



سجش از دور

GIS ایران



سنجش از دور و GIS ایران
Iranian Remote Sensing & GIS
سال اول، شماره چهارم، زمستان ۱۳۸۸
Vol.1, No.4, Winter 2010
۹۸-۸۷

ارزیابی مدل‌های شبکه عصبی و درخت تصمیم برای تشخیص مناطق ابری در تصاویر ماهواره نوآ بر روی گستره ایران

خلیل قربانی*^۱، علی خلیلی^۲، سید کاظم علوی پناه^۳، غلامرضا نخعی زاده^۴

۱. دانشجوی دوره دکتری هواشناسی کشاورزی، دانشکده مهندسی و فناوری کشاورزی، دانشگاه تهران
۲. استاد دانشکده مهندسی و فناوری کشاورزی، دانشگاه تهران
۳. استاد دانشکده جغرافیا، دانشگاه تهران
۴. استاد دانشکده اقتصاد، دانشگاه کالسروهه آلمان

تاریخ پذیرش مقاله: ۱۳۸۹/۸/۲

تاریخ دریافت مقاله: ۱۳۸۸/۱۱/۷

چکیده

برای مطالعه سطح زمین با تصاویر ماهواره‌ای، طبقه‌بندی و تشخیص درست پیکسل‌های ابری امری ضروری به‌شمار می‌آید. از میان روش‌های طبقه‌بندی موجود می‌توان به مدل‌های شبکه عصبی و درخت تصمیم در داده‌کاوی اشاره کرد که الگوریتم‌های متعددی از این دو دسته مدل، شکل گرفته و توسعه یافته‌اند. به‌منظور ارزیابی دقت این مدل‌ها در طبقه‌بندی و انتخاب بهترین آنها، یازده الگوریتم از این دو دسته مدل ارزیابی شدند. بدین منظور با انتخاب ۴۰۰۰۰ پیکسل با ویژگی‌های مناطق ابری، صاف، برفی و آب در چهار کلاس از تصاویر کالیبره شده ماهواره نوآ بر روی گستره ایران در فصول مختلف سال و با استخراج اطلاعات پنج باند نوآ محاسبه نسبت‌های باندی NDVI، نسبت بازتابندگی باند یک به بازتابندگی باند دو و اختلاف دمای درخشندگی باند پنج با دمای درخشندگی باند چهار و معرفی آنها به‌عنوان متغیرهای ورودی، دقت هر یک از الگوریتم‌ها در طبقه‌بندی این کلاس‌ها مقایسه شد. زمان اجرای سریع الگوریتم‌های درخت تصمیم در مقایسه با اجرای کندتر الگوریتم‌های شبکه عصبی و شفاف بودن تصمیمات گرفته شده در مدل‌های درخت تصمیم از مزایای این دسته مدل‌های طبقه‌بندی است. در نهایت بعد از تشکیل ماتریس تطابق که تعداد درستی و خطا در طبقه‌بندی پیکسل‌ها را نشان می‌دهد، مشخص شد که در بین یازده الگوریتم مورد مقایسه، الگوریتم درخت تصمیم C5، با ۴۳ مورد خطا در تشخیص پیکسل‌های ابری، با دقتی معادل ۹۹/۵۶ درصد دارای بهترین دقت در طبقه‌بندی است. نیز با توجه به مزایای ذکر شده برای این دسته مدل‌های طبقه‌بندی، C5 مناسب‌ترین الگوریتم برای طبقه‌بندی پیکسل‌های ماهواره‌ای و تشخیص پیکسل‌های ابری شناخته شد.

کلیدواژه‌ها: طبقه‌بندی، پیکسل ابری، شبکه عصبی، درخت تصمیم، ماهواره نوآ.

* نویسنده مکاتبه‌کننده: کرج، پردیس کشاورزی و منابع طبیعی، دانشکده مهندسی و فناوری کشاورزی، گروه آبیاری. تلفن: ۰۹۱۱۳۷۷۴۵۸۳

۱- مقدمه

کاربر (به صورت خودکار) الگوها و رابطه‌های منطقی بین داده‌ها را پیدا می‌کنند. داده‌کاوی از روش‌هایی است که به وسیله آن الگوهای مفید از میان داده‌ها با حداقل دخالت کاربر استخراج می‌شوند و طبقه‌بندی یکی از مسائل مطرح در داده‌کاوی است. از جمله الگوریتم‌هایی که برای طبقه‌بندی در داده‌کاوی مورد استفاده قرار می‌گیرد، مدل‌های شبکه عصبی مصنوعی و درخت تصمیم‌اند.

امروزه روش‌های یادگیری ماشینی متنوعی در سنجش از دور به کار می‌روند. به طور نمونه می‌توان به استفاده از فن شبکه عصبی و منطق فازی در طبقه‌بندی نظارت شده برای تصاویر سنجنده‌های چندطیفی (Promcharoen et al., 1999)، به کار بردن الگوریتم ژنتیک برای ماسک ابر (Brumby et al., 2001)، استفاده از درخت تصمیم برای طبقه‌بندی پوشش اراضی (Hansen et al., 1996) و استفاده از شبکه عصبی براساس مشخصه‌های طیفی و بافت تصویر در طبقه‌بندی ابرها (Tian et al., 1999) اشاره کرد.

