند. پس از یافتن w ، مقدار b به ازای بردارهای پشتیبان مختلف از رابطه زیر بدست می‌آید و b نهایی از میانگین b های حاصل بدست می‌آید.

$$\alpha_i [y_i (wx_i + b) - 1] = 0, \quad i = 1, \dots, L \quad (24)$$

طبقه‌بندی کننده نهایی بصورت زیر خواهد بود [۱۹].

$$f(x, \alpha_1, \dots, \alpha) = \text{sgn} \left(\sum_{i=1}^K \alpha_i y_i K(x_i, x) + b \right) \quad (25)$$

همانگونه که بیان شد SVM معمولی فقط قادر به تفکیک دو کلاس می‌باشد و برای طبقه‌بندی چند کلاسه دو راهکار مهم وجود دارد [۵]:

- یکی در برابر یکی (OAO): در این روش کلاس‌ها بصورت دو به دو تفکیک می‌شوند. بنابراین اگر تعداد کلاس‌ها n باشد، $\frac{n(n-1)}{2}$ بار SVM بکار گرفته می‌شود. در نهایت کلاس اختصاص یافته به هر


۲- در هر دو حالت بررسی شده با استفاده از روش پیشنهادی، می-توان به این نتیجه رسید که بکارگیری این روش منجر به افزایش دقت و اعتبار طبقه‌بندی نسبت به حالتی که از خوشه‌بندی EM یا از طبقه‌بند مبتنی بر پیکسل استفاده کرده‌ایم، شده است. شکل ۳، نقشه‌های طبقه‌بندی بدست آمده را به همراه نقشه مرجع و شکل ۴ نمودار مقایسه دقت و اعتبار طبقه‌بندی در الگوریتم‌های شبیه‌سازی شده را نشان می‌دهد. روند نمودار نیز حاکی از افزایش دقت و اعتبار طبقه‌بندی با استفاده از روش پیشنهادی است.

مکانی-طیفی است که در آن برای طبقه‌بندی اولیه داده، یکبار از SVM و بار دیگر از ML و برای بخش‌بندی از خوشه‌بندی EM استفاده شده است. روش سوم، طبقه‌بند مکانی-طیفی پیشنهادی است که در آن از خوشه‌بندی ارائه شده در مقاله برای استخراج اطلاعات مکانی و از طبقه‌بند SVM و ML برای بدست آوردن نقشه طبقه‌بندی اولیه استفاده شده است. می‌توان با مشاهده نتایج جدول به نکات زیر دست یافت:


۱- اعتبار طبقه‌بند مبتنی بر پیکسل در بهترین حالت ۷۶/۱۴٪ است در حالیکه در روش دوم که از طبقه‌بند مکانی-طیفی با خوشه‌بندی EM استفاده شده است، بهترین اعتبار بدست آمده ۷۷/۳۶٪ است و در روش سوم که از طبقه‌بند مکانی-طیفی با خوشه‌بندی پیشنهادی استفاده شده است، بهترین اعتبار بدست آمده ۸۰/۸۷٪ است. این اعداد بیانگر این مطلب می‌باشند که بکارگیری طبقه‌بندهای مکانی-طیفی منجر به افزایش اعتبار طبقه‌بندی نسبت به طبقه‌بند مبتنی بر پیکسل می‌شود.

