

طبقه‌بندی عارضه مبنای تصاویر پلاریمتری سار با استفاده از طبقه‌بندی‌کننده‌های چندگانه ماشین بردار پشتیبان

مسعود حبیبی^۱، محمود رضا صاحبی^{۲*}، یاسر مقصودی^۲

^۱ دانشجوی کارشناسی ارشد سنجش از دور - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
masoudhabibi@kntu.com

^۲ استادیار گروه فتوگرامتری و سنجش از دور - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
sahebi@kntu.com
ymaghsoudi@kntu.ac.ir

(تاریخ دریافت دی ۱۳۹۳، تاریخ تصویب تیر ۱۳۹۴)

چکیده

طبقه‌بندی پوشش زمین یکی از کاربردهای مهم استفاده از داده‌های سنجش از دوری است. از میان تصاویر و داده‌های مورد استفاده در این مورد، داده‌های پلاریمتری راداری به خاطر امکان استخراج ویژگی‌های زیاد و متنوع می‌توانند برای طبقه‌بندی گزینه مناسبی باشند. در این مقاله یک روش عارضه‌مبنا برای طبقه‌بندی مناطق شهری با استفاده از داده‌های پلاریمتری راداری به صورت تلفیق نتایج پیکسل مبنای طبقه‌بندی SVM و قطعات تصویری ارائه می‌گردد. در این تحقیق برای رسیدن به دقت مناسب طبقه‌بندی از مجموعه ویژگی‌های بهینه استفاده شده است. بدین منظور، از روش طبقه‌بندی‌کننده‌های چندگانه SVM استفاده شده است. برای نیل به این هدف، معیار دقت کلاس در طبقه‌بندی SVM، جهت انتخاب ویژگی به صورت کلاس مبنا و همچنین انتخاب ویژگی به صورت تصادفی مورد استفاده قرار گرفته شده است. در تصاویر پلاریمتری به خاطر نویز ضربه‌ای، گاهی نتایج طبقه‌بندی پیکسل مبنا ممکن است راضی‌کننده نباشد. لذا در این تحقیق از ویژگی‌های مربوط به فضای تصویر یا قطعات تصویری استفاده شده است. بطور کلی روش ارائه شده سه گام اصلی دارد: انتخاب ویژگی، طبقه‌بندی پیکسل مبنا و تلفیق نتایج پیکسل مبنا و قطعات تصویری. بهبود دقت طبقه‌بندی بعنوان دستاورد مهم این تحقیق معرفی شده‌اند. نتایج نشان می‌دهد که دقت کلی روش ارائه شده ۹۰/۰۷٪ نسبت به نتایج پیکسل مبنای طبقه‌بندی‌کننده‌های چندگانه SVM (۸۳/۶۱٪) بهبود داشته است.

واژگان کلیدی: طبقه‌بندی‌کننده چندگانه، تصویر پلاریمتری، عارضه مبنا، انتخاب ویژگی، کلاس مبنا

* نویسنده رابط

۱- مقدمه

مبنای کار داده‌های پلاریمتری با روزه ی مصنوعی^۱ بر اساس دریافت داده از سطح زمین با استفاده از ارسال امواج الکترومغناطیس با قطبش قائم و افقی و دریافت آن می‌باشد. این نوع داده به کاربر اجازه‌ی شناسایی کلاس‌های مختلف را با آنالیز چند قطبی^۲ ضرایب بازپراکنش^۳ می‌دهد. از آنجایی که سنجنده‌های پلاریمتری به عنوان جزئی از سیستم‌های راداری امکان اخذ داده در شب و روز و در همه‌ی شرایط آب و هوایی را داراست، لذا عملاً شرایط جوی محدودیتی اساسی در اخذ داده ایجاد نمی‌کند.

طبقه‌بندی تصاویر یکی از روش‌های مهم در تفسیر تصاویر راداری سنجش از دور می‌باشد که در شناسایی کلاس‌های مربوط به پیکسل‌های تصویر کاربرد دارد. طبقه‌بندی کننده‌های مجموع^۴ و یا طبقه‌بندی کننده‌های چندگانه^۵ تکنیک‌هایی در طبقه‌بندی تصاویر سنجش از دوری هستند که با تلفیق^۶ طبقه‌بندی کننده‌های مختلف و مستقل برای رسیدن به یک نتیجه‌ی پیکسل مینا می‌توانند به بهبودی در نتیجه‌ی طبقه‌بندی در مقایسه با طبقه‌بندی کننده‌های تک برسند. روشهای مختلفی برای ساختن طبقه‌بندی کننده‌های چندگانه وجود دارند. این روشها شامل موارد زیر می‌باشند:

اصلاح داده‌های آموزشی (مثل bagging [۱] و boosting [۲]) [۳] و دستکاری ویژگی‌های ورودی (تقسیم فضای به چند زیرفضای مجزا [۴])، دستکاری کلاس‌های خروجی (مانند تبدیل مسئله چند کلاسه به چند مسئله دو کلاسه). بعد از ساخت یک طبقه‌بندی کننده‌ی چندگانه یک روش برای تلفیق و یا ترکیب نتایج طبقه‌بندی کننده‌ها ایجاد میشود. روشهای مختلفی برای تلفیق در مقالات معرفی و اجرا شده است. برای مثال رای اکثریت، تئوری شواهد D-S [۵]، منطق فازی [۶]، جمع وزن دار و همچنین ترکیب شبکه عصبی مصنوعی و طبقه‌بندی کننده‌های سلسله مراتبی.