معروف‌ترین الگوریتمی که به منظور تشخیص ابر در تصاویر ماهواره نوآ ارائه شده، الگوریتم^۱ CLAVR است، که (Stowe 1999) و دیگران آن را وضع کرده‌اند. این الگوریتم، چهار درخت تصمیم را برای تشخیص مناطق صاف از مناطق ابری بر روی سطوح زمینی و آبی در طول روز و شب به کار می‌برد، به طوری که هر درخت تصمیم آستانه‌ها و آزمون‌های یکنواختی را بر روی آرایه ۲×۲ از پیکسل‌ها به اجرا درمی‌آورد و پیکسل‌ها را در دسته‌های صاف، مخلوط و یا ابری طبقه‌بندی می‌کند. این درحالی است که (Shiffman 2005) و دیگران با مقایسه نتایج درخت تصمیم الگوریتم‌های CLAVR و ALDT^۲ در تشخیص ابر از تصاویر ماهواره نوآ، دقت نتایج الگوریتم ALDT را بهتر از CLAVR تشخیص دادند، به طوری که اختلاف در دقت‌های این دو الگوریتم

در صورت عدم تشخیص درست مناطق ابری، چه بسا تحلیل‌هایی که براساس این تصاویر صورت می‌گیرند، به نتایج نادرستی بینجامند. روش‌های زیادی برای تشخیص ابر با استفاده از پردازش پیکسل به پیکسل، تکوین شده و توسعه یافته است (Hutchison et al., 1997; Saunders and Kriebles, 1998; Dechet et al., 1998). این روش‌ها بر پایه آستانه‌های به دست آمده از همه پنج باند NOAA/AVHRR به صورت رابطه منطقی ریاضی بیان می‌گردد. عموماً بیشتر الگوریتم‌های تشخیص ابر برای تصاویر سنجنده NOAA/AVHRR از داده‌های بازتاب سطحی و حرارتی استفاده می‌شود. تشخیص ابر بر این حقیقت استوار است که ابرها عموماً در طیف مرئی (باند ۱) روشن و یا در طیف مادون قرمز (باند ۲) تیره‌اند (Gutman, 1992) و در باند سه به بالا و یا در باندهای چهار و پنج به طور نسبی دمای درخشندگی پایین‌تری دارند (Yamanouchi and Kawaguchi, 1992). در این روش‌ها با معرفی آستانه‌هایی برای مقادیر بازتاب سطحی یا حرارتی باندها و یا نسبت‌های باندی، آزمون‌هایی برای تشخیص مناطق ابری ارائه شده است. افزون بر اینها، (Engman and Gurney 1991) برای تشخیص ابر از برف، توصیه کرده‌اند که ترکیبی از عوارض زمینی، تشخیص الگو، یکنواختی در بازتاب‌ها، حضور سایه (سایه ابر یا عوارض زمینی) و پایداری تصویر با زمان در تفسیر تصاویر ماهواره‌ای، مورد استفاده قرار گیرد (Porhemmat, 2002). در طول موج ۱/۶ میکرون ابرهای نازک سیروس و ابرهای ضخیم می‌توانند به طور مستقیم طبقه‌بندی شوند و از برف تفکیک گردند (Warren, 1982). این موضوع به طور شفاف در استفاده از سنجنده TM لندست، که باند پنج آن در محدوده ۱/۷۸-۱/۵۷ میکرون است، ثابت شده است (Dozier, 1987; Baglio, 1989).

البته روش‌های دیگری هم وجود دارند که اصطلاحاً به کشف دانش می‌پردازند؛ یعنی با کمترین دخالت

1. CLAVR: Clouds from AVHRR

2. ALDT: Automatically Learned Decision Trees

می‌یابد. الگوریتم Exhaustive CHAID اصلاح شده الگوریتم CHAID است و برای برطرف کردن برخی از ضعف‌های CHAID تکوین یافته است (Biggs, de Ville, and Suen, 1991). به‌ویژه زمانی که ممکن است CHAID نتواند انشعاب بهینه‌ای برای یک متغیر پیدا کند. از این‌رو یکی کردن داده‌ای را به محض اینکه داده‌های باقی‌مانده از لحاظ آماری متفاوت باشند، متوقف می‌کند.

الگوریتم C&RTree (درخت رگرسیون و طبقه‌بندی) (Breiman et al., 1984)، روند‌افزار بازگشتی دودویی است، که گره‌های والدین را دقیقاً به دو گروه فرزند منشعب می‌کند و به‌طور بازگشتی منشعب کردن را تا زمانی که انشعاب دیگری نتواند ساخته شود ادامه می‌دهد.

الگوریتم C4.5 و C5 بهبودیافته الگوریتم IDE3 هستند، که در آن هرس کردن با جایگزینی گره داخلی با گره برگ رخ می‌دهد که بدان وسیله درصد یا میزان خطا کاهش می‌یابد (Podgorelec et al., 2002). این الگوریتم روشی افزایشی از هرس کردن درخت را به‌کار می‌گیرد تا خطای طبقه‌بندی کردن ناشی از نویز یا جزئیات خیلی زیاد را در داده‌های آموزشی کاهش دهد. روش نرخ ناخالصی بهره برای ارزیابی مشخصه انشعاب کردن به کار می‌رود (Quinlan, 1993).

