

طبقه‌بندی دانش‌مبنای داده‌های پلاریمتری رادار با روزنه مصنوعی با استفاده از روش Support Vector Machine-Decision Tree (SVM-DT)

محسن جعفری^{۱*}، محمدجواد ولدان زوج^۲، یاسر مقصودی^۳

^۱ کارشناس ارشد سنجش از دور - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه‌نصیرالدین طوسی
mohsen.jafari@mail.kntu.ac.ir

^۲ دانشیار گروه فتوگرامتری و سنجش از دور - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه‌نصیرالدین طوسی
valadanzouj@kntu.ac.ir

^۳ استادیار گروه فتوگرامتری و سنجش از دور - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه‌نصیرالدین طوسی
ymaghsoudi@kntu.ac.ir

(تاریخ دریافت آذر ۱۳۹۳، تاریخ تصویب خرداد ۱۳۹۴)

چکیده

روش‌های مختلف طبقه‌بندی داده پلاریمتری به‌طور کلی در سه گروه قرار می‌گیرند. (۱) روش‌های آماری، (۲) روش‌های بر مبنای مکانیسم پراکنش و (۳) روش‌های دانش‌مبنا. در این مقاله روشی دانش‌مبنا و شیء‌مبنا برای طبقه‌بندی داده‌ی پلاریمتری مطرح شده است که در آن روش طبقه‌بندی SVM-DT برای تلفیق دانش در سه بخش دانش اولیه، دانش حاصل از داده پلاریمتری و دانش خبره توسعه داده شده است. دانش حاصل از داده (آماري، فیزیکی و مکانی) در مراحل تعیین طرح درختی، ویژگی برای طبقه‌بندی کننده SVM و همچنین در انتخاب ویژگی‌های بهینه به کار گرفته می‌شود. دانش اولیه برای توازن تعداد داده‌های آموزشی در طبقه‌بندی کننده SVM استفاده می‌شود. در نهایت دانش خبره نیز در دو مرحله ایجاد طرح درختی و همچنین انتخاب ویژگی‌های بهینه در روش پیشنهادی استفاده می‌شود. داده پلاریمتری سنجنده رادارست-۲ از منطقه‌ی جنگلی Petawawa کانادا با شش کلاس بلوط قرمز (Or)، کاج سفید (PW)، صنوبر سیاه (Sb)، آب (Wa)، منطقه‌ی شهری (Ur) و پوشش گیاهی (GV) برای پیاده‌سازی این تحقیق انتخاب شده است. برای بررسی تأثیر دانش‌های مختلف در روش پیشنهادی ۶ طبقه‌بندی کننده در آزمایش‌ها مقایسه شده است: طبقه‌بندی کننده ویشارت، SVM با تمام ویژگی‌ها، SVM-DT با تمام ویژگی‌ها، SVM-DT شیء‌مبنا با تمام ویژگی‌ها، SVM-DT شیء‌مبنا همراه با انتخاب ویژگی و SVM-DT شیء‌مبنا با انتخاب ویژگی و دانش اولیه. نتایج نشان داد اضافه شدن دانش‌های مختلف به طبقه‌بندی تأثیر مثبت و خوبی بر روی کلاس‌های جنگل دارد اگرچه برخی از این دانش‌ها در کلاس‌های دیگر بی‌تأثیر و یا حتی تأثیر منفی دارند. در نهایت دقت کلی روش پیشنهادی حدود ۸۷ درصد حاصل شد که در مقایسه با روش ویشارت ۱۵ درصد و در مقایسه با طبقه‌بندی کننده SVM، ۹ درصد بهبود داشته است.

واژگان کلیدی: داده پلاریمتری رادار با روزنه مصنوعی، طبقه‌بندی دانش‌مبنا، SVM-DT، دانش خبره، جنگل

۱- مقدمه

طبقه‌بندی^۱ داده پلاریمتری رادار با روزنه مصنوعی^۲ ابتدا با روش‌های پردازش تصاویر^۳ و روش‌های آماری^۴ آغاز و سپس با کمک پارامترهای استخراج‌شده از روش‌های مختلف تجزیه هدف^۵ وارد مراحل جدیدی شد. به‌طورکلی می‌توان روش‌های طبقه‌بندی داده پلاریمتری را با سه دیدگاه کلی تقسیم‌بندی کرد: روش‌های آماری [۱، ۲]، روش‌های برمبنای مکانیسم پراکنش [۳، ۴] و روش‌های دانش‌مبنا [۵، ۶].

روش‌های آماری، طبقه‌بندی داده پلاریمتری را برمبنای یک توزیع خاص آماری برای آن انجام می‌دهند. لی^۶ و همکاران (۱۹۹۴) [۱] با در نظر گرفتن توزیع ویشارت^۷ برای ماتریس کوواریانس^۸ داده‌های چند منظره^۹ ضمن برآورد یک تابع چگالی پایدار برای داده پلاریمتری به نتایج بهتری نسبت به سایر روش‌های آماری دست یابند. به‌طورکلی روش‌های آماری به‌واسطه گسترده بودن باز پراکنش^{۱۰} حاصل از برخورد موج ماکروویو و هدف و یا به‌عبارت دیگر باز پراکنشی حاوی چندین نوع مکانیسم پراکنش^{۱۱} نتایج مناسب و قابل‌توجهی ارائه ندادند چراکه این روش‌ها به تمام اطلاعات تصویر (تجزیه هدف، تفکیک‌کننده‌ها^{۱۲}...) توجه نمی‌کنند.

استفاده از نوع مکانیسم پراکنش از روش‌های دیگر طبقه‌بندی داده پلاریمتری می‌باشد. این روش‌ها از اطلاعات حاصل از الگوریتم‌های تجزیه [۳، ۷، ۸] که به دنبال استخراج مکانیسم پراکنش در هر المان تصویر هستند، برای طبقه‌بندی استفاده می‌کنند. تعداد و نوع اطلاعات استفاده‌شده در طبقه‌بندی سبب تفاوت در نتایج روش‌های این گروه شده است.

اولین و شناخته‌شده‌ترین روش در این گروه طبقه‌بندی نظارت‌نشده H/A/a است که داده را در فضای

ویژگی برمبنای اطلاعات بی‌نظمی^{۱۳} نوع پراکنش بازگشتی و ناهمسانگردی^{۱۴} به ۹ ناحیه تقسیم می‌کند [۳]. روش‌های نظارت‌شده مختلفی وجود دارند که هر یک اطلاعات مکانیسم پراکنش (الگوریتم‌های تجزیه) را به‌عنوان فضای ویژگی ورودی در نظر می‌گیرند. ازجمله این روش‌ها می‌توان به الگوریتم‌های SVM^{۱۵} و شبکه عصبی^{۱۶} اشاره کرد [۹-۱۱]. در [۱۲] برای بهبود ساختار شبکه عصبی در طبقه‌بندی داده‌های پلاریمتریک طبقه‌بندی کننده شبکه RBF^{۱۷} را با تکنیک جستجوی تکاملی^{۱۸} و (MD-PSO)^{۱۹} به کار گرفتند. سه دسته ویژگی در این تحقیق استفاده‌شده است که عبارت‌اند از: ماتریس کامل کوواریانس، مقادیر تجزیه H/a/A و بردار بافت^{۲۰} حاصل از ماتریس هم رخدادی^{۲۱} الگوریتم PCA^{۲۲} هم برای کاهش فضای ویژگی استفاده‌شده است. نتایج این تحقیق عملکرد بهتر این روش را در مقایسه با سایر شبکه عصبی‌های به‌کاررفته در داده پلاریمتری را نشان می‌دهد. مرجع [۱۰] پارامترهای الگوریتم تجزیه پائولی^{۲۳} بی‌نظمی، ناهمسانگردی، زاویه آلفا، ضریب تغییرات بین مؤلفه‌های LL و RR، توان کل و عناصر قطر اصلی ماتریس کوواریانس دایره‌ای برای سه باند C، L و P را در الگوریتم نظارت‌شده SVM برای طبقه‌بندی پوشش زمین بکار گرفته است. اگرچه این تحقیق به لحاظ استفاده از باندهای مختلف پلاریمتری دارای برتری است اما مجموعه‌ی کاملی از ویژگی‌های پلاریمتری در آن به کار نرفته است. تحقیقات بعدی همچون تحقیق [۱۳] ضمن استفاده از پارامترهای بیشتری توانستند طبقه‌بندی SVM را به‌صورت چند طبقه‌بندی کننده و انتخاب ویژگی‌های بهینه را به‌صورت کلاسی ارائه دهند. نتایج تحقیق بر روی تفکیک گونه‌های جنگلی موفقیت روش آن‌ها را نشان می‌دهد. البته در تحقیقات زیادی الگوریتم‌های انتخاب ویژگی مختلفی در کنار طبقه‌بندی کننده SVM سعی