انتخاب ویژگی کلاس مینا (CBFS)^۷ یک روش انتخاب ویژگی است که برای هر کلاس به صورت جداگانه ویژگی‌هایی را در ابتدا جدا میکند که این ویژگی‌ها کلاس مورد نظر را بهتر از کلاس‌های دیگر تفکیک کند. در کل به تعداد کلاسهای مورد نظر دسته‌های ویژگی برای طبقه‌بندی کننده داریم. ما از این روش برای انتخاب ویژگی در طبقه‌بندی کننده‌ی پیکسل مینا استفاده میکنیم.

طبقه‌بندی تصاویر پلاریمتریک راداری را میتوان در دو دسته‌ی کلی، پیکسل مینا^۸ [۷]، [۸] و قطعه مینا^۹ [۹] و [۱۰] تقسیم بندی کرد. طبقه‌بندی پیکسل مینا به صورت کلی خوب اجرا میشود و نتایج مفیدی دارد ولی در تصاویر راداری به خاطر وجود اسپکل^{۱۰} نتایج این دسته از روشهای طبقه‌بندی تحت تاثیر قرار میگیرند و گاهی نتایج مناسب و مورد انتظار بدست نمی‌آید. برای مقابله با این مشکل روشهای قطعه مینا یا عارضه مینا روی تصاویر راداری اجرا شده اند. در این روشها طبقه‌بندی در سطح عارضه^{۱۱} انجام میگیرد. عارضه‌های تصویری متناظر با موجودیت‌هایی از جهان واقعی هستند که در تصویر به صورت چند پیکسل کنار هم و با بعضی ویژگی‌های مشابه ظاهر میشوند [۱۱]. میتوان از قطعات تصویری که خروجی روشهای مختلف قطعه‌بندی هستند به عنوان عارضه‌های تصویری استفاده کرد. در سال‌های اخیر روشهای مختلف عارضه‌مبنایی برای طبقه‌بندی تصاویر راداری معرفی و اجرا شده اند [۱۲]، [۱۳]، [۱۴]، [۱۵].

در روشهای معمولی طبقه‌بندی شی گرا معمولاً از میانگین ویژگی‌های پیکسل‌های یک عارضه به عنوان ویژگی عارضه در طبقه‌بندی استفاده میشود اما در تحقیق [۱۴] روشی جدید برای طبقه‌بندی شی گرا ارائه شد. در این تحقیق از تلفیق نتایج طبقه‌بندی پیکسل مینا و قطعات تصویری برای طبقه‌بندی استفاده شده است. این روش تلفیق "پلاریمتری مکانی"^{۱۲} نام گرفته شده است. روش شناخته شده‌ای با نام روش "طیفی مکانی"^{۱۳} در تصاویر هایپراسپکترال مشابه با این روش تلفیق قبلاً به خوبی اجرا شده است [۱۶]، [۱۷].

^۷ Class base feature selection

^۸ Pixel-base

^۹ Segment-base

^{۱۰} speckle

^{۱۱} Object level

^{۱۲} Polarimetric spatial

^{۱۳} Spectral spatial

^۱ Synthetic Aperture Radar Polarimetry

^۲ multi-polarization


^۳ backscattering coefficients

^۴ Ensemble classifier

^۵ Multi-classifier

^۶ fusion

می‌باشد [۱۸]. شکل ۱ ترکیب رنگی Pauli از داده ی مورد نظر را نشان میدهد.



شکل ۱- تصویر RGB Pauli از داده ی مورد استفاده در این تحقیق

۲-۲- روش پیشنهادی

شکل ۲ فلوچارت الگوریتم ارائه شده برای حالت استفاده از انتخاب ویژگی کلاس مبنا را نشان میدهد. در ادامه الگوریتم ارائه شده در شش گام اصلی معرفی میگردد:

پیش پردازش

از تصویر اصلی ماتریس کوهرنسی استخراج شده است و در مرحله ی بعد با استفاده از این ماتریس ویژگی های مورد نیاز برای طبقه بندی استخراج میشود. برای کاهش نویز یک فیلتر Refined lee با ابعاد پنجره ی ۵ پیکسل برای ویژگی های همدوس^۵ به کار رفته است. به دلیل اینکه روش معرفی شده برای توسعه ی مدل طبقه بندی است این روش روی تصویر تک منظر انجام شده است و کلیه ی عملیات تصویری روی فضای range انجام شده است و همچنین عدم دسترسی به داده های زمینی عملیات ژئورفرنسینگ انجام نشده است. میتوان بعد از طبقه بندی پایانی تصویر عملیات ژئورفرنسینگ روی تصویر طبقه بندی شده انجام شود.

در تحقیق پیش رو روشی نوین بر اساس روش ذکر شده ([۱۴]) برای تصاویر پلاریمتری اجرا میشود و نتایج پیکسل مبنای طبقه بندی کننده های چندگانه را با قطعات تصویری تلفیق میکنیم. در روش پیشنهادی تمام پیکسل های یک قطعه به کلاسی منتسب میشوند که بیشترین حضور آن کلاس در نتیجه ی پیکسل مبنا را داشته باشد. در اینجا بعد از ساخت طبقه بندی کننده های چندگانه پیکسل مبنا با سه روش مختلف قطعات تصویری را برچسب میزنیم و به عنوان نتایج عارضه مبنا ارائه میکنیم: در روش اول ابتدا طبقه بندی کننده های تک را با هم تلفیق میکنیم، پیکسل های یک قطعه تصویری به کلاسی تعلق میگیرد که آن کلاس در نتیجه ی پیکسل مبنای طبقه بندی کننده ی چندگانه تلفیق شده بیشترین حضور را داشته باشند. روش دوم مشابه روش اول است با این تفاوت که قبل از تلفیق طبقه بندی کننده های تک با هم، این نتایج با قطعات تصویری تلفیق میشوند. در روش دوم تمام پیکسل های یک قطعه تصویری به کلاسی تعلق میگیرد که بیشترین حضور را در تمام طبقه بندی کننده های تک دارد. در روش سوم به جای رای اکثریت^۱ که در دو روش بالا به کار رفت از جمع وزن دار^۲ با وزن احتمال طبقه بندی SVM^۳ برای هر کلاس برای برچسب زنی هر قطعه استفاده میشود.