الگوریتم QUEST در واقع الگوریتم جدید دودویی گسترش - درخت است (Loh and Shih, 1997) که با انتخاب میدان انشعاب و نقطه انشعاب، جداگانه سروکار دارد. انشعاب تک‌متغیری در آن تقریباً با انتخاب میدان ناریب انجام می‌شود؛ یعنی اینکه اگر همه میدان‌های پیش‌بین به‌طور مساوی نسبت به میدان هدف آموزنده باشد، QUEST هر میدان پیش‌بین با احتمال برابر را انتخاب می‌کند. می‌توان هرس کردن مرکب خودکار را استفاده کرد، تا اندازه درخت کاهش یابد.

اما شبکه عصبی مصنوعی، یکی از روش‌های

از لحاظ آماری معنی‌دار بود. اینان برای ارزیابی مدل درخت تصمیم در تشخیص ابر از تصاویر سنجنده AVHRR از داده‌های گزارش شده در مرکز اطلاعات جوی بریتانیا¹ استفاده کردند که این داده‌ها شامل مشاهدات مقدار ابر در ایستگاه‌های متعدد هواشناسی‌اند. با توجه به عدم دسترسی به الگوریتم CLAVR، به ایجاد مدلی برای تشخیص و طبقه‌بندی پیکسل‌های ابر، برف و آب از پیکسل‌های صاف در تصاویر ماهواره نوآ پرداخته شد.

الگوریتم‌های متعددی از مدل‌های درخت تصمیم و شبکه عصبی برای طبقه‌بندی، شکل گرفته و توسعه یافته‌اند. در این تحقیق، ضمن استفاده از یازده الگوریتم ارائه شده در نرم‌افزار SPSS Clementine12، دقت این مدل‌ها در طبقه‌بندی پیکسل‌های ابری ارزیابی گردید تا مناسب‌ترین آنها در طبقه‌بندی پیکسل‌های ماهواره‌ای در منطقه مورد مطالعه (ایران) معرفی گردد. پیش از پرداختن به آن، نگاهی به الگوریتم‌های مورد استفاده، ضروری می‌نماید:

درخت‌های تصمیم روشی برای نمایش برخی از قوانینی هستند که به یک رده یا مقدار منتهی می‌گردند و از طریق جداسازی متوالی داده‌ها به گروه‌های مجزا ساخته می‌شوند. مدل‌های مختلفی از درخت تصمیم در داده‌کاوی به‌کار می‌روند که از آن میان می‌توان به روش‌های CHAID، C&RT، EXHAUSTIVE CHAID، C5 و QUEST اشاره کرد.

الگوریتم CHAID (Kass, 1980) فن آماری بسیار مؤثری برای قطع‌بندی کردن یا نمو درخت است و با استفاده از معیار معنی‌داری یک آزمون آماری (آزمون آماری کای اسکور برای میدان هدف گسسته و آزمون F برای میدان هدف پیوسته) همه مقادیر پتانسیل‌های پیش‌بین را ارزیابی می‌کند. سپس بهترین پیش‌بین را برای تشکیل اولین شاخه در درخت تصمیم برمی‌گزیند، به‌طوری که هر گروه از یک گروه مقادیر همگن از میدان انتخاب شده ساخته می‌شود. این روند به‌طور بازگشتی تا زمانی که درخت رشد کامل کرده باشد ادامه

1. BADC: British Atmospheric Data Center

غیرمفید از لایه‌های ورودی و مخفی هرس می‌شود. روش EXHAUSTIVE PRUNE حالت خاصی از PRUNE است که دارای دو لایه مخفی است که در آن تعداد واحدها در لایه‌های مخفی اول و دوم به ترتیب ۳۰ و ۲۰ است. RBFN نیز نوع خاصی از شبکه عصبی است، شامل سه لایه ورودی، مخفی و خروجی. لایه‌های ورودی و خروجی در آن شبیه به شبکه پرسپترون چند لایه است. لایه مخفی شامل نرون‌هایی است که کلاسترهایی از قالب‌های ورودی شبیه به کلاسترهای مدل K-means را ارائه می‌کند (Clementine® 12.0 Algorithms Guide, 2007).

۲- مواد و روش‌ها

برای انجام این تحقیق، شش تصویر از سنجنده AHVRR/3 ماهواره نوآ در فصول مختلف سال (۳ فروردین، ۲۴ خرداد، ۲۲ شهریور، ۳ آبان، ۹ دی و ۲۲ اسفند سال ۱۳۸۷) انتخاب شدند. سپس با استفاده از روابط زیر (ارائه شده در محیط نرم‌افزار PCI Geomatica V9.1) تصحیحات رادیومتری بر روی پیکسل‌های تصویر به اجرا درآمد:

ابتدا تصحیح برای زاویه سمت‌الرأسی خورشید انجام می‌شود، زیرا زاویه تابش خورشیدی بر مقدار انرژی دریافتی هر پیکسل و بازتاب آن مؤثر است. برای لحاظ کردن آن بر روی باندهای مرئی سنجنده AVHRR از رابطه (۱) استفاده می‌شود:

$$\text{Pixel}_{out} = \frac{\text{Pixel}_{in}}{\cos(Z)} \quad \text{رابطه (۱)}$$

Pixel_Out مقدار تصحیح شده پیکسل، Pixel_In مقدار تصحیح نشده پیکسل و $\cos(Z)$ کسینوس زاویه سمت‌الرأسی خورشید است.