جدول ۱. دقت و اعتبار طبقه‌بندی کلاس‌ها در ۳ روش طبقه‌بندی برای داده‌ی F210

روش	طبقه‌بند مبتنی بر پیکسل				طبقه‌بند مکانی-طیفی با خوشه‌بندی EM				روش پیشنهادی			
	ML		SVM		ML/EM		SVM/EM		ML/Proposed Segmentation		SVM/Proposed Segmentation	
	دقت	اعتبار	دقت	اعتبار	دقت	اعتبار	دقت	اعتبار	دقت	اعتبار	دقت	اعتبار
شماره کلاس												
۱	۹۰/۷	۹۸/۹۵	۹۴/۳۲	۹۲/۸	۹۲/۹۲	۹۸/۴۶	۹۴/۹۶	۹۳/۶۶	۹۳/۳۶	۹۸/۵	۹۴/۸۲	۹۳/۸۷
۲	۹۰/۸۳	۹۸/۲۳	۹۳/۸	۹۸/۰۸	۹۴/۸۵	۹۸/۰۹	۹۵/۶۵	۹۸/۰۱	۹۳/۴	۹۸/۴۴	۹۳/۷۳	۹۷/۸۶
۳	۸۹/۹۷	۲۸/۳۶	۸۵/۳۵	۵۴/۲۵	۸۵/۳۵	۶۹/۴۶	۸۳/۵۵	۸۶/۶۷	۸۹/۹۷	۵۷/۱۹	۹۱/۷۷	۷۱/۴
۴	۸۶/۶۵	۵۱/۴۷	۸۷/۳۹	۴۶/۷	۸۹/۸۳	۶۱/۵۴	۸۹/۹۴	۵۵/۹۷	۹۳/۴۳	۷۲/۹۵	۹۲/۱۶	۵۸/۵۹
۵	۹۶/۸	۹۵/۶۲	۹۶/۹۶	۹۲/۴۲	۹۷/۱۳	۹۰/۲۴	۹۷/۱۳	۹۰/۳۸	۹۷/۲۹	۸۲/۸۸	۹۷/۲۹	۸۱/۳۴
۶	۸۴/۴۱	۴۸/۲	۸۱/۷۶	۶۵/۷۳	۶۸/۶۶	۷۳/۶۷	۹۵/۳۶	۵۷/۰۴	۷۲/۶۴	۷۸/۹۲	۷۲/۱۴	۸۲/۳۹
۷	۹۷/۹۴	۹۲/۲۲	۹۵/۸۷	۸۴/۴۲	۹۵/۵۸	۶۷/۶۴	۹۵/۲۸	۶۴/۷	۹۷/۹۴	۸۱/۹۸	۹۷/۹۴	۷۹/۰۵
۸	۸۶/۳۳	۶۹/۷	۷۹/۰۹	۶۱/۹۱	۷۸/۲۸	۵۵/۱۵	۴۸/۵۳	۶۲/۷۴	۷۳/۳۲	۸۲/۰۱	۶۹/۷۱	۷۲/۰۲
۹	۷۱/۹۱	۷۹/۵۶	۶۱/۱۷	۸۸/۹۳	۷۶/۸۵	۷۷/۵۹	۶۵/۶	۸۷/۰۸	۸۶/۶	۷۴/۹۹	۷۲/۱۹	۸۲/۱۶
دقت و اعتبار متوسط (%)	۸۸/۳۹	۷۳/۶	۸۶/۱۹	۷۶/۱۴	۸۶/۶	۷۶/۸۷	۸۵/۱۱	۷۷/۳۶	۸۸/۶۶	۸۰/۸۷	۸۶/۸۶	۷۹/۸۵



شکل ۳. نقشه‌ی کلاس به دست آمده برای سه روش طبقه‌بندی به همراه GTM داده‌ی F210



شکل ۴. نمودار مقایسه دقت و اعتبار طبقه‌بندی در الگوریتم‌های شبیه‌سازی شده

attribute filters for the analysis classification of hyperspectral data,” *Int. J. Remote Sens.*, 2010, vol. 31, no. 22, pp. 5975–5991.

[9] L. Denis, F. Tupin, J. Darbon, and M. Sigelle, “SAR image regularization with fast approximate discrete minimization,” *IEEE Trans. Image Process.*, 2009, vol. 18, no. 7, pp. 1588–1600.

[10] S. Le Hegarat-Masclé, A. Kallel, and X. Descombes, “Ant colony optimization for image regularization based on a nonstationary markov modeling,” *IEEE Trans. Image Process.*, 2007, vol. 16, no. 3, pp. 865–878.

[11] Y. Tarabalka, J. Chanussot, and J.A. Benediktsson, “Segmentation and classification of hyperspectral images using watershed transformation,” *Pattern Recogn.*, 2010, vol. 43, no. 7, pp. 2367–2379.

[12] Y. Tarabalka, J.A. Benediktsson, J. Chanussot, and J.C. Tilton, “Multiple spectral-spatial classification approach for hyperspectral data,” *IEEE Trans. Geosci. and Remote Sens.*, 2010, vol. 48, no. 11, pp. 4122–4132.

[13] J.C. Tilton, Y. Tarabalka, P. M. Montesano, and E. Gofman, “Best merge region growing segmentation with integrated non-adjacent region object aggregation,” *IEEE Trans. Geosci. Remote Sens.*, 2012, vol. 50, no. 10.

[14] S. Lee and M. Crawford, “Unsupervised multistage image classification using hierarchical clustering with a Bayesian similarity measure,” *IEEE Trans. Image Process.*, 2005, vol. 14, no. 3, pp. 312–320.