۲- مواد و روش ها

۲-۱- داده مورد استفاده

داده ی مورد استفاده در این تحقیق تصویر پلاریمتریک راداری از شهر سانفرانسیسکو است که با سنجنده ی رادارست-۲ در چهار قطبش کامل به صورت تک منظر در باند C مورد استفاده قرار گرفته است. این داده در مد FQ9 با قدرت تفکیک جانبی^۴ ۱/۱ متر در برد نزدیک تا ۱۰/۵ متر در برد دور اخذ شد است. برای این تحقیق از یک بخش از تصویر با ابعاد ۱۱۱۳ سطر و ۱۰۹۷ ستون استفاده شده است. تصویر شامل منطقه ای شهری است که دارای کلاس های اصلی آب، گیاه، ساختمان و راه


^۱ Majority voting

^۲ weighted summation

^۳ Support vector machine

^۴ range resolution

° coherence



شکل ۲- فلوچارت الگوریتم روش ارائه شده برای انتخاب ویژگی کلاس مبنا

استخراج ویژگی

در این مرحله با استفاده از ماتریس کوهرنسی و ماتریس بازپراکنش ویژگی های پلاریمتری استخراج میکنیم. جدول ۱ ویژگی های همدوس و ناهمدوس به کار گرفته شده در این گام را نشان میدهد:

جدول ۱- ویژگی های پلاریمتریک استفاده شده در این تحقیق

Features	Symbols	Number of features
Coherency matrix elements	T	9
Covariance matrix elements	C	9
Freeman 3 component decomposition	Free	3
H/ A/ Alpha	HAA	9
Huynen decomposition	JRH	9
Neuman 2 component decomposition	NEU	3
Barnes 1 decomposition	RMB1	9
Cloude decomposition	SRC	9
Van Zyl 3 component decomposition	VZ3	3
Holm 2 decomposition	WAH	9
Yamaguchi 4 component decomposition	YAM	4
Krogager decomposition	KROG	3
Cameron decomposition	CAM	1

این ویژگی ها شامل ویژگی هایی هستند که مستقیماً از خود داده ی اصلی استخراج شده اند. ویژگی های

همدوس مانند خروجی تجزیه تارگت^۱ Krogager از ماتریس بازپراکنش استخراج شده اند ولی ویژگی های ناهمدوس مانند خروجی تجزیه تارگت Freeman از ماتریس کواریانس یا کوهرنسی استفاده میکنند.

انتخاب ویژگی به روش کلاس مبنا و انتخاب ویژگی به صورت تصادفی

انتخاب ویژگی^۲ یک روش برای انتخاب از مجموعه ای از ویژگی های مرتبط از فضای ویژگی برای ساختن مدل است [۱۹].

اثر هیوز^۳ نشان میدهد که با افزایش تدریجی تعداد باندهای طیفی بعد از رسیدن به تعداد معینی باند در صورت ثابت بودن داده های آموزشی با افت دقت طبقه بندی همراه هستیم و این بر اهمیت انتخاب ویژگی تاکید میکند و نشان میدهد که استفاده از همه ی ویژگی ها در طبقه بندی نسبت به استفاده از ویژگی های بهینه باعث کاهش دقت کلی طبقه بندی میشود.

انتخاب ویژگی به روش کلاس مبنا یک روش انتخاب ویژگی است که برای ساخت طبقه بندی کننده های چندگانه انجام میشود و اجرای آن در تصاویر پلاریمتری با داده های پلاریمتری دقت خوبی را نشان داده است [۱۹].

در این روش به جای انتخاب ویژگی برای همه ی کلاس ها به صورت همزمان، برای هر کلاس به صورت جداگانه ویژگی

^۱ Target decomposition

^۲ Feature selection

^۳ Hughes

پیکسل به عنوان عارضه شروع به کار میکند و به صورت تکراری طبق یک معیار همگنی^۴، عارضه های همسایه را تلفیق میکند و این کار تا رسیدن به یک عارضه ی معنی دار ادامه پیدا میکند. معیار از دو بخش تشکیل شده است: معیار همگنی ویژگی پلاریمتری و معیار شکل. معیار شکل خود از دو قسمت معیار نرمی^۵ و معیار فشردگی^۶ تشکیل شده است:

$$f = \omega_a h_a + \omega_{shape} (\omega_c h_c + \omega_s h_s) \quad (1)$$

که ω_a ، ω_{shape} ، ω_c و ω_s به ترتیب وزن ویژگی همگنی تصویر، وزن همگنی شکل، وزن نرمی و وزن فشردگی هستند. h_c و h_s همگنی نرمی و همگنی فشردگی هستند و f فاکتور همگنی کلی است.

برای قطعه بندی تصویر پلاریمتری معمولاً از ویژگی های Pauli و یا Freeman در مطالعات استفاده میشود [۱۴]، [۲۲].