در تصحیح رادیومتری با توجه به روابط زیر، مقدار عدد دیجیتالی که بین صفر تا ۱۰۲۳ متغیر است در باندهای مرئی به درصد بازتابندگی و در باندهای حرارتی به دمای درخشندگی برحسب درجه کلوین تبدیل می‌شود:

محاسباتی است که به کمک فرایند یادگیری و با استفاده از پردازشگرهایی به نام نرون تلاش می‌کند تا با شناخت روابط ذاتی بین داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. لایه یا لایه‌های مخفی، اطلاعات دریافت شده از لایه ورودی را پردازش می‌کنند و در اختیار لایه خروجی قرار می‌دهند. هر شبکه با دریافت مثال‌هایی آموزش می‌بیند. آموزش فرایندی است که در نهایت منجر به یادگیری می‌شود. یادگیری شبکه، زمانی انجام می‌شود که وزن‌های ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف بین مقادیر پیش‌بینی شده و محاسبه شده در حدی معقول و پذیرفتنی باشد. با دستیابی به این شرایط، فرایند یادگیری محقق شده است. شبکه عصبی آموزش دیده می‌تواند برای پیش‌بینی خروجی‌های متناسب با مجموعه جدید داده‌ها به کار رود (Dayhoff, 1990). در این تحقیق از روش‌های QUICK، DYNAMIC، MULTIPLE، PRUNE، EXHAUSTIVE PRUNE و RBFN در نرم‌افزار SPSS Clementine استفاده شده است.

در روش QUICK یک شبکه تک آموزش داده می‌شود و به طور پیش‌فرض یک لایه مخفی با حداکثر $(\sum (n_i + n_o) / 20)$ نرون برای شبکه در نظر گرفته می‌شود که در آن n_i تعداد نرون‌های ورودی و n_o تعداد نرون‌های لایه خروجی است. شبکه با روش انتشار پس‌رو آموزش می‌یابد. در روش MULTIPLE شبکه‌های چندتایی در حالت Pseudoparallel آموزش داده می‌شود و هر یک از شبکه‌های معین، مقداردهی می‌گردد و همه آنها آموزش داده می‌شوند. در نهایت شبکه با دقت بالا به عنوان مدل نهایی برگردانده می‌شود. در روش DYNAMIC، توپولوژی شبکه در طول آموزش با نرون‌های اضافه شده برای بهبود عملکرد تغییر می‌کند، تا زمانی که شبکه دقت مطلوب را به دست آورد. روش PRUNE به طور مفهومی برعکس روش DYNAMIC است. این روش با شبکه‌ای بزرگ شروع می‌شود و به تدریج با حذف کردن نرون‌های

رابطه (۲)

$$PO = S(c).PI + I(c)$$

PI مقدار کالیبره نشده پیکسل (معمولاً بین ۰-۱۰۲۳ برای AVHRR)، مقدار کالیبره شده پیکسل (بازتابندگی)، S(c) ضریب زاویه و I(C) عرض از مبدأ هستند که مقادیر ضریب زاویه و عرض از مبدأ از فایل تصویر قابل استخراج است. برای کالیبراسیون باندهای حرارتی از روابط زیر استفاده می‌شود:

رابطه (۳)

$$PO = PlanckEqn(E)$$

$$E = S(c).PI + I(c)$$

Po مقدار کالیبره شده پیکسل (دمای درخشندگی سطح برحسب درجه کلوین)، E رادیانس پیکسل ورودی ($mW/(m^2.Sr.cm^{-1})$) ضریب زاویه باند مورد نظر و I(c) عرض از مبدأ برای باند مورد نظر است. رابطه PlanckEqn بدین صورت است:

رابطه (۴)

$$T = \frac{C_1 \cdot V}{\ln(1 + C_1 \cdot V_r / E)}$$


$$C_1 = 1/191.0659 \times 10^{-5} (mW / m^2.sr.cm^{-4})$$

$$C_2 = 1/438833 (cm.k)$$

در رابطه مذکور، T دمای درخشندگی برحسب درجه کلوین، C1 مقدار ثابت ($mW/(m^2.Sr.cm^4)$) مقدار ثابت برحسب سانتی‌متر در کلوین، V شماره موج مرکزی (cm^{-1}) و E رادیانس ($mW/(m^2.Sr.cm^{-1})$) است. در سنجنده AVHRR/3 که بر روی ماهواره‌های نوآ ۱۵، ۱۶، ۱۷ و ۱۸ قرار دارد، باند دیگری به نام 3A در محدوده طیفی ۱/۶۴-۱/۵۸ میکرون اضافه شده است. با معرفی باند 3A، باند ۳ در محدوده طیفی (۳/۹۳ - ۳/۵۵) به باند 3B تغییر نام داد. چون در هر زمان فقط پنج باند از سنجنده AVHRR می‌توانند عمل کنند، بنابراین باندهای 3A و 3B بر روی