^{۱۳} Entropy

^{۱۴} Anisotropy

^{۱۵} Support Vector Machine

^{۱۶} Neural Network

^{۱۷} Radial Basis Function

^{۱۸} Evolutionary search

^{۱۹} multidimensional particle swarm optimization

^{۲۰} Texture

^{۲۱} GLCM

^{۲۲} Principle Component Analysis

^{۲۳} Pauli

^۱ Classification

^۲ Polarimetric SAR data (PolSAR)

^۳ Image processing

^۴ Statistical

^۵ Target decomposition

^۶ Lee

^۷ Wishart

^۸ Covariance

^۹ Multi-Look

^{۱۰} Backscatter

^{۱۱} Scattering mechanism

^{۱۲} Discriminators

دارند تا حدودی مشکلات ناشی از تعداد زیاد ویژگی‌های پلاریمتری را کاهش دهند.

یکی از مهم‌ترین مشکلات روش‌هایی که در بالا به آن‌ها اشاره شد پیچیدگی محاسباتی و همچنین عدم استفاده از سایر دانش‌های در دسترس برای طبقه‌بندی است. به‌منظور جبران این نقص روش‌های دانش‌مبنای داده پلاریمتری مطرح گردیدند [۵]. روش کار در طبقه‌بندی دانش‌مبنا بر اساس دانش خبره^۱ است؛ که هر کلاس قواعد طبقه‌بندی خاص خود را دارد و به‌صورت ترتیبی اعمال می‌شوند. قواعد طبقه‌بندی درک ساده و پیاده‌سازی آسانی دارد. همچنین روش برای هر منطقه و موقعیت خاص قابل‌تعمیم است. این روش طبقه‌بندی شامل دو مرحله است. مرحله اول ایجاد دانش و مدل و تشکیل قواعد پایه، مرحله دوم تشکیل طرح طبقه‌بندی به‌صورت درختی (DT)^۲ در سطوح مختلف [۵، ۶، ۱۴، ۱۵].

روش‌های مختلف دانش‌مبنا که تاکنون ارائه‌شده‌اند عموماً به‌صورت درختی یا سلسله مراتبی می‌باشند. این روش‌ها اگرچه در محاسبات و فرآیند پردازش پیچیدگی را کاهش می‌دهند اما در برابر پوشش‌های پیچیده زمینی و همچنین داده‌ی پیچیده‌ای مثل داده پلاریمتری عملکرد مطلوبی ندارند.

در مباحث شناسایی الگو روشی ترکیبی از SVM و DT برای طبقه‌بندی داده‌ها ارائه‌شده است (SVM-DT) [۲۰-۱۶]. این روش هم مکانیسم جداساز قدرتمندی بین کلاس‌ها دارد مانند SVM و هم از پیچیدگی‌های محاسباتی کمتری برخوردار است و دانش خبره را در فرآیند طبقه‌بندی به کار می‌گیرد مانند (DT). اگرچه این طبقه‌بندی کننده ویژگی‌های منحصربه‌فردی دارد اما کمتر در طبقه‌بندی داده‌های سنجش‌ازدور به‌کاررفته است. اخیراً مرجع [۲۱] از این روش در طبقه‌بندی تصاویر با قدرت تفکیک مکانی بالا استفاده نموده است. آن‌ها ضمن بررسی نتایج روش SVM-DT به‌صورت شیء‌مبنا با روش‌های مختلف طبقه‌بندی ازجمله روش SVM مرسوم اثبات کرده‌اند که نتایج در تصاویر سنجش‌ازدور هم ضمن بهبود وضعیت محاسباتی به لحاظ دقت نیز بهبود دارد.

در این مقاله روش طبقه‌بندی SVM-DT برای نخستین بار برای داده‌های پلاریمتری رادار با روزه مصنوعی توسعه داده می‌شود. دانش‌های مختلف متناسب با داده پلاریمتری در باند C و منطقه‌ی جنگلی استخراج و از آن‌ها در مراحل مختلف طبقه‌بندی کننده SVM-DT استفاده می‌شود. به این ترتیب در این مقاله روشی جدید برای طبقه‌بندی داده‌های پلاریمتری ارائه شده است که می‌تواند دانش را در سه سطح دانش اولیه^۳، دانش خبره و دانش حاصل از داده‌ی کار گیرد.

در ادامه‌ی این مقاله و در بخش دوم، مبانی طبقه‌بندی کننده SVM-DT بیان می‌شود. در بخش سوم داده مورد استفاده و منطقه‌ی مورد مطالعه تشریح می‌گردد. در بخش چهارم، روش SVM-DT برای داده پلاریمتری و کلاس‌های مورد مطالعه توسعه داده می‌شود. بخش پنجم مربوط به تحلیل نتایج حاصل از روش پیشنهادی می‌باشد. بخش پایانی نیز نتیجه‌گیری از این تحقیق و پیشنهادها برای تحقیقات آینده است.

۲- مبانی طبقه‌بندی کننده SVM-DT

پایه و اساس طبقه‌بندی کننده SVM-DT یک معماری درختی است که برای تصمیم‌گیری در گره‌های^۴ آن از طبقه‌بندی کننده دو کلاسه SVM استفاده می‌شود. این روش دو مزیت دقت بالای طبقه‌بندی در SVM و همچنین یک وضعیت محاسباتی مناسب و همراهی دانش خبره در DT را به همراه دارد. روش SVM-DT تنها نیاز به m-1 طبقه‌بندی دو کلاسه به روش SVM برای m کلاس دارد که بهبود قابل‌توجهی در زمان انجام طبقه‌بندی در مقایسه با روش‌های متداول OAO^۶ و OAA^۷ برای تعمیم دو کلاسه به چند کلاسه ایجاد می‌کند. طبقه‌بندی کننده‌های DT به دلیل استفاده از یک جداکننده ساده در داده‌های آموزشی برای تفکیک کلاس‌ها بسیار به داده‌های نویزی و منفرد حساس هستند. استفاده از یک طبقه‌بندی دوتایی قدرتمند مانند SVM که رفتار قابل قبولی در برابر این داده‌ها دارد می‌تواند

^۳ Prior knowledge

^۴ Image knowledge

^۵ Nodes

^۶ One Against One

^۷ One Against All

^۱ Expert knowledge

^۲ Decision Tree (DT)

عملکرد طبقه‌بندی کننده DT در گره‌ها را بهبود بخشد. با فرض $D = \{(x_i, y_i), i = 1, \dots, N\}$ به عنوان مجموعه داده‌های موردنظر به تعداد N که در آن: $y_i \in \{+1, -1\}$ و $x_i = [x_{i,1}, x_{i,2}, \dots, x_{i,q}]^T \in \mathbb{R}^q$ کلاس داده x_i را نشان می‌دهد؛ SVM کرنل مبنا برای برآورد یک جداکننده فرا صفحه مناسب در یک فضای ویژگی بزرگ عبارت است از:

$$F: f(x) = ((\omega \cdot \phi(x)) + b) = 0, \quad (1)$$

دو پارامتر موجود در رابطه ۱ (ω, b) هستند که $b \in \mathbb{R}$ و $F \in \omega$ است. به این ترتیب تابع تصمیم بهینه معادل رابطه ۲ خواهد بود.

$$f(x) = \text{sgn}(\sum_{i \in S} a_i y_i K(x_i, x) + b), \quad (2)$$

که در رابطه ۲ $S = \{i: 0 < a_i^* \leq C\}$ ضریب غیر صفر a_i متناظر است با بردارهای پشتیبان^۱ (SVs). فضای مارجین^۲ $f(x) \in [+1, -1]$ ، به وسیله مارجین‌های مثبت و منفی در اطراف صفحه اصلی جداکننده مشخص می‌شود. به علاوه مقادیر تصمیم $+1$ و -1 را نشان می‌دهد. در این مقاله از کرنل گوسین^۳ RBF در SVM به دلیل توانایی‌اش در کنترل داده‌ها با ابعاد بالا استفاده شده است.