طبقه بندی کننده ی مجموع کلاس مبنا ماشین بردار پشتیبان

طبقه بندی کننده ی SVM نشان داده است که در طبقه بندی تصاویر پلاریمتری اجرای خوبی دارد [۱۵]، [۱۸]، [۲۳]. کرنل به کار رفته برای SVM در این تحقیق به صورت شعاعی گاوسی (RBF) است و پارامترهای SVM در این حالت که ضریب پنالتی (c) و شعاع کرنل (g) میباشد برای هر بار اجرای SVM با استفاده از یک جستجوی شبکه ای^۸ در یک فضای محدود، پارامترهای بهینه ی آن بدست آمده و مورد استفاده قرار گرفته است. در این قسمت ما روی هر دسته ویژگی که در مراحل قبل ایجاد کردیم یک طبقه بندی کننده ی SVM اجرا میکنیم. برای هر روش چهار طبقه بندی کننده به تعداد چهار کلاس تصویری داریم. هر طبقه بندی کننده دو سری خروجی دارد: یکی برچسب کلاس برای هر پیکسل و دیگری احتمال خروجی SVM^۹ برای هر کلاس.

ما با این نتایج به دو صورت مختلف برخورد میکنیم. در راه اول این چهار طبقه بندی کننده را به صورت سخت (رای اکثریت) و یا نرم (جمع احتمالات) با هم تلفیق میکنیم و از این نتایج پیکسل مبنای تولید شده در گام بعدی استفاده میکنیم. در راه دوم قبل از

انتخاب میکنیم. در ابتدا روش روی کلاس اول اجرا میشود و ویژگی هایی که برای تفکیک کلاس اول از بقیه ی کلاس ها مناسب تر است انتخاب میشود. سپس به سراغ کلاس دوم میرود و ویژگی های مرتبط با آن را انتخاب میکند و این کار برای همه ی کلاس ها انجام میشود [۲۰]. انتخاب ویژگی به روش ترتیبی شناور رو به جلو (SFFS)^۱ به عنوان تابع جستجو در انتخاب ویژگی استفاده شده و برای معیار یا تابع هدف انتخاب ویژگی از معیار دقت کلاس در طبقه بندی SVM استفاده شده است. این معیار بر اساس طبقه بندی کننده ی SVM است و در پایانی روی هر دسته ویژگی یک طبقه بندی SVM اجرا میشود. طبقه بندی کننده ی SVM طبقه بندی کننده ای است که یک ابر صفحه خطی در فضای طیفه بالاتر برای جدا کردن دو کلاس با بیشترین فاصله margin پیدا میکند.

برای حالت کلاس مبنا از دقت کلاس در طبقه بندی به عنوان معیار انتخاب ویژگی استفاده شده است، به این صورت که بدون دستکاری برچسب کلاس ها، ویژگی های مرتبط با هر کلاس را استخراج میکنیم. همچنین در این تحقیق از انتخاب ویژگی به صورت تصادفی برای هر طبقه بندی کننده در یک طبقه بندی کننده ی چند گانه استفاده شده است. Waske و همکاران در [۲۱] نشان دادند که در طبقه بندی تصاویر هایپر اسپکترال با طبقه بندی کننده های چندگانه ی ماشین بردار پشتیبان که با انتخاب ویژگی تصادفی ایجاد شده اند میتوان به دقت بالاتری نسبت به طبقه بندی کننده ی تک رسید.

در این تحقیق برای بدست آوردن تعداد طبقه بندی کننده های بهینه برای تولید طبقه بندی کننده ی مجموع با انتخاب ویژگی تصادفی و تعداد ویژگی های بهینه در هر طبقه بندی کننده، از درصدهای مختلفی از ویژگی ها (از ۴ تا ۹۰ درصد) و تعداد مختلفی طبقه بندی کننده (۱۰، ۲۵ و ۵۰) استفاده شده است.

قطعه بندی تصویر پلاریمتری

قطعه بندی، فضای تصویر را به مناطق همگن تقسیم میکند. دو ناحیه ی همسایه در تصویر به دو قطعه ی مجزا تقسیم میشوند اگر رفتار پلاریمتری مختلفی داشته باشند. روش مولتی رزولوشن (FNEA)^۲ روشی است که در این قسمت به کار رفته و ما با استفاده از نرم افزار ecognition آنرا اجرا میکنیم. این روشی پایین به بالا^۳ است که با یک

^۴ This homogeneity criterion

^۵ smoothness heterogeneity

^۶ compactness heterogeneity

^۷ Radial basis function

^۸ Grid search

^۹ SVM probability

^۱ Sequential floating forward feature selection

^۲ Fractal Net Evolution Approach

^۳ Bottom-up

این که این نتایج تلفیق شوند مستقیماً از این نتایج برای استفاده در گام بعدی که تلفیق با قطعات است استفاده میکنیم.

تلفیق چهار طبقه بندی کننده به صورت سخت به این صورت است که پیکسل به کلاسی تعلق میگیرد که بیشترین حضور را در چهار طبقه بندی کننده داشته باشد و در تلفیق نرم پیکسل به کلاسی تعلق میگیرد که بیشترین احتمال خروجی SVM را در چهار طبقه بندی کننده داشته باشد.

تلفیق طبقه کننده های مجموع کلاس مبنای با قطعات تصویری

در اینجا با چند روش کلاس پیکسل های قطعاتی که در مرحله ی قطعه بندی تولید کردیم را تعیین میکنیم.