سنجنده AVHRR/3 به جای یکدیگر به کار برده می‌شوند. باند 3A با مرکزیت طول موج ۱/۶ میکرون، به طور معنی‌داری تفکیک بین ابرها و برف را بهبود بخشیده است. در این محدوده طیفی، برف بازتابندگی خیلی کمی دارد ولی بازتابندگی ابر زیاد است (شکل ۱). در این تحقیق به منظور کلاس‌بندی پیکسل‌های نمونه، با ایجاد تصویر با ترکیب رنگی کاذب از باند 3A (شکل ۲) و با تأکید بر اینکه معمولاً پوشش‌های برفی طی چند روز متوالی پایدارند و سایه پوشش‌های ابری بر روی تصاویر نمایان است، با بررسی تصاویر روزهای قبل و بعد یک تصویر، یکنواختی پوشش و کمک گرفتن از گزارش وضعیت جوی که میزان ابری یا صاف بودن آسمان و نوع ریزش‌های جوی (برف و باران) در ایستگاه‌های هواشناسی را گزارش می‌کند، با دقت مناطقی صاف یا ابری و برفی تشخیص داده شدند و از آنها نمونه‌برداری گردید. در مورد انتخاب پیکسل‌های آبی تلاش شد تا نمونه‌ها از قسمت‌های مختلف منابع آبی (دریاها و دریاچه‌ها) انتخاب شوند.

با نمونه‌برداری از پیکسل‌های واقع در مناطق ابری، صاف، برف و آب بر روی ایران (شکل ۲)، بازتابندگی باندهای یک و دو و سه برحسب درصد و دمای درخشندگی باندهای چهار و پنج برحسب درجه کلوین استخراج شد.




شکل ۱. منحنی بازتاب طیفی ابر و برف

منبع: Jensen, 2007

پیکسل از هر طبقه برای آموزش مدل و ۵۰۰۰ تای دیگر برای آزمون و مقایسه مدل‌ها در نظر گرفته شدند. بنابراین جدولی شامل ۴۰۰۰۰ نمونه که حاوی نه فیلد اطلاعاتی بود تشکیل گردید (جدول ۱).

از طبقه‌بندی‌کننده درخت تصمیم، الگوریتم‌های C5، EXHAUSTIVE CHAID، C&RT، CHAID و QUEST و از طبقه‌بندی‌کننده شبکه عصبی الگوریتم‌های QUICK، MULTIPLE، PRUNE، EXHAUSTIVE PRUNE، RBFN DYNAMIC مورد آزمون قرار گرفتند. ردیف یک تا هشت جدول ۱ به‌عنوان متغیر ورودی، و ردیف نهم آن به‌عنوان متغیر هدف تعیین شدند.

پس از آماده‌سازی داده‌ها، هر یک از یازده مدل طبقه‌بندی‌کننده اجرا شدند تا براساس داده‌های آموزشی آموزش ببینند. سپس از مدل‌های آموزش‌یافته، برای طبقه‌بندی ۲۰,۰۰۰ نمونه برای آزمون مدل‌ها در طبقه‌بندی پیکسل‌ها استفاده شد.



شکل ۲. مناطق انتخاب شده در تصاویر کالیبره شده سنجنده AVHRR/3 ماهواره نوآ

سپس نسبت‌های طیفی مانند NDVI، نسبت بازتابندگی باند دو به بازتابندگی باند یک و اختلاف دمای درخشندگی باند پنج با دمای درخشندگی باند چهار نیز برای هر یک از نمونه‌ها محاسبه شد. تعداد ۱۰۰۰۰ پیکسل از هر یک از طبقات صاف، برف، آب و ابری نمونه‌برداری شدند که به‌طور تصادفی ۵۰۰۰

جدول ۱. اطلاعات استخراج شده از پیکسل‌های نمونه‌برداری شده

ردیف	نام ستون	محتوی اطلاعاتی	واحد
۱	p1	بازتابندگی باند ۱	درصد
۲	p2	بازتابندگی باند ۲	درصد
۳	p3	بازتابندگی باند ۳	درصد
۴	T4	دمای درخشندگی باند ۴	درجه کلوین
۵	T5	دمای درخشندگی باند ۵	درجه کلوین
۶	(p2/p1)	نسبت بازتابندگی باند ۲ به بازتابندگی باند ۱	بدون بعد
۷	T4-T5	اختلاف دمای درخشندگی باند ۵ از دمای درخشندگی باند ۴	درجه کلوین
۸	NDVI	نمایه پوشش گیاهی نرمال شده	بدون بعد
۹	Class	ابر، صاف، آب و برف	بدون بعد

۳- بحث و نتایج

اشتباه در پیش‌بینی از ۲۰۰۰۰ نمونه پیکسل برای چهار کلاس ابر، برف، صاف و آب (۵۰۰۰ نمونه از هر کلاس) محاسبه شد (جدول ۴).