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right), \quad (3)$$

که در این کرنل σ واریانس در امتداد محورهای ویژگی‌ها را نشان می‌دهد. دو پارامتر SVM (C و σ) در این مقاله به کمک روش جستجوی شبکه‌ای در هر گره که یک SVM انجام می‌شود برآورد می‌گردد.

طرح درختی برای هر گره باید به دقت طراحی شود. شناسایی هر نمونه از بالا به پایین در طرح درختی انجام می‌شود و در هر گره برای تعلق آن نمونه در هر کدام از شاخه‌ها تصمیم‌گیری می‌شود. هر کدام از این شاخه‌ها خود می‌توانند شامل چندین کلاس باشند که در مراحل بعدی

از یکدیگر جدا می‌شوند. حرکت بالا به پایین نمونه ادامه پیدا می‌کند تا پیکسل به یک کلاس تعلق پیدا کند.

۳- منطقه مورد مطالعه، داده مورد استفاده و پیش‌پردازش

منطقه مورد مطالعه یک جنگل تحقیقاتی به نام Petawawa در ایالت Ontario کانادا ($45^\circ 57' N$, $77^\circ 34' W$) است. این منطقه، شامل نواحی جنگل، پوشش گیاهی، آب و منطقه‌ی شهری است. گونه‌های مختلف موجود در این جنگل تحقیقاتی شامل دو نوع درخت سخت‌چوب^۴ و نرم‌چوب^۵ هستند که از این بین سه گونه‌ی مختلف جنگلی در نظر گرفته شد. گونه Or از دسته سخت‌چوب‌ها که در زمستان بدون برگ هستند و دو گونه‌ی نرم‌چوب Pw و Sb که برگ‌ریزان در هیچ فصلی از سال ندارند. مجموعه کلاس‌های انتخاب‌شده و همچنین تعداد داده‌های آموزشی و ارزیابی هر کلاس در جدول ۱ آمده است. برای انتخاب داده‌های آموزشی و ارزیابی از پلی‌گون‌های ایجادشده از نقشه‌های موجود در منطقه، تفسیر عکس‌های هوایی، تصاویر سنجنده ETM+ و بازدیدهای زمینی استفاده شده است. مجموعه داده‌های حقیقی فوق توسط سازمان جنگل‌داری کانادا در جنگل‌های تحقیقاتی Petawawa جمع‌آوری شده و به‌روزرسانی می‌شود [۴، ۱۳، ۲۲، ۲۳].

در این تحقیق از سه دسته داده استفاده شده است. داده‌های زمینی شامل داده‌های آموزشی و ارزیابی، داده‌های سنجنش‌ازدوری شامل داده پلاریمتری SAR سنجنده RADARSAT-2، مدل ارتفاعی رقومی زمین جهت تصحیح هندسی.

تصویر در باند C معادل طول‌موج ۵/۵ سانتی‌متر در حالت FQ9 و با زاویه فرود ۲۸ و ۲۹٫۸ درجه اخذ شده است. تصویر خام است و هیچ پردازشی بر روی آن صورت نگرفته است و به‌صورت Single Look Complex (SLC) می‌باشد. جهت آماده‌سازی و آنالیزهای اولیه داده پلاریمتری از نرم‌افزار POLSAR pro.4.2 استفاده شد. تصویر خام ورودی شامل مقادیر شدت رسیده به سنجنده است. کمیت موردعلاقه برای طی آنالیزهای بعدی مقدار

۴ Hardwood
۵ Softwood

۱ Support vectors
۲ Margin
۳ Gaussian

برای برآورد پایدار از یک پنجره 7×7 در هنگام محاسبه پارامتر استفاده شد. جدول ۲ جزئیات و نماد ویژگی‌های استفاده‌شده در این مقاله را نشان می‌دهد.

شکل ۱ (الف) زیر تصویر انتخاب‌شده با ابعاد 1000×1000 از سنجنده رادارست-۲ با ترکیب رنگی قرمز: $|HH-VV|$ ، سبز: $|HV|$ و آبی: $|HH+VV|$ پس از پیش‌پردازش و شکل ۱ (ب) موقعیت جغرافیایی منطقه‌ی انتخابی در گوگل ارث^۱ را نشان می‌دهد.

type	name	description	# of train	#of test
Forest-Hardwood	Or	Red oak	980	772
Forest-Softwood	Pw	White pine	305	375
	Sb	Black spruce	900	782
	GV	Ground vegetation	570	494
Other	Wa	Water	1047	810
	Ur	Urban	978	631
Total			4780	3864

شدت دریافتی به شدت ارسالی نسبت به سطح زمین است. به این منظور از تصویر خام، پارامتر σ^0 (Sigma-nougat) استخراج شد. مرحله بعد استخراج ماتریس همدوسی است، که برای استخراج پارامترهای تجزیه و طبقه‌بندی موردنیاز می‌باشند. این کار بدون هیچ میانگین‌گیری بر روی پیکسل‌ها و با فرض تئوری معکوس‌پذیری هدف ($S_{hv} = S_{vh}$) انجام می‌شود. پس از استخراج ماتریس همدوسی برای کاهش نویز لکه در تصویر از پالایه Box.car با ابعاد 7×7 استفاده شد. این پالایه به دلیل نوع منطقه‌ی مورد مطالعه که لبه‌های حساسی در کلاس‌ها وجود ندارد، انتخاب گردید. برای زمین مرجع کردن و همچنین تصحیح هندسی تصویر از نرم‌افزار ASF Map ready، اطلاعات مداری و مدل ارتفاعی رقومی منطقه استفاده شد. برای استخراج پارامترهای پلاریمتری همدوس از ماتریس همدوسی پالایه نشده و زمین مرجع شده و همچنین برای استخراج پارامترهای ناهمدوس از علاوه بر ماتریس همدوسی پالایه شده و زمین مرجع شده


جدول ۲- ویژگی‌های استفاده‌شده در روش پیشنهادی (SVM-DT)

Feature	Description	Symbol	Number
original features	Scattering matrix	[S]	3
	Coherency matrix element	[T]	6
	Covariance matrix element	[C]	5
decomposition features	Pauli	[P]	3
	Krogager [10]	[Krog]	3
	Van Zyl [11]	[Van]	3
	Huynen	[T_Huy]	3
	Barnes1	[T_Bar1]	3
	Barnes2	[T_Bar2]	3
	Cloude	[SRC]	6
	Cloud and Pottier	[H, A, α]	7
	Freeman3	[Free3]	3
	Freeman2	[Free_2]	2
	Neumann	[Neu]	4
	Yamaguchi	[Yam]	4
	Touzi	[Touz]	4
SAR discriminators	Complex corelation coefficients	[ro]	3
	Depolarization ratio	[depol_ind]	1
	Polarization ratio	[rh]	3
	Polarization Asymmetry	[PA]	1
	Span	[Span]	1
	Beta	[β]	1
	RVI	[RVI]	1
	Degree of purity	[deg_pur]	1
	Gamma	[γ]	1
	Lambda	[Δ]	1
	Delta	[Δ]	1
	Serd	[serd]	1
	Derd	[derd]	1
	Shannon	[shanon]	1
Total			80

^۱ Google Earth



(ب)




(الف)

شکل ۱- الف) ترکیب رنگی پائولی تصویر پیش‌پردازش شده از زیر تصویر انتخاب شده؛ ب) موقعیت زیر تصویر در محیط گوگل ارث همراه پلی گون‌های داده‌های زمینی

اطلاعات تصویر پایدار نیست. در روش پیشنهادی دانش در سه سطح در فرآیند طبقه‌بندی به کار می‌رود: دانش اولیه، دانش خبره و دانش حاصل از داده. شکل ۲ جایگاه به‌کارگیری دانش در سطوح مختلف را در روش پیشنهادی نشان می‌دهد.