در اینجا قطعات تصویری و نتایج پیکسل مبنای مرحله ی قبل با سه روش مختلف تلفیق میشوند: در روش اول از نتیجه ی تلفیق چهار طبقه بندی کننده به صورت نرم و یا سخت به عنوان پیکسل مبنای استفاده میکنیم. هر قطعه به کلاسی تعلق میگیرد که بیشترین حضور را در نتیجه ی پیکسل مبنای تلفیق شده داشته باشد. این روش به نوعی دای اکثریت درون هر قطعه است.

در روش دوم برچسب طبقه بندی کننده های تک قبل از تلفیق با هم به عنوان نتیجه ی پیکسل مبنای استفاده میشود. هر قطعه به کلاسی تعلق میگیرد که بیشترین حضور را در چهار طبقه بندی کننده ی تک داشته باشد.

در روش سوم از احتمال خروجی طبقه بندی کننده های تک قبل از تلفیق استفاده میشود. هر قطعه به کلاسی تعلق میگیرد که بیشترین احتمال خروجی را در تمام طبقه بندی کننده های تک قبل از تلفیقشان داشته باشد.


۳- نتایج عملی و بحث

پس از فیلترینگ و استخراج ویژگی ها، فرآیند انتخاب ویژگی روی ویژگی های استخراج شده با روش کلاس مبنای اجرا شد. دقت کلاس به عنوان معیاری در انتخاب ویژگی در این مرحله به کار گرفته شد. در این بخش برای یافتن تعداد ویژگی های مناسب برای هر طبقه بندی کننده در طبقه بندی مجموع انتخاب ویژگی با تعداد مختلف ویژگی انجام شد و نتایج دقت کلی طبقه بندی کننده ی مجموع بدست آمد که در شکل ۳ الف و ۳ ب نمایش داده شده است.


در هر سه روش انتخاب ویژگی با جانشانی انجام شده است. به این معنی که ویژگی های استفاده شده در یک طبقه بندی کننده مرتبط با یک کلاس میتوانند در طبقه بندی کننده های دیگر نیز انتخاب شوند.

با توجه به دقت های نشان داده شده در شکل برای حالت استفاده از انتخاب ویژگی کلاس مبنای ۱۲ ویژگی برای هر طبقه بندی کننده انتخاب شده است. همچنین نتایج نشان میدهد که برای حالت انتخاب ویژگی تصادفی استفاده از ۱۰ درصد ویژگی ها در هر طبقه بندی کننده مناسب تر است و همچنین با افزایش تعداد طبقه بندی کننده ها دقت کلی افزایش می یابد ولی زیاد محسوس نیست. در ادامه برای این حالت از ۱۰ طبقه بندی کننده و ۱۰ درصد ویژگی ها استفاده کردیم. شکل ۳ ب دقت طبقه بندی طبقه بندی کننده ی چندگانه با استفاده از انتخاب ویژگی تصادفی را نشان میدهد.


دقت کلی طبقه بندی در نتایج پیکسل مبنای استفاده از انتخاب ویژگی کلاس مبنای ۸۳٫۱۱٪ در تلفیق سخت طبقه بندی کننده ها و ۸۳٫۶۱٪ در طبقه بندی نرم بدست آمده است. شکل ۴ بهترین نتیجه ی طبقه بندی پیکسل مبنای مجموع با استفاده از دو روش انتخاب ویژگی یعنی کلاس مبنای و انتخاب ویژگی تصادفی را نشان میدهد.



ج




ب




الف

شکل ۳- دقت کلی طبقه بندی (الف) کلاس مبنای با معیار دقت کلاس (ب) طبقه بندی کننده ی چندگانه با انتخاب ویژگی تصادفی (ج) طبقه بندی کننده ی تک SVM



ب




الف

شکل ۴- الف) نتیجه ی طبقه بندی پیکسل مبنا با استفاده از دقت کلاس به عنوان معیار انتخاب ویژگی با ۱۲ ویژگی (دقت کلی ۸۳٫۶۱٪) ب) نتیجه ی طبقه بندی پیکسل مبنا با استفاده از انتخاب ویژگی تصادفی (دقت کلی ۸۴٫۴۴٪)


برای روش اول تلفیق نشان میدهد. روش اول که تلفیق قطعات با نتیجه ی تلفیق طبقه بندی کننده های چندگانه پیکسل مبنا به صورت سخت و نرم است روی تمام مقیاس های قطعات تصویری اجرا شده است. این روش معادل رای گیری اکثریت درون هر قطعه به ازای کلاس پیکسل های طبقه بندی کننده ی چندگانه (ی تلفیق شده) برای برچسب زنی قطعات است.

برای قطعه بندی در این مطالعه برای ضریب همگنی شکل مقدار ۰٫۱ در نظر گرفته شده است و برای ضریب فشردگی ۰٫۴ و ۰٫۶ و ۰٫۹ را در نظر گرفته شده. قطعه بندی در مقیاس های ۲۰ تا ۱۰۰ با فاصله های ۱۰ انجام گرفته است.


همان طور که ذکر شد نتایج طبقه بندی پیکسل مبنا با این قطعات تصویری تلفیق شد. شکل ۵ نتایج دقت کلی طبقه بندی را




ب



الف



د




ج


شکل ۵- دقت کلی طبقه بندی روش طبقه بندی کننده ی مجموع عارضه مبنا الف) تلفیق قطعات با طبقه بندی کننده های پیکسل مبنا که به صورت کلاس مبنا انتخاب ویژگی شده و به صورت سخت با هم تلفیق شده اند ب) تلفیق قطعات با طبقه بندی کننده های پیکسل مبنا با استفاده از انتخاب ویژگی تصادفی و به صورت سخت با هم تلفیق شده اند ج) تلفیق قطعات با طبقه بندی کننده های پیکسل مبنا که به صورت کلاس مبنا انتخاب ویژگی شده و به صورت نرم با هم تلفیق شده اند د) تلفیق قطعات با طبقه بندی کننده های مبنا با استفاده از انتخاب ویژگی تصادفی و به صورت نرم با هم تلفیق شده اند

نتایج روش دوم که در آن قطعات تصویری با برچسب طبقه بندی کننده های تلفیق نشده ترکیب میشوند در شکل ۶ آورده شده است. این روش معادل با رای گیری

اکثریت هر کلاس درون هر قطعه به ازای همه ی طبقه بندی کننده ها (ی تلفیق نشده) است.