ماتریس تطابق که نشان‌دهنده تعداد درستی و اشتباه در طبقه‌بندی پیکسل‌هاست تشکیل گردید (جدول ۲ و ۳)، و براساس نتایج آن، تعداد کل و درصد درستی و

جدول ۲. ماتریس تطابق نتایج طبقه‌بندی پیکسل‌های صاف، ابر، برف و آب در مدل‌های طبقه‌بندی‌کننده شبکه عصبی از ۲۰۰۰۰ نمونه پیکسل

مدل شبکه عصبی	شرایط	پیش‌بینی شده		
		صاف	برف	آب
QUICK	صاف	۴۹۱۵	۳	۷۷
	برف	۷	۴۸۹۵	۹۸
	آب	۰	۱	۴۹۹۹
	ابر	۱۴۲	۲۱	۴۸۲۶
MULTIPLE	صاف	۴۹۶۳	۰	۳۳
	برف	۳	۴۹۷۶	۲۱
	آب	۲	۰	۴۹۹۷
	ابر	۸۶	۲۱	۴۸۹۳
PRUNE	صاف	۴۹۶۰	۰	۳۵
	برف	۷	۴۹۸۱	۱۲
	آب	۰	۰	۴۹۹۹
	ابر	۶۶	۸	۴۹۲۳
EXHAUSTIVE PRUNE	صاف	۴۹۸۲	۰	۱۴
	برف	۱	۴۹۸۳	۱۶
	آب	۱	۰	۴۹۹۹
	ابر	۱۰۶	۵	۴۸۱۷
RBFN	صاف	۴۶۹۴	۳	۲۷۹
	برف	۵۸	۴۷۲۲	۲۲۰
	آب	۱۰	۱۹	۴۹۷۱
	ابر	۱۶۱	۱۰۰	۴۷۳۷
DYNAMIC	صاف	۴۹۱۸	۰	۷۸
	برف	۷	۴۹۱۸	۷۲
	آب	۶	۰	۴۹۸۷
	ابر	۱۸۵	۳۸	۴۷۷۳

خلیل قربانی و همکاران

جدول ۳. ماتریس تطابق نتایج طبقه‌بندی پیکسل‌های صاف، ابر، برف و آب در مدل‌های طبقه‌بندی‌کننده درخت تصمیم از ۲۰۰۰۰ نمونه پیکسل

مدل درخت تصمیم	شرایط	پیش‌بینی شده		
		صاف	برف	آب
C5	صاف	۴۹۶۶	۰	۵
	برف	۳	۴۹۹۱	۰
	آب	۱	۰	۴۹۹۸
CHAID	ابر	۳۹	۱	۳
	صاف	۴۷۱۹	۰	۶
	برف	۱۸	۴۶۷۴	۰
	آب	۰	۰	۴۹۹۶
	ابر	۲۹۲	۴۶	۷
	صاف	۴۷۱۹	۰	۶
EXHUSTIVE CHAID	برف	۱۸	۴۶۷۴	۰
	آب	۰	۰	۴۹۹۶
	ابر	۲۹۲	۴۶	۷
QUESRT	صاف	۴۸۱۴	۰	۱۰
	برف	۰	۴۵۴۵	۵۹
	آب	۲	۰	۴۹۹۰
	ابر	۳۲۵	۶۷	۱۰۹
C&R Tree	صاف	۴۸۱۷	۱۶	۹
	برف	۰	۴۹۵۶	۰
	آب	۰	۱۶	۴۹۸۴
	ابر	۳۸۹	۱۹۳	۱۵

جدول ۴. نتایج پیش‌بینی مدل‌های طبقه‌بندی در بین ۲۰,۰۰۰ نمونه پیکسل

نام مدل	صحت		اشتباه	
	تعداد	درصد	تعداد	درصد
QUICK	۱۹۶۳۵	۹۸/۱۸	۳۶۵	۱/۸۲
MULTIPLE	۱۹۸۲۹	۹۹/۱۵	۱۷۱	۰/۸۶
PRUNE	۱۹۸۶۳	۹۹/۳۲	۱۳۷	۰/۶۸
EXHAUSTIVE PRUNE	۱۹۸۵۱	۹۹/۲۶	۱۴۹	۰/۷۴
RBFN	۱۹۱۲۴	۹۵/۶۲	۸۷۶	۴/۳۸
DYNAMIC	۱۹۵۹۶	۹۷/۹۸	۴۰۴	۲/۰۲
C5	۱۹۹۱۲	۹۹/۵۶	۸۸	۰/۴۴
CHAID	۱۹۰۱۷	۹۵/۰۸	۹۸۳	۴/۹۲
EXHUSTIVE CHAID	۱۹۰۱۷	۹۵/۰۸	۹۸۳	۴/۹۲
QUES	۱۸۸۴۸	۹۴/۲۴	۱۱۵۲	۵/۷۶
C&R Tree	۱۹۲۲۰	۹۶/۱	۷۸۰	۳/۹۰

الگوریتم‌های درخت تصمیم داشته است. بخشی از نحوه تصمیم‌گیری و آستانه‌های در نظر گرفته درخت تصمیم C5 برای طبقه‌بندی چهار کلاس صاف (کلاس ۱)، برف (کلاس ۲)، آب (کلاس ۳) و ابری (کلاس ۴) بدین صورت است:

در الگوریتم درخت تصمیم برآزش داده شده C5، اولین آزمون با در نظر گرفتن آستانه ۱۰/۴۶ برای باند دو آغاز می‌گردد و در صورتی که مقدار ارزش این باند کمتر از ۱۰/۴۶ باشد آزمون‌هایی بدین شکل دنبال می‌شود:

$p2 \leq 10.460$
 $(p2/p1) \leq 0.866 \rightarrow \text{Class}(3)$
 $(p2/p1) > 0.866$
 $T5 \leq 291.270 \rightarrow \text{Class}(3)$
 $T5 > 291.270$
 $(p2/p1) \leq 1.036 \rightarrow \text{Class}(4)$
 $(p2/p1) > 1.036 \rightarrow \text{Class}(1)$

در غیر این صورت اگر درصد بازتابندگی باند دو بیشتر از ۱۰/۴۶ باشد، دوباره آزمون‌های دیگری صورت می‌گیرد تا عمل طبقه‌بندی و تشخیص پیکسل‌ها صورت گیرد.

براساس نتایج ارائه شده در جدول‌های ۲ و ۳ و ۴، مشخص می‌شود که از مدل شبکه عصبی الگوریتم‌های MULTIPLE, EXHAUSTIVE PRUNE, PRUNE با دقتی بیش از ۹۹ درصد، نمونه‌ها را درست پیش‌بینی کردند که از این میان الگوریتم EXHAUSTIVE PRUNE با ۱۸ خطا از ۵۰۰۰ نمونه بالاترین دقت را در پیش‌بینی و تشخیص پیکسل‌های صاف و الگوریتم PRUNE با ۷۷ خطا از ۵۰۰۰ نمونه در پیش‌بینی و تشخیص پیکسل‌های ابری دارای کمترین مقدار خطا هستند، ولی در مجموع الگوریتم PRUNE در طبقه‌بندی داده‌ها به چهار کلاس آب، برف، صاف و ابر با ۱۳۷ خطا در بین ۲۰,۰۰۰ نمونه بالاترین دقت طبقه‌بندی را دارد.

در بین الگوریتم‌های درخت تصمیم، الگوریتم C5 با دقتی بیش از ۹۹ درصد، نمونه‌ها را درست پیش‌بینی کرد. این الگوریتم در پیش‌بینی شرایط صاف ۳۴ مورد خطا از ۵۰۰۰ نمونه صاف و در پیش‌بینی شرایط ابری ۴۳ مورد خطا در بین ۵۰۰۰ نمونه ابری در پیش‌بینی داشته است که در بین دیگر الگوریتم‌های درخت تصمیم کمترین مقدار خطا را داشته است. در مجموع الگوریتم C5 با درختی به عمق ۲۴ و ۸۸ مورد خطا از ۲۰,۰۰۰ نمونه، بالاترین دقت پیش‌بینی را در

جدول ۵. مشخصات الگوریتم‌ها و زمان لازم برای اجرای هر یک از آنها

زمان اجرا (ثانیه)	تعداد نرون				الگوریتم
	لایه ورودی	لایه مخفی یک	لایه مخفی دو	لایه خروجی	
۵۰۰۵	۸	۱۰	۷	۳	Dynamic
۳۰۰۰	۸	۲۶	۱۶	۳	Exhaustive Prune
۳۰۰۰	۸	۲۰	-	۳	RBFN
۳۰۰۰	۸	۱۰	-	۳	Prune
۳۰۰۰	۸	۳	-	۳	Quick
۲۷۰۰	۸	۱۹	۱۷	۳	Multiple
۳۰	-	-	-	۲۴	C5
۲۸	-	-	-	۶	C&R Tree
۲۸	-	-	-	۳	EXHAUSTIVE CHAID
۲۵	-	-	-	۷	QUEST
۲۲	-	-	-	۴	CHAID

- در مجموع بین تمام الگوریتم‌های مورد ارزیابی، کمترین خطا مربوط به طبقه‌بندی پیکسل‌های آب و برف بود که این می‌تواند به دلیل یکنواخت بودن سطح نمونه‌برداری و کاهش خطا در نمونه‌برداری این دسته پیکسل‌ها باشد.
- دقت نتایج حاصل از این تحقیق که به انتخاب و معرفی نمونه‌های اولیه بستگی دارد، روش نمونه‌برداری به‌کار گرفته شده را تأیید می‌کند.

۴- نتیجه‌گیری

برای معرفی بهترین الگوریتم در بین الگوریتم‌های ذکر شده، دقت طبقه‌بندی در اولویت است؛ اما با افزایش حجم نمونه‌های آموزشی، زمان آموزش الگوریتم‌ها نیز دارای اهمیت خاصی است. الگوریتم‌های درخت تصمیم در مقایسه با الگوریتم‌های شبکه عصبی با سرعت بالاتری اجرا شدند که این می‌تواند در شرایط برابر، مزیتی برای الگوریتم‌های درخت تصمیم باشد. نوع تصمیمات گرفته شده برای طبقه‌بندی در الگوریتم‌های درخت، تصمیمی است مشخص و شفاف و قابل استخراج. لیکن در شبکه عصبی که در اصطلاح به آنها مدل‌های جعبه سیاه گفته می‌شود، چنین امکانی وجود ندارد.