۴- سطوح دانش پیشنهادی در طبقه‌بندی داده پلاریمتری با روش SVM-DT

طبقه‌بندی فرآیند مناسبی برای به تصویر کشیدن قابلیت تفکیک عوارض در تصاویر است که لازمه‌ی دقت خوب آن داشتن اطلاعات جامع از کلاس‌های مختلف می‌باشد. آموزش مدل بدون اطلاعات جانبی و فقط تکیه بر



شکل ۲- نحوه به‌کارگیری دانش‌های مختلف در طرح طبقه‌بندی پیشنهادی (SVM-DT)

دانش اولیه، عبارت است از اطلاعاتی که از قبل درباره منطقه یا داده مورد مطالعه وجود دارد. به‌طور کلی دو منبع

۴-۱- دانش اولیه

[۲۶] مقدار D_{ii} را بر پایه دانش اولیه عدم توازن در داده‌های آموزشی معرفی کرد به‌طوری‌که $D_{ii} = \lambda n^+ / N$ برای کلاس $y_i = +1$ و همچنین $D_{ii} = \lambda n^- / N$ برای کلاس $y_i = -1$ است. n^+ و n^- نیز تعداد داده‌های آموزشی در کلاس‌های متناظر را نشان می‌دهند. λ نیز مقیاس است که باید مقدار بهینه آن در طبقه‌بندی برآورد گردد.

۴-۲- دانش خبره

دانش خبره، اطلاعاتی است که از فرد متخصص درباره منطقه یا داده به دست می‌آید و می‌تواند برای هدایت مرحله آموزش طبقه‌بندی به کار گرفته شود. با این کار روند آموزش SVM منطقی و بادانش خبره علاوه بر دانش داده تلفیق می‌شود. در روش پیشنهادی در دو جایگاه دانش خبره به کار می‌رود. اول، ایجاد طرح طبقه‌بندی درختی و دوم انتخاب ویژگی‌های بهینه. در طرح طبقه‌بندی به‌جای استفاده از روش‌های متداول مانند OAO و OAA برای تعمیم SVM دو کلاسه به چند کلاسه از یک طرح درختی استفاده می‌شود. بخشی از اطلاعات جهت اولویت دادن به کلاس‌ها برای جدا شدن از سایرین به کمک دانش خبره تأمین می‌شود. بخش دوم که دانش خبره در آن کاربرد دارد، انتخاب ویژگی‌های بهینه است. در این مقاله روشی ترکیبی از دانش‌های مختلف از جمله دانش خبره برای انتخاب ویژگی ارائه شده است که جایگزین مناسبی برای سایر روش‌های ریاضی و آماری مانند ژنتیک می‌باشد.

۴-۳- دانش حاصل از داده

اطلاعات حاصل از داده پلاریمتری را می‌توان در سه بخش تقسیم‌بندی کرد (شکل ۳) [۲۲]. دانش آماری همان اطلاعاتی است که با در نظر گرفتن یک توزیع خاص برای داده برآورد می‌شود و یا سایر پارامترهایی که ویژگی‌های آماری داده را نمایش می‌دهند. مجموعه پارامترهایی با مفاهیم فیزیکی که به سه شیوه المان‌های اصلی^۷ تجزیه هدف و تفکیک‌کننده‌ها از داده قابل استخراج هستند در گروه دانش فیزیکی قرار می‌گیرند.

^۷ The features obtained directly from original data

دانش اولیه برای اضافه کردن به طبقه‌بندی کننده SVM وجود دارد [۲۴]. یکی دانش اولیه در داده^۱ و دیگری دانش اولیه در خصوصیات کلاس‌ها^۲. از آنجایی که کلاس‌های پوشش‌های زمینی ویژگی خاصی در برابر یکدیگر به لحاظ ریاضی که مؤثر در فرآیند آموزش SVM باشد ندارند، مورد دوم در طبقه‌بندی تصاویر سنجش‌ازدوری کاربردی ندارد. دانش اولیه در داده را می‌توان از سه دیدگاه طبقه‌بندی کرد: عدم توازن داده آموزشی^۳، دانشی درباره داده‌های بدون برچسب^۴ و کیفیت متفاوت داده‌های ورودی^۵ [۲۴]. مورد سوم در روش پیشنهادی این تحقیق جایی ندارد چراکه تنها منبع مورد استفاده تصویر است و منبع دیگری وجود ندارد. همچنین با توجه به این که اطلاعات خاصی درباره داده‌های بدون برچسب در دسترس نمی‌باشد؛ بنابراین تنها دانش اولیه موجود ایجاد توازن در داده‌های آموزشی کلاس‌های مختلف است. در طبقه‌بندی کننده درختی هر مرتبه یک کلاس از سایر کلاس‌ها جدا می‌شود که این باعث می‌شود تعداد داده‌های آموزشی برای دو طرف طبقه‌بندی نزدیک به هم نباشد. همان‌طور که گفته شد، در روش پیشنهادی SVM-DT برای هر گره در طرح درختی یک SVM انجام می‌شود که با توجه به عدم توازن داده‌های آموزشی در دو طرف طبقه‌بندی کننده SVM آموزش این طبقه‌بندی کننده دچار کم‌دقتی می‌شود.

روش موردنظر برای تأثیر دانش اولیه در طبقه‌بندی کننده SVM، وزن دار کردن داده است [۲۴]. با در نظر گرفتن یک وزن متناسب با تعداد داده‌های آموزشی هر کلاس در کرنل موردنظر می‌توان این نقصان را برطرف کرد. این ایده در [۲۵] برای حالت عدم توازن در داده‌های آموزشی با در نظر گرفتن کرنل تصحیح‌شده (رابطه ۴) مطرح گردید.

$$K' = K + D \quad (4)$$

در رابطه فوق D یک ماتریس قطری است که درایه‌های قطر اصلی آن D_{ii} هستند. هورویستیکس^۶ در

^۱ Prior knowledge on the data


^۲ Prior knowledge on Class-Invariance

^۳ Unbalanced data

^۴ Unlabeled data

^۵ Quality of data

^۶ Heuristics



شکل ۳- انواع مختلف دانش حاصل از داده پلاریمتری

دانش مکانی^۱ نیز مجموعه روش‌های اضافه کردن اطلاعات همسایگی به طبقه‌بندی است که به سه شکل قبل، حین و بعد از پردازش قابل افزودن هستند [۲۷]. در روش پیشنهادی اطلاعات مختلف از انواع آماری، فیزیکی و مکانی از داده استخراج و در طبقه‌بندی به کار گرفته شده است. اطلاعات آماری در دو جایگاه مهم به کار می‌رود. ۱- انتخاب ویژگی (همبستگی بین ویژگی‌ها و فاصله JM^2) و ۲- طرح طبقه‌بندی (فاصله ویشارت بین کلاس‌ها). دانش فیزیکی به‌عنوان ویژگی‌های ورودی طبقه‌بندی کننده SVM و همچنین امضای پلاریمتری برای ایجاد طرح درختی استفاده می‌شود. در این مقاله برای افزودن دانش مکانی به طبقه‌بندی از روش شیء‌مبنا استفاده شده است. تمام ویژگی‌های پلاریمتری از این قطعات برآورد می‌گردد.