الف




ب


شکل ۶- دقت کلی طبقه بندی مجموع عارضه مبنای رای گیری اکثریت درون قطعات به ازای طبقه بندی کننده های پیکسل مبنای الف) استفاده انتخاب ویژگی کلاس مبنای ب) با استفاده از انتخاب ویژگی تصادفی

نتایج روش سوم که از بیشترین جمع احتمالات برای انتساب کلاس به قطعات استفاده میشود در شکل ۷ نشان

داده شده است. این روش با استفاده از طبقه بندی کننده های چندگانه تلفیق نشده انجام گرفته است.



الف



ب

شکل ۷- دقت کلی طبقه بندی طبقه بندی کننده ی مجموع عارضه مبنای با جمع احتمالات درون قطعات در حالت الف) استفاده از انتخاب ویژگی کلاس مبنای ب) استفاده از انتخاب ویژگی تصادفی

هنگامی که از قطعات با ضریب فشردگی ۰,۴ در قطعه بندی استفاده کردیم دقت کلی روش عارضه مبنای عمدتا از روش پیکسل مبنای هم کمتر میشد. قطعات با ضریب فشردگی ۰,۶ نتیجه ی بهتر داشتند و ۰,۹ بهترین نتایج را بر اساس دقت کلی طبقه بندی نشان میداد. بهترین دقت زمانی بدست آمد که طبقه بندی کننده های پیکسل مبنای با روش نرم با هم تلفیق شده بودند و نتیجه ی آن با قطعات با روش اول یا همان رای اکثریت درون قطعه تلفیق می- شدند. این نتیجه مربوط به زمانی بود که از دقت کلاس

برای انتخاب ویژگی استفاده شده بود و دقت کلی ۹۰,۰۷٪ نشان دهنده ی ۶,۴۶٪ افزایش نسبت به نتیجه ی پیکسل مبنای تلفیق شده است. بهترین دقت کلی روش عارضه مبنای هنگام استفاده از انتخاب ویژگی تصادفی ۸۷,۷۵٪ و با افزایش ۳,۳۱٪ نسبت به نتیجه پیکسل مبنای چند گانه میباشد. شکل ۸ بهترین نتایج طبقه بندی عارضه مبنای مجموع را در هر دو حالت استفاده از انتخاب ویژگی کلاس مبنای و انتخاب ویژگی تصادفی را نشان میدهد. با مقایسه ی بصری این دو شکل میتوان دید که در حالت استفاده از


شکل راست این راهها به صورت قطعات جدا افتاده نمایش داده شده اند. کلاس اب در هر دو روش به خوبی برای دریا تفکیک شده و در حالت کلاس مینا تمام دریاچه های کوچک در تصویر نیز به خوبی مشخص شده اند.

در این قسمت به صورت مختصر دقت کلاس های طبقه بندی کننده ی مجموع عارضه مینا مقایسه و بررسی شده اند. دقت کلاس مربوط به تقریباً همه ی روشهای عارضه مینای بکار رفته در این تحقیق نسبت به مقیاس قطعه بندی رفتاری مشابه دارند. کلاس اب در طبقه بندی کننده ی مجموع عارضه مینا در مقیاس قطعه بندی ۳۰ و ۴۰ و ۵۰ به بیشترین دقت خود میرسند و این دقت در ضریب فشردگی ۰,۹ اتفاق می افتد. ضریب فشردگی ۰,۶ بهترین ضریب برای طبقه بندی کلاس گیاه میباشد. در مقیاس های ۴۰ و ۵۰ و ۶۰ و در ضریب ۰,۶ کلاس گیاه به بهترین دقت میرسد و در مقیاس های پایین تر ضریب ۰,۴ هم میتواند به دقت مشابه برسد. کلاس ساختمان در مقیاس های ۷۰ و ۸۰ و ۹۰ و ۱۰۰ و در ضریب ۰,۹ به بالاترین دقت میرسد ولی ضریب ۰,۶ در ۴۰ و ۵۰ بالاترین دقت این کلاس را در بین ضرایب دارد. بهترین دقت های کلاس راه در ضرایب فشردگی بالا و در مقیاس های پایین اتفاق می افتد. در کل دقت کلی طبقه بندی در مقیاس های ۴۰ و ۵۰ و در ضریب ۰,۹ اتفاق افتاده است.


برای مقایسه ی نتایج مختلف عارضه مینا با توجه به مقیاس های مختلف قطعه بندی میتوان گفت کلاس های مختلف تصویری در مقیاس های مختلف به بیشترین دقت ممکن میرسند ولی طبقه بندی کننده ی مجموع در مقیاس های متوسط بهترین حالت ممکن از نظر دقت کلی میرسد. با توجه به شکل خاص عوارض شهری ضریب فشردگی بیشتر در نتایج منجر به دقت کلی بالاتر طبقه بندی کننده ی مجموع عارضه مینا میشود. در کل روش طبقه بندی عارضه مینای مجموع نسبت به روش پیکسل مینای مجموع به صورت معنی داری بهتر عمل کرد.