با توجه به نتایج ماتریس تطابق (جدول ۲ و ۳)، از بین الگوریتم‌های درخت تصمیم، مدل C5 و از بین الگوریتم‌های شبکه عصبی، مدل‌های MULTIPLE، PRUNE و EXHAUSTIVE PRUNE با دقتی بیش از ۹۹ درصد پیکسل‌های ابر، برف، آب و صاف را درست شناسایی و طبقه‌بندی کردند. بالاترین دقت پیش‌بینی مربوط به الگوریتم C5 است که با توجه به دیگر مزایای ذکر شده مناسب‌ترین الگوریتم برای طبقه‌بندی و شناخت پیکسل‌های ابری از پیکسل‌های بدون ابر معرفی می‌گردد.

با افزایش حجم داده‌های آموزشی، زمان لازم برای آموزش مدل‌ها نیز اهمیت خاصی دارد. بدین منظور جدولی تشکیل شد (جدول ۵) و نتایج مربوط به زمان لازم برای آموزش هر یک از این الگوریتم‌ها مورد مقایسه قرار گرفت. به طوری که نتایج مشخص می‌کند این زمان برای مدل‌های درخت تصمیم خیلی کمتر از مدل‌های شبکه عصبی است، که این خود می‌تواند از جمله مزایای استفاده از مدل‌های درخت تصمیم باشد.

نتایجی که از این تحقیق به دست آمد، عبارت‌اند از:

- در پیش‌بینی و طبقه‌بندی پیکسل‌های برفی، بیشترین خطا همانا اشتباه فرض کردن پیکسل ابر به جای برف بود و الگوریتم درخت تصمیم C5 با تعداد شش خطا در این مورد بهترین دقت طبقه‌بندی را دارد.
- در پیش‌بینی و طبقه‌بندی پیکسل‌های ابری، بیشترین خطا در واقع اشتباه فرض کردن پیکسل صاف و برف به جای ابر بود و الگوریتم درخت تصمیم C5 با تعداد ۳۹ خطا در این مورد بهترین دقت طبقه‌بندی را دارد. این الگوریتم هیچ پیکسل ابری را به اشتباه برف پیش‌بینی نکرد و در سه مورد پیکسل ابری را به اشتباه پیکسل آب پیش‌بینی کرد.
- در پیش‌بینی و طبقه‌بندی پیکسل‌های صاف، بیشترین خطا همانا اشتباه فرض کردن پیکسل ابر به جای پیکسل صاف بود. در این مورد الگوریتم شبکه عصبی EXHAUSTIVE PRUNE با تعداد ۱۴ خطا و بعد از آن الگوریتم، درخت تصمیم C5 با ۲۹ خطا بهترین دقت طبقه‌بندی را دارند.
- در پیش‌بینی و طبقه‌بندی پیکسل‌های آب، الگوریتم درخت تصمیم در یک مورد به اشتباه پیکسل آبی را پیکسل ابر، و در مورد دیگری پیکسل صاف طبقه‌بندی کرده است که در بین دیگر الگوریتم‌ها بهترین دقت طبقه‌بندی را دارد.

۵- منابع

- Baglio, J.V., and Holroyd, E.W., 1989, **Methods for Operational Snow Cover area Mapping using the Advanced Very High Resolution Radiometer: San Juan Mountains Test Study**, Research Technical Report, U.S. Geological Survey, Sioux Falls and U.S. Bureau of Reclamation, Denver.
- Biggs, D., B. de Ville, and E. Suen., 1991, **A Method of Choosing Multiway Partitions for Classification and Decision Trees**, Journal of Applied Statistics, V. 18, P. 49-62.
- Breiman, L., Freidman, J.H., Olshen, R.A. and Stone C.J., 1984, **Classification and Regression Trees**, Chapman and Hall/CRC, New York, P. 358.
- Brumby, S.P., Hirsch K.L., Davis A.B., Harvey N.R., and Rohde, C.A., 2001, **Genetic Refinement of Cloud-masking Algorithms for the Multi-spectral Thermal Imager (MTI)**, In Proceedings of the IEEE International Geosciences and Remote Sensing Symposium, Sydney, Australia, July 9-13, P. 1152-1154.
- Clementine® 12.0 Algorithms Guide, 2007, P. 291.
- Dayhoff, J.E., 1990, **Neural Network Principles**, Prentice-Hall International, U.S.A
- Dech, S.W., Tungalagsaikhan, P., Preusser, C., and Meisner, R.E., 1998, **Operational Value Adding to AVHRR data over Europe**, Methods, result, and prospect: Aerospace Science and Technology, V. 5, P. 335-346.
- Dozier, J., 1989., **Remote Sensing of Snow in Visible and Near-infrared Wavelengths**, Theory and Applications of Optical Remote Sensing, G. Asrar, ed., John Wiley and Sons, New York.
- Engman, E. T. and Gurney, R. J. 1991, **Remote Sensing in Hydrology**, Chapman and Hall, London, P. 223.
- Gutman , G. G., 1992, **Satellite Daytime Image Classification for Global Studies of Earth's Surface Parameters from