۵- پیاده‌سازی و تحلیل نتایج روش SVM-DT توسعه داده‌شده برای داده پلاریمتری


۵-۱- قطعه‌بندی^۳

قطعه‌بندی بر روی داده پلاریمتری پیش‌پردازش شده به کمک نرم‌افزار eCognition Developer [۲۸] و با روش چندمقیاسه^۴ انجام شده است. تصویر ورودی قطعه‌بندی باید یک ترکیب رنگی مناسب از ویژگی‌های استخراجی باشد. تصویر تجزیه^۵ مؤلفه‌ای فریمن^۶ و ون زیل^۶ و پائولی

در تحقیقات اخیر مورد استفاده بوده است. با توجه به نتایج مناسب [۱۵] در این مقاله ورودی قطعه‌بندی، تصویر ترکیب رنگی پائولی انتخاب گردید. انتخاب پارامترهای مناسب نیز یکی دیگر از مسائل مهم در قطعه‌بندی چندمقیاسه است. مقدار فشردگی^۷ با توجه به عوارض موجود در تصویر انتخاب می‌شود. از آنجایی که منطقه‌ی موردنظر به جز قسمت کوچکی بیشتر جنگلی است و نظم خاصی در قطعات و عوارض دیده نمی‌شود تأثیر این پارامتر کم و برابر 0.2 در نظر گرفته شد. مقدار شکل^۸ رابطه معکوس با میزان تأثیر رنگ دارد از این‌رو مقدار شکل نیز در نرم‌افزار 0.08 در نظر گرفته شد تا سهم بیشتری در شباهت پیکسل‌های یک قطعه به رنگ که در داده پلاریمتری به معنای پراکنش است، اختصاص داده شود. پارامتر کلیدی در این قطعه‌بندی مقیاس^۹ است که اندازه‌ی قطعات را تعیین می‌کند. اندازه قطعات نباید به حدی کوچک باشد که ما را از هدف خود یعنی همراه کردن اطلاعات همسایگی دور کند و همچنین نباید این قطعات خیلی بزرگ باشند که نتایج طبقه‌بندی را به‌سوی اشتباه سوق دهند. نتایج ۳ مقیاس متفاوت برای قسمتی از تصویر در شکل ۴ آمده است. مقدار مقیاس ۱۰ پس از آزمایش‌های متعدد مقدار مناسبی تشخیص داده شد.

^۷ Compactness
^۸ Shape
^۹ Scale

^۱ Spatial knowledge
^۲ Jeffries Matusita Distance
^۳ Segmentation
^۴ Multi-resolution
^۵ Freeman
^۶ Van Zyl



شکل ۴- تعیین مقدار بهینه مقیاس برای قطعه‌بندی تصویر ترکیب رنگی پانولی داده پلاریمتری رادارست-۲

۵-۲- ایجاد طرح درختی

سه معیار متفاوت آماری، فیزیکی و همچنین دانش خبره برای ایجاد طرح درختی به کار گرفته شده است شکل ۲. معیار آماری فاصله ویشارت بین میانگین ماتریس کوواریانس داده‌های آموزشی کلاس‌های مختلف است. کلاسی که فاصله

بیشتری نسبت به باقی کلاس‌ها دارد در اولویت جدا شدن و طبقه‌بندی قرار دارد. جدول ۳ فاصله ویشارت حاصل از داده‌های آموزشی شش کلاس موردبررسی را نشان می‌دهد. مطابق جدول معیار فاصله ویشارت بین میانگین داده‌های آموزشی از هر کلاس یک دانش را ارائه می‌دهد:

✓ کلاس آب از بقیه کلاس‌ها بسیار متمایز است.

جدول ۳- فاصله ویشارت بین ماتریس کوواریانس داده‌های آموزشی کلاس‌های مختلف

	Or	Pw	Sb	Ur	Wa	GV	sum
Or	-3.28	-3.61	-2.68	-2.40	-5.99	-4.12	-22.08
Pw	-3.22	-3.66	-2.57	-2.34	-6.31	-4.17	-22.27
Sb	-3.22	-3.52	-2.75	-2.61	-5.50	-3.94	-21.57
Ur	-2.76	-3.15	-2.21	-3.09	-5.78	-3.77	-20.77
Wa	54.09	48.16	-68.36	59.31	-11.52	30.15	248.55
GV	-3.02	-3.48	-2.18	-1.87	-6.94	-4.31	-21.80

معیار فیزیکی، امضای پلاریمتری حاصل از میانگین داده‌های آموزشی کلاس‌های مختلف است. کلاسی که امضای متفاوتی از سایر کلاس‌ها داشته باشد در اولویت طبقه‌بندی است. با دو معیاری که در مرجع [۲۳] معرفی و تحلیل شده است؛ یعنی فاصله اقلیدسی و همبستگی بین امضای کلاس‌های مختلف، دانش از امضای پلاریمتری استخراج می‌شود. جدول ۴ میزان نرمال شده همبستگی و جدول ۵ فاصله اقلیدسی بین امضای پلاریمتری میانگین داده‌های کلاس‌های مختلف را نشان می‌دهند. ستون آخر این جدول تمایز کلاس‌های مربوطه از مجموع سایر کلاس‌ها را نشان می‌دهد. در جدول همبستگی هر قدر میزان این عدد کمتر

باشد نشان می‌دهد که آن کلاس تفاوت بیشتری با سایر کلاس‌ها دارد. مطابق این قاعده نکته قابل دریافت تفاوت بسیار زیاد کلاس منطقه شهری نسبت به سایر کلاس‌هاست. در جدول فاصله اقلیدسی هر قدر این عدد بزرگ‌تر باشد نشان می‌دهد کلاس مربوطه تفاوت بیشتری از سایر کلاس‌های دیگر دارد. مطابق این جدول ترتیب منطقه شهری، آب و پوشش گیاهی و جنگل به ترتیب تمایز قرار دارند. بدین ترتیب دانش‌های زیر از امضای پلاریمتری حاصل می‌شود:

✓ کلاس منطقه شهری از کلاس‌های جنگل و پوشش گیاهی متمایز است.

✓ کلاس پوشش گیاهی از کلاس‌های جنگل متمایز است.

جدول ۴- همبستگی بین امضای پلاریمتری (Co-polarized) میانگین داده‌های آموزشی کلاس‌های مختلف

	Or	Pw	Sb	Ur	Wa	GV	Sum
Or	1	0.97	0.98	0.31	0.99	0.98	5.23
Pw	0.97	1	0.98	0.34	0.98	0.98	5.24
Sb	0.98	0.98	1	0.25	0.99	1	5.20
Ur	0.31	0.34	0.25	1	0.28	0.27	2.46
Wa	0.99	0.98	0.99	0.28	1	0.99	5.23
GV	0.98	0.98	1	0.27	0.99	1	5.23

جدول ۵- فاصله اقلیدسی بین امضای پلاریمتری (Co-polarized) میانگین داده‌های آموزشی کلاس‌های مختلف

	Or	Pw	Sb	Ur	Wa	GV	Sum
Or	0	16.22	14.06	36.62	13.86	7.48	88.24
Pw	16.22	0	5.38	34.78	27.64	19.40	103.42
Sb	14.06	5.38	0	35.96	25.54	16.58	97.53
Ur	36.62	34.78	35.96	0	43.12	39.02	189.52
Wa	13.86	27.64	25.54	43.12	0	9.50	119.62
GV	7.48	19.40	16.58	39.02	9.50	0	91.98

انتخاب ویژگی‌های بهینه ضروری به نظر می‌رسد. روش‌های مختلفی برای انتخاب ویژگی‌های بهینه وجود دارد. از جمله این روش‌ها می‌توان به روش‌های مختلف بهینه‌سازی مثل ژنتیک^۱ و یا روش‌های آماری مانند PCA اشاره کرد. روش پیشنهادی در این تحقیق به دنبال فرآیندی دانش‌مبناست که تلفیقی از معیارهای آماری و دانش خبره باشد. سه معیار برای انتخاب ویژگی‌های بهینه در نظر گرفته شد. فاصله JM که عددی بین صفر و ۲ را برای میزان تفکیک‌پذیری یک ویژگی ارائه می‌دهد، ویژگی‌هایی با JM بزرگ‌تر برای انتخاب اولویت‌دارند (رابطه ۵).

$$JM_{ij} = \sqrt{2(1 - e^{-\alpha})}$$

$$\alpha = \frac{1}{8}(\mu_i - \mu_j)^T \left(\frac{C_i + C_j}{2} \right)^{-1} (\mu_i - \mu_j) + \frac{1}{2} \ln \left(\frac{|(C_i + C_j)/2|}{\sqrt{|C_i| \times |C_j|}} \right) \quad (5)$$


در رابطه فوق C_i کوواریانس ویژگی موردنظر در کلاس i ، μ_i میانگین ویژگی در کلاس i و $|C_i|$ دترمینان ماتریس C_i است. این فاصله برای تمام ویژگی‌ها در هریک از ۵ سطح طبقه‌بندی که طراحی شد اندازه‌گیری می‌شود. با توجه به میزان تفکیک بین کلاس‌ها، در هر سطح ویژگی‌های با بیشترین فاصله JM به‌عنوان کاندیداهای ویژگی‌های بهینه انتخاب می‌شوند.