روش طبقه بندی چندگانه که با انتخاب ویژگی تصادفی ایجاد شده، در این مقاله برای مقایسه روی تصویر اجرا شده است. نتایج پیکسل مینای ان راضی کننده و نسبت به نتیجه ی کلاس مینا نتیجه ای مشابه و از لحاظ دقت کلی اندکی بهتر میباشد. بعد از تلفیق نتیجه ی طبقه بندی کننده ی پیکسل مینا با قطعات تصویری دقت کلی اندکی (۳,۳۱٪) بهبود داشت ولی دقت

انتخاب ویژگی کلاس مینا طبقه بندی همگن تری مشاهده میشود. درون منطقه ی شهری و کلاس ساختمان در طبقه بندی با انتخاب ویژگی تصادفی قطعات کوچک جدا افتاده از کلاس راه مشاهده میشود. در حالت انتخاب ویژگی کلاس مینا با مشاهده ی کلاس گیاه میتوان به خوبی دید که این مناطق به صورت همگن و مناسب طبقه بندی شده اند ولی در حالت انتخاب ویژگی تصادفی همانند کلاس ساختمان، قطعات جدا افتاده ی کلاس راه دیده میشوند.



الف



ب

شکل ۸- بهترین نتایج طبقه بندی عارضه مینا با طبقه بندی کلاس مینا با (الف) معیار دقت کلاس در انتخاب ویژگی با (الف) استفاده انتخاب ویژگی کلاس مینا (دقت کلی ۹۰,۰۷٪) (ب) با استفاده از انتخاب ویژگی تصادفی (دقت کلی ۸۷,۷۵٪)

برای کلاس راه در حالت استفاده از انتخاب ویژگی کلاس مینا راه های اصلی به خوبی تشخیص داده شده اند ولی برخی جزییات راههای کوچکتر از بین رفته اند و در

۴- نتیجه گیری

هدف از این تحقیق ارائه ی یک روش عارضه مبنای برای طبقه بندی تصاویر پلاریمتریک میباشد. روش اجرا شده در منطقه ی شهری با در نظر گرفتن چهارکلاس تصویری اجرا شده است. برای طبقه بندی قطعات تصویری با نتایج طبقه بندی پیکسل مبنای به صورت نرم و سخت تلفیق شد. همچنین در این مطالعه از روش کلاس مبنای برای انتخاب ویژگی و ساخت طبقه بندی کننده ی مجموع استفاده شده است.

همان طور که انتظار میرفت دقت کلی طبقه بندی کننده ی مجموع پیکسل مبنای از دقت کلی طبقه بندی کننده ی تک بر مبنای SVM در این تحقیق بیشتر شد. همینطور دقت کلی روش عارضه مبنای در مقیاس های بهینه از دقت کلی طبقه بندی کننده ی مجموع پیکسل مبنای بیشتر شد. برای اجرای طبقه بندی کننده پیکسل مبنای از رای گیری نرم و سخت درون قطعات استفاده شد. دقت کلی رای گیری سخت یا همان رای اکثریت در این مورد بیشتر بود. قطعات استفاده شده در مقیاس های ۲۰ تا ۱۰۰ و در ضرایب فشردگی ۰,۴ , ۰,۶ و ۰,۹ تولید شد. به خاطر کشیدگی عارضه ها در مناطق شهری قطعه بندی تصویر در ضرایب فشردگی بالاتر منجر به دقت طبقه بندی عارضه مبنای بالاتر میشود. بالاترین دقت در مقیاس ۵۰ و در ضریب ۰,۹ بدست آمد. خروجی طبقه بندی در حالت عارضه مبنای برخلاف نتیجه ی پیکسل مبنای که نویزی بود کاملاً همگن بدست آمد.

کلی ان نسبت به روش کلاس مبنای پایین تر میباشد. با مقایسه ی نقشه ی خروجی هر دو روش در شکل ۸ میبینیم که خروجی روش انتخاب ویژگی تصادفی اندکی نویزی است و این نشان میدهد که انتخاب ویژگی کلاس مبنای که به صورت هدف دار در هر طبقه بندی کننده ویژگی های مناسب کلاس خاصی را انتخاب میکند به صورت معنی داری بهتر اجرا میشود. جدول ۲ بهترین نتایج هر روش طبقه بندی را با توجه به دقت کلی و ضریب کاپا نشان میدهد.

جدول ۲- مقایسه ی روشهای طبقه بندی اجرا شده از لحاظ دقت کلی

روش طبقه بندی	دقت کلی (درصد)	ضریب کاپا
طبقه بندی کننده ی SVM پیکسل مبنای (۱۰ ویژگی)	۸۰,۴۶	۰,۷۱۷۷
طبقه بندی کننده ی پیکسل مبنای چندگانه با انتخاب ویژگی تصادفی (۱۰ درصد ویژگی های کل در هر طبقه بندی کننده و تلفیق قطعات به صورت نرم)	۸۴,۴۴	۰,۷۹۲۵
طبقه بندی کننده ی پیکسل مبنای چندگانه با انتخاب ویژگی کلاس مبنای (۱۲ ویژگی در هر طبقه بندی کننده و تلفیق قطعات به صورت نرم)	۸۳,۶۱	۰,۷۸۱۶
طبقه بندی کننده ی عارضه مبنای چندگانه با انتخاب ویژگی تصادفی (۱۰ درصد ویژگی های کل در هر طبقه بندی کننده و تلفیق قطعات به صورت نرم)	۸۷,۷۵	۰,۸۳۶۸
طبقه بندی کننده ی عارضه مبنای چندگانه با انتخاب ویژگی کلاس مبنای (۱۶ ویژگی در هر طبقه بندی کننده و تلفیق قطعات به صورت سخت)	۹۰,۰۷	۰,۸۶۷۶