[15] Ueda, N. and Nakano, R. Deterministic annealing EM algorithm. *Neural Networks*, 1998, vol. 11, no. 2, pp. 271–282

[16] Suzuki K., Isao H., and Noboru S., “Linear-Time Connected-Component Labeling Based on Sequential Local Operations”, *Computer Vision and Image Understanding*, 2003, vol. 89, no. 1, pp. 1–23, Academic Press.

[17] L. Zenlik Manor and P. Perona, “Self-tuning spectral clustering,” advances in neural information processing systems, Cambridge, ma: mit press, 2005, vol. 17, pp. 1601–1608.

[18] R.O. Duda, P.e. Hart, and D.G. Stock, “Pattern classification”, *Second Edition*, Wiley, 2001.

[19] V. Vapnik and A. Chervonenkis, “The necessary and sufficient conditions for consistency in the empirical risk minimization method,” *Pattern Recognition and Image Analysis*, 1991, vol. 1, no. 3, pp. 283–305.

نتیجه گیری

در این مقاله، از یک طبقه‌بند مکانی-طیفی به منظور طبقه‌بندی تصاویر F210 استفاده شده است که در آن، تعریف ساختار مکانی توسط روش بخش‌بندی صورت می‌گیرد. برای بخش‌بندی از خوشه‌بندی مبتنی بر بیشینه‌سازی انتظار (EM) و تخصیص برچسب به اجزای متصل استفاده گردید. به منظور بهبود روش خوشه‌بندی EM و جلوگیری از گیرافتادن در بهینه محلی، روش پیشنهاد شده است که با تغییر در توابع مربوط به تخصیص خوشه، گام تخمین پارامتر و تخصیص خوشه را تحت تأثیر قرار می‌دهد و به این ترتیب، امکان هم‌پوشانی بین اجزا از بین رفته و تشخیص ساختارهای کوچک در تصاویر چندطیفی با دقت بیشتری صورت می‌گیرد. به همین علت، روش پیشنهادی می‌تواند یک روش مناسب برای طبقه‌بندی مکانی-طیفی مبتنی بر خوشه‌بندی برای تصاویر چندطیفی باشد. همچنین بکارگیری روش بیان شده منجر به بهبود قابل ملاحظه‌ای در معیار دقت و اعتبار طبقه‌بندی نسبت به طبقه‌بندی مکانی-طیفی بر پیکسل و طبقه‌بندی مبتنی بر خوشه‌بندی EM شده است.

مرجع‌ها

[1] Y. Tarabalka, J.A. Benediktsson, and J. Chanussot, “Spectral spatial classification of hyperspectral imagery based on partitional clustering techniques,” *IEEE Trans. Geosci. and Remote Sens.*, 2009, vol. 47, no. 9, pp. 2973–2987.

[2] D. A. Landgrebe, *Signal Theory Methods in Multispectral Remote Sensing*. New York: Wiley, 2003.

[3] P. K. Goel, S. O. Prasher, R. M. Patel, J. A. Landry, R. B. Bonnell, and A. A. Viau, “Classification of hyperspectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn,” *Comput. Electron. Agric.*, 2003, vol. 39, no. 2, pp. 67–93.

[4] G. Camps-Valls and L. Bruzzone, “Kernel-based methods for hyperspectral image classification,” *IEEE Trans. Geosci. Remote Sens.*, 2005, vol. 43, no. 6, pp. 1351–1362.

[5] C.H. Li, B.C. Kuo, C.T. Lin, and C.S. Huang, “A spectral-contextual support vector machine for remotely sensed image classification,” *IEEE Trans. Geosci. And Remote Sens.*, 2012, vol 50, no. 3, pp. 784–799.

[6] H. Ghassemian, D. Landgrebe, “An Unsupervised Feature Extraction Method for High Dimensional Image Data”. *IEEE Proc. on System, Man and Cybernetics*, 1987, vol.2, pp. 540–544.

[7] Y. Zhao, L. Zhang, P. Li, and B. Huang, “Classification of highspatial resolution imagery using improved Gaussian Markov Random-Field-based texture features.” *IEEE Trans. Geosci. Remote Sens.*, 2007, vol. 45, no. 5, pp. 1458 – 1468.

[8] M. Dalla Mura, J.A. Benediktsson B. Waske and L. Bruzzone, “Extended profiles with morphological