یکی از معیارهای آماری دیگر برای انتخاب ویژگی‌های بهینه که در این تحقیق به کار گرفته شد میزان همبستگی بین ویژگی‌های مختلف است. درواقع ویژگی‌های انتخابی نباید به ویژگی‌های انتخاب‌شده از قبل وابسته باشند. اولویت با ویژگی‌های با JM بیشتر است اما نباید ویژگی‌ها همبسته باشند. در هر ۵ سطح طبقه‌بندی این همبستگی بین دو طرف طبقه‌بندی محاسبه می‌شود.

برخی اطلاعات را می‌توان از دانش خبره دریافت. مطابق این دانش می‌توان اولویت‌هایی را برای کلاس‌های مختلف ارائه کرد. قانون مهم حاصل از دانش خبره مطابق با خصوصیات فیزیکی درختان در منطقه‌ی مورد مطالعه این تحقیق عبارت است از:

✓ کلاس Or درختی سخت‌چوب است و خصوصیات متفاوتی از دو گونه‌ی دیگر Pw و Sb که نرم‌چوب هستند دارد.

با توجه به مجموع دانش‌های فوق می‌توان طرح درختی شکل ۵ را برای تفکیک و طبقه‌بندی کلاس‌های موردنظر پیشنهاد داد.



شکل ۵- طرح درختی نهایی، برگرفته از سه دانش آماری، فیزیکی و خبره

۵-۳- انتخاب ویژگی‌های بهینه

با توجه به تعداد زیاد ویژگی‌های حاصل از داده پلاریمتری و همچنین وجود برخی ویژگی‌های نویزی و همبستگی بین ویژگی‌های مختلف نیاز به یک فرآیند

^۱ Genetic

دارد. از آنجایی بیشتر کلاس‌های موردبررسی در این تحقیق اهداف خالص نیستند، حجم بیشتر ویژگی‌های انتخابی ویژگی‌های ناهمدوس هستند. الگوریتم‌های تجزیه همدوس بیشتر مناسب اهداف خالص هستند. بدون میانگین‌گیری روی داده استخراج می‌شوند؛ بنابراین برای کلاسی مانند منطقه‌ی شهری که خالص‌تر از سایر کلاس‌هاست وجود ویژگی‌های حاصل از روش‌های همدوس مناسب است. در مقابل روش‌های ناهمدوس مناسب کلاس‌های جنگل و پوشش گیاهی می‌باشد.

یکی از معیارهای مهم دیگر برای انتخاب ویژگی، دانش خبره است که از نمایش پراکندگی^۱ داده‌های آموزشی در ویژگی و همچنین اطلاعات قبلی درباره نوع ویژگی‌ها حاصل می‌شود. ویژگی‌هایی که جدایی بیشتری بین دو کلاس ایجاد کنند، در اولویت هستند. کنترل نهایی برای انتخاب ویژگی با همین دانش خبره انجام می‌شود. جدول ۶ ویژگی‌های انتخاب‌شده در سطوح طبقه‌بندی مختلف را نشان می‌دهد. در انتخاب مجموعه نهایی کاهش ابعاد ویژگی تا حد امکان هم موردتوجه قرار

جدول ۶- ویژگی‌های انتخاب‌شده در سطوح مختلف طبقه‌بندی (SVM-DT)

سطح	ویژگی‌های انتخاب‌شده			
	S _{hv}	SRC5	SRC6	Free_dbl
1	Touz_tau	Free2_grou	Neu_psi	Yam_dbl
	Span	Shanon		
2	S _{hv}	S _{hh}	T ₃₃	C ₃₃
	Krog_d	SRC6	H	Free2_vol
	Neu_psi	Neu_tau	Yam_hel	Touz_tau
	Shanon			
3	S _{hh}	S _{hv}	T ₂₂	T ₁₂
	T ₁₃	C ₁₁	SRC5	SRC4
	SRC5	SRC6	(1-H)A	H
	Free2_vol	Free2_grou	Neu_psi	Neu_tau
	Van_dbl	Touz_tau	Shanon	T33_bar
4	T ₂₂	T ₁₂	T ₁₃	C ₁₁
	SRC5	SRC6	(1-H)A	H
	Free_dbl	Free2_vol	Free2_grou	Neu_delta_phi
	Neu_psi	Van_dbl	Yam_dbl	Touz_alpha
	Touz_phi	Touz_psi	Touz_tau	betta
	delta	Shanon		
5	S _{hh}	S _{hv}	T ₂₂	T ₁₂
	T ₁₃	C ₁₁	SRC5	SRC4
	T33_bar	(1-H)A	H	Yam_dbl
	Free2_vol	Free2_grou	Neu_psi	Neu_tau
	Yam_vol	Touz_alpha	Touz_tau	Shanon

دانش اولیه. شکل ۶ نقشه‌ی طبقه‌بندی روش‌های ذکرشده را نشان می‌دهد. همچنین دقت کلاسی و دقت کلی این روش‌ها در جدول ۷ آمده است.


۵-۴- تحلیل نتایج طبقه‌بندی

برای ارزیابی نتایج طبقه‌بندی گام‌به‌گام اضافه شدن مراحل بررسی گردید. طبقه‌بندی کننده ویشارت، SVM با تمام ویژگی‌ها، SVM-DT با تمام ویژگی‌ها، SVM-DT شی‌مبنا همراه با انتخاب ویژگی و SVM-DT شی‌مبنا با انتخاب ویژگی و


^۱ Scatter plot

جدول ۷- مقایسه نتایج روش‌های طبقه‌بندی با روش پیشنهادی (SVM-DT)


	Wishart	SVM	SVMDT	SVMDT-Obj	SVMDT-Obj-Sel	KSVMDT-Obj-Sel
Or	37.95	57.29	67.39	73.17	72.34	76.63
Pw	42.93	47.8	49.67	65.67	70.77	79.6
Sb	64.19	76.34	76.09	80.4	82.09	86.9
Ur	89.07	94.33	95.34	92.37	94.58	98.01
Wa	100	100	100	100	100	100
GV	93.19	92.55	94.29	91.5	93.03	95.51
Overall	72.30	78.97	81.53	84.97	86.18	87.36




SVM با تمام ویژگی‌ها




ویشارت پیکسل مبنای




SVM-DT شیء‌مبنای با تمام ویژگی‌ها




SVM-DT با تمام ویژگی‌ها



SVM-DT شیء‌مبنای با انتخاب ویژگی و دانش اولیه



SVM-DT شیء‌مبنای با انتخاب ویژگی



شکل ۶- نقشه‌ی طبقه‌بندی روش‌های مختلف

همان‌طور که از تمام دانش‌ها قبل از طبقه‌بندی قابل‌استخراج بود، کلاس Wa کلاسی با خصوصیات کاملاً متفاوت از سایر کلاس‌هاست. پراکنش حاصل از آب یک پراکنش سطحی است که گاهی اوقات پراکنش‌های دوسطحی کوچک در آن دیده می‌شود. در مقابل اگرچه سطوح مختلفی در مناطق شهری هستند که پراکنش سطحی تولید می‌کنند اما همواره پیچیدگی‌های بیشتری در یک واحد تصویر در منطقه‌ی شهری وجود دارد که به سهم پراکنش‌های دوسطحی و ماریچ می‌افزاید. بیشترین سهم پراکنش کلاس‌های جنگل نیز مربوط به پراکنش حجمی و تا حدودی دوسطحی است. از این‌رو جدایی زیادی بین کلاس Wa و سایر کلاس‌ها وجود دارد که می‌تواند توسط روش‌های مختلف طبقه‌بندی با دقت بالا از دیگر کلاس‌ها تفکیک شود (جدول ۷).