مراجع

- [1] L. Breiman, "Bagging predictors," Machine learning, vol. 24, pp. 123-140, 1996.
- [2] Y. Freund and R. E. Schapire, "Experiments with a new boosting algorithm," in ICML, 1996, pp. 148-156.
- [3] G. J. Briem, J. A. Benediktsson, and J. R. Sveinsson, "Multiple classifiers applied to multisource remote sensing data," Geoscience and Remote Sensing, IEEE Transactions on, vol. 40, pp. 2291-2299, 2002.
- [4] T. K. Ho, "The random subspace method for constructing decision forests," Pattern Analysis and Machine Intelligence, IEEE Transactions on, vol. 20, pp. 832-844, 1998.
- [5] A. Al-Ani and M. Deriche, "A new technique for combining multiple classifiers using the Dempster-Shafer theory of evidence," arXiv preprint arXiv:1107.0018, 2011.

- [6] B. M. Steele, "Combining multiple classifiers: an application using spatial and remotely sensed information for land cover type mapping," *Remote sensing of environment*, vol. 74, pp. 545-556, 2000.
- [7] J.-S. Lee, M. R. Grunes, T. L. Ainsworth, L.-J. Du, D. L. Schuler, and S. R. Cloude, "Unsupervised classification using polarimetric decomposition and the complex Wishart classifier," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 37, pp. 2249-2258, 1999.
- [8] C. F. Barnes and J. Burki, "Late-Season Rural Land-Cover Estimation With Polarimetric-SAR Intensity Pixel Blocks and-Tree-Structured Near-Neighbor Classifiers," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 44, pp. 2384-2392, 2006.
- [9] Y. Dong and A. K. Milne, "Segmentation and classification of vegetated areas using polarimetric SAR image data," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 39, pp. 321-329, 2001.
- [10] J. Lee, M. Grunes, E. Pottier, and L. Ferro-Famil, "Segmentation of polarimetric SAR images," in *INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM*, 2001, pp. I: 414-416.
- [11] T. Blaschke and G. J. Hay, "Object-oriented image analysis and scale-space: theory and methods for modeling and evaluating multiscale landscape structure," *International Archives of Photogrammetry and Remote Sensing*, vol. 34, pp. 22-29, 2001.
- [12] Q. Yu, P. Gong, N. Clinton, G. Biging, M. Kelly, and D. Schirokauer, "Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery," *Photogrammetric Engineering & Remote Sensing*, vol. 72, pp. 799-811, 2006.
- [13] Y. Wu, K. Ji, W. Yu, and Y. Su, "Region-based classification of polarimetric SAR images using Wishart MRF," *Geoscience and Remote Sensing Letters, IEEE*, vol. 5, pp. 668-672, 2008.
- [14] X. Ma, H. Shen, J. Yang, L. Zhang, and P. Li, "Polarimetric-Spatial Classification of SAR Images Based on the Fusion of Multiple Classifiers," 2014.
- [15] H. Li, H. Gu, Y. Han, and J. Yang, "Object-oriented classification of polarimetric SAR imagery based on statistical region merging and support vector machine," in *Earth Observation and Remote Sensing Applications*, 2008. EORSA 2008. International Workshop on, 2008, pp. 1-6.
- [16] K. Bernard, Y. Tarabalka, J. Angulo, J. Chanussot, and J. A. Benediktsson, "Spectral-spatial classification of hyperspectral data based on a stochastic minimum spanning forest approach," *Image Processing, IEEE Transactions on*, vol. 21, pp. 2008-2021, 2012.
- [17] M. Fauvel, Y. Tarabalka, J. A. Benediktsson, J. Chanussot, and J. C. Tilton, "Advances in spectral-spatial classification of hyperspectral images," *Proceedings of the IEEE*, vol. 101, pp. 652-675, 2013.
- [18] M. Salehi, M. R. Sahebi, and Y. Maghsoudi, "Improving the Accuracy of Urban Land Cover Classification Using Radarsat-2 PolSAR Data," 2011.
- [19] Y. Maghsoudi, "Analysis of Radarsat-2 Full Polarimetric Data for Forest Mapping," 2011.
- [20] Y. Maghsoudi, M. Collins, and D. G. Leckie, "Polarimetric classification of Boreal forest using nonparametric feature selection and multiple classifiers," *International Journal of Applied Earth Observation and Geoinformation*, vol. 19, pp. 139-150, 2012.
- [21] B. Waske, S. van der Linden, J. A. Benediktsson, A. Rabe, and P. Hostert, "Sensitivity of support vector machines to random feature selection in classification of hyperspectral data," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 48, pp. 2880-2889, 2010.
- [22] G. Hong, Y. Kui, and J. YouLiang, "Segmentation of Polarimetric SAR Image Using Object-Oriented Strategy," in *Remote Sensing, Environment and Transportation Engineering (RSETE)*, 2012 2nd International Conference on, 2012, pp. 1-5.
- [23] S. Fukuda and H. Hirose, "Support vector machine classification of land cover: application to polarimetric SAR data," in *Geoscience and Remote Sensing Symposium*, 2001. IGARSS'01. IEEE 2001 International, 2001, pp. 187-189.