از آنجایی که کلاس Ur ساختار پیچیده‌تری نسبت به آب دارد، دقت طبقه‌بندی در روش SVM به‌مراتب از طبقه‌بندی کننده‌ای مانند ویشارت که تنها از اطلاعات آماری استفاده می‌کند بهتر است؛ اما نکته قابل‌ذکر بهبود دقت این کلاس در روش پیشنهادی SVM-DT است. اضافه کردن دانش خبره در تعیین مراحل طبقه‌بندی توانست تا حدی از اشتباهات طبقه‌بندی کننده SVM جلوگیری کند. وقتی دانش مکانی به طبقه‌بندی کننده اضافه می‌شود دقت این کلاس کاهش می‌یابد که شاید بتوان گفت روش قطعه‌بندی برای اضافه کردن اطلاعات مکانی در منطقه شهری خیلی مناسب نیست. استفاده از مجموعه ویژگی‌های بهینه باعث کاهش وابستگی بین آن‌ها، همچنین بهبود پیچیدگی محاسباتی و در نتیجه افزایش دقت در کلاس Ur می‌شود. اضافه کردن دانش اولیه به طبقه‌بندی موجب افزایش مناسب دقت منطقه شهری می‌شود. در هنگام جدا کردن این کلاس از سایر کلاس‌ها تعداد داده‌های آموزشی کاملاً نامتقارن است. تعداد داده‌های آموزشی کلاس Ur حدود یک‌سوم سایر کلاس‌هاست. به همین دلیل بیشترین تأثیر دانش اولیه در نتایج طبقه‌بندی در کلاس Ur نمود پیدا می‌کند. اگرچه این نسبت برای کلاس Wa کوچک‌تر است اما همان‌طور که گفته شد با توجه به جدایی زیاد این کلاس از سایر کلاس‌ها دانش اولیه در نتیجه این کلاس بی‌تأثیر است.

وجود ویژگی‌های همبسته در طبقه‌بندی کننده SVM و SVM-DT موجب می‌شود که دقت کلاس GV خیلی

نسبت به طبقه‌بندی کننده ویشارت بهبود نیابد و یا حتی کاهش نیز پیدا کند. البته دقت نسبتاً بالای این کلاس در تمام روش‌ها نشان‌دهنده تمایز این کلاس از سایرین می‌باشد. بهبود دقت روش SVM-DT در این کلاس نسبت به SVM نشان‌دهنده روند مناسب طرح درختی است. متأسفانه در این کلاس هم مانند کلاس منطقه‌ی شهری دانش مکانی موجب کاهش دقت طبقه‌بندی شده است؛ اما با همان استدلال قبل که در کلاس Ur آورده شد می‌توان گفت که دانش اولیه موجب ایجاد توازن در روند آموزش طبقه‌بندی کننده SVM شده است.

طبقه‌بندی گونه‌های جنگلی از مهم‌ترین اهداف این تحقیق بوده است که بر این اساس عملکرد روش پیشنهادی در این کلاس‌ها اهمیت بیشتری دارد. کلاس‌های جنگل دارای پراکنشی بسیار نزدیک به هم و بسیار پیچیده است. پراکنش‌های حجمی مختلف، پراکنش‌های دوسطحی بین تنه درختان و زمین و همچنین پراکنش دوقطبی بین شاخ و برگ‌ها در این کلاس‌ها وجود دارد که خود نشان‌دهنده دشوار بودن تفکیک آن‌ها از یکدیگر است. وجود دانش فیزیکی کافی که بخشی از دانش حاصل از داده است لازمه‌ی اساسی طبقه‌بندی مطلوب در کلاس‌های جنگل است. به همین دلیل افزایش چشم‌گیری در طبقه‌بندی کننده‌های SVM و SVM-DT نسبت به ویشارت وجود دارد. روش SVM-DT نسبت به SVM یک افزایش ۱۰ درصدی در دقت کلاس Or ایجاد کرده است. در طرح طبقه‌بندی اولویت با جدا شدن این کلاس از دو کلاس دیگر Sb و Pw بود همین ایجاد یک اولویت به‌موقع به کمک دانش خبره موجب افزایش دقت این کلاس شده است. دقت کلاس‌های Or، Pw و Sb به کمک دانش مکانی به ترتیب نزدیک ۶، ۱۶ و ۴ درصد افزایش یافته است. همان‌طور که پیش‌تر بیان شد دانش مکانی بر روی سایر کلاس‌ها یا بی‌تأثیر و یا تأثیر منفی داشت اما موجب افزایش محسوس دقت در کلاس‌های جنگل شده است. پراکنش کلاس‌های جنگل به یکدیگر بسیار نزدیک‌اند و با داشتن اطلاعات مربوط به یک تک پیکسل نمی‌توان به نتایج قابل‌اتکایی رسید. انتخاب ویژگی‌های بهینه باعث بهبود نتایج در دو کلاس Pw و Sb شده است. همچنین اضافه کردن دانش اولیه تنها در دقت کلاس Or مؤثر بوده است چراکه عدم توازن داده آموزشی بیشتر در تفکیک این کلاس از سایر کلاس‌های جنگل محسوس است.

۶- نتیجه‌گیری

در این مقاله روش طبقه‌بندی SVM-DT برای داده پلاریمتری رادار با روزنه مصنوعی توسعه داده شد. در روش پیشنهادی دانش‌های سه‌گانه (دانش اولیه، دانش حاصل از داده و دانش خبره) در فرآیند طبقه‌بندی SVM-DT برای داده پلاریمتری به کار گرفته شد. در روش پیشنهادی این مقاله، دانش حاصل از داده (آماري، فیزیکی و مکانی) در مراحل تعیین طرح درختی، ویژگی برای طبقه‌بندی کننده SVM و همچنین در انتخاب ویژگی‌های بهینه به کار گرفته می‌شود. همچنین دانش اولیه برای توازن تعداد داده‌های آموزشی در طبقه‌بندی کننده SVM استفاده می‌شود. در نهایت دانش خبره نیز در دو مرحله ایجاد طرح درختی و همچنین انتخاب ویژگی‌های بهینه در روش پیشنهادی استفاده می‌شود. آزمایش‌ها برای ارزیابی نتایج روش پیشنهادی با شش طبقه‌بندی کننده طراحی شد. طبقه‌بندی کننده ویشارت، SVM با تمام ویژگی‌ها، SVM-DT با تمام ویژگی‌ها، SVM-DT شی‌مبنا همراه با انتخاب ویژگی و SVM-DT شی‌مبنا با انتخاب ویژگی و دانش اولیه. مهم‌ترین نتایج این آزمایش‌ها به شرح زیر است.

دقت کلاس آب در تمام روش‌ها ۱۰۰ درصد است که مهم‌ترین دلیل آن تمایز بسیار زیاد پراکنش این کلاس از سایر کلاس‌ها می‌باشد؛ بنابراین تأثیر سطوح مختلف دانش مورد استفاده در تحقیق در این کلاس محسوس نیست. دقت کلاس Ur با روش‌های مختلف متفاوت است. روش SVM، SVM-DT و ویشارت به ترتیب نتایج بهتری را ارائه می‌دهند. اضافه کردن دانش مکانی به این کلاس

تأثیر منفی دارد. همچنین انتخاب ویژگی‌های بهینه و دانش اولیه اثر مثبتی بر این کلاس داشتند.

دقت کلاس GV برخلاف تمام کلاس‌های دیگر در طبقه‌بندی کننده ویشارت دقت بهتری نسبت به SVM با تمام ویژگی‌ها دارد. اضافه کردن دانش مکانی مانند کلاس Ur تأثیر مثبت ندارد. دانش اولیه بهبود نسبی در نتیجه این کلاس ایجاد می‌کند.

دقت کلاس‌های جنگل (Or، Pw و Sb) به دلیل نزدیکی پراکنش آن‌ها در روش ویشارت اصلاً مطلوب نیست. روش SVM-DT باعث بهبود نتایج نسبت به SVM می‌شود. اضافه کردن دانش مکانی برخلاف سایر کلاس‌ها در این کلاس بسیار مثبت است. انتخاب ویژگی‌های بهینه نیز بر روی دو کلاس Pw و Sb تأثیر مثبت دارد. دانش اولیه تنها در دقت کلاس Or باعث بهبود نسبی می‌شود و در دو کلاس دیگر تقریباً بی‌تأثیر است.

مطابق نتایج روش پیشنهادی این تحقیق افزودن اطلاعات جانبی موجب پایداری روند آموزش روش طبقه‌بندی داده پلاریمتری و همچنین بهبود دقت آن می‌شود؛ بنابراین توصیه می‌شود در کنار اطلاعات و دانشی که از داده پلاریمتری به دست می‌آید و همچنین دانش اولیه و خبره‌ای که در این مقاله استفاده شد، از سایر اطلاعات مانند اطلاعاتی از جنس خاک، شیب در منطقه و یا نقشه‌های کاربری موجود، در تحقیقات آتی استفاده شود.

سپاسگزاری

از همکاری سازمان جنگل‌داری کانادا برای اجازه استفاده از داده رادارست-۲ تشکر و قدردانی می‌نمایم.

مراجع

- [1] Lee J. S., Grunes M. R., and Kwok R. (1994), "Classification of multi-look polarimetric SAR imagery based on complex Wishart distribution," Int. J. Remote Sens., vol. 15, no. 11, pp. 2299-2311.
- [2] Van Zyl J. J. and Burnette C. (1992), "Bayesian classification of polarimetric SAR images using adaptive a priori probabilities," Int. Jour. Remote Sens., vol. 13, no. 5, pp. 835-840.
- [3] Cloude S. R. and Pottier E. (1997), "An entropy based classification scheme for land applications of polarimetric SAR," IEEE Trans. Geosci. Remote Sens., vol. 35, no. 1, pp. 68-78.

- [4] Maghsoudi, Y., 2011. "Analysis of Radarsat-2 Full Polarimetric Data for Forest Mapping," Ph.D. dissertation, Calgary University, Calgary, The Canada.
- [5] Pierce L. E., Ulaby F. T., Sarabandi K., and Dobson M. C. (1994), "Knowledge-based classification of polarimetric SAR images," IEEE Trans. Geosci. Remote Sens., vol. 32, no. 5, pp. 1081-1086.
- [6] Dobson M. C., Pierce L. E., and Ulaby F. T. (1996), "Knowledge-based land-cover classification using ERS-1/JERS-1 SAR composites," IEEE Trans. Geosci. Remote Sens., vol. 34, no. 1, pp. 83-99.
- [7] Cloude S. R. and Pottier E. (1996), "A review of target decomposition theorems in radar polarimetry," IEEE Trans. Geosci. Remote Sens., vol. 34, no. 2, pp. 498-518.
- [8] An W., Cui Y., Yang J. (2010), "Three-component model-based decomposition for polarimetric SAR data," IEEE Trans. Geosci. Remote Sens., vol. 48, pp. 2732-2739.
- [9] Lardeux C., Frison P. L., Tison C., Souyris J. C., Stoll B., Fruneau B., Rudant J. P. (2009), "Support vector machine for multifrequency SAR polarimetric data classification," IEEE Trans. Geosci. Remote Sens., vol. 47, pp. 4143-4152.
- [10] Lardeux, C., Frison, P.-L., Rudant, J.-P., Souyris, J.-C., Tison, C., Stoll, B. (2006), "Use of the SVM classification with polarimetric SAR data for land use cartography," In: IEEE Int. Geosc. Remote Sens. Sym., IGARSS 2006, pp. 493-496.
- [11] Chen C. T., Chen K. S., Lee J. S. (2003), "The use of fully polarimetric information for the fuzzy neural classification of SAR images," IEEE Trans. Geosci. Remote Sens., vol. 41, pp. 2089-2100.
- [12] Ince T., Kiranyaz S., and Gabbouj M. (2012), "Evolutionary RBF classifier for polarimetric SAR images," Expert Systems with Applications, vol. 39, pp. 4710-4717.
- [13] Maghsoudi Y., Collins M., and Leckie D. G. (2012), "Polarimetric classification of Boreal forest using nonparametric feature selection and multiple classifiers," Int. J. Appl. Earth Observ. Geoinf. vol. 19, pp. 139-150.
- [14] Ferrazzoli P., Guerriero L., and Schiavon G. (1999), "Experimental and model investigation on radar classification capability," IEEE Trans. Geosci. Remote Sens., vol. 37, no. 2, pp. 960-968.
- [15] Qi Z., Yeh A. G. O., Li X., and Lin Z. (2012), "A novel algorithm for land use and land cover classification using RADARSAT-2 polarimetric SAR data," Remote Sens. Environment, vol. 118, pp. 21-39.
- [16] Bennett K. P. and Blue J. A. (1998), "A support vector machine approach to decision trees," in Proceedings of the Neur. Netw. IEEE World Cong. Compu. Intell. pp. 2396-2401.
- [17] Arun Kumar M. and Gopal M. (2010), "A hybrid SVM based decision tree," Pattern Recognition, vol. 43, pp. 3977-3987.
- [18] Madzarov G., Gjorgjevikj D., and Chorbev I. (2009), "A Multi-class SVM Classifier Utilizing Binary Decision Tree," Informatica (Slovenia), vol. 33, pp. 225-233.
- [19] Cheong S., Oh S. H., and Lee S. Y. (2004), "Support vector machines with binary tree architecture for multi-class classification," Neur. Infor. Proces. Lett. Revie. vol. 2, pp. 47-51.
- [20] Vural V. and Dy J. G. (2004), "A hierarchical method for multi-class support vector machines," in Proceedings of the twenty-first int. conf. Mach. lear., pp. 105-110.
- [21] Moustakidis S., Mallinis G., Koutsias N., Theocharis J. B., and Petridis V. (2012), "SVM-based fuzzy decision trees for classification of high spatial resolution remote sensing images," IEEE Trans. Geosci. Remote Sens., vol. 50, pp. 149-169.
- [22] Jafari M. (2014), Knowledge based classification of polarimetric SAR data using physical information, Master thesis in Remote Sensing engineering, K. N. Toosi University of Technology.
- [23] Jafari M., Maghsoudi Y., Valadan zoej M J. (2015), A New Method for Land Cover Characterization and Classification of Polarimetric SAR Data Using Polarimetric Signatures, IEEE Journal of Selected Topics in Applied Earth Observation Remote Sensing, vol. 8, pp. 498-518.

- [24] Lauer F. and Bloch G. (2008), "Incorporating prior knowledge in support vector machines for classification: A review," *Neurocomputing*, vol. 71, pp. 1578-1594.
- [25] Veropoulos K., Campbell C., and Cristianini N. (1999), "Controlling the sensitivity of support vector machines," in *Proceedings of the int. joi. Conf. artifi. intelli.* pp. 55-60.
- [26] Brown M. P., Grundy W. N., Lin D., Cristianini N., Sugnet C. W., Furey T. S., et al. (2000), "Knowledge-based analysis of microarray gene expression data by using support vector machines," *Proceed. Nation. Acad. Scienc.*, vol. 97, pp. 262-267.
- [27] Wu Y., Ji K., Yu W., and Su Y. (2008), "Region-based classification of polarimetric SAR images using Wishart MRF," *IEEE Geosci. Remote Sens. Lett.* vol. 5, pp. 668-672.
- [28] M. Baatz, U. Benz, S. Dehghani, M. Heynen, A. Holtje, P. Hofman, et al. (2004), "eCognition Professional: User Guide 4 (Munich, Germany: Definiens Imaging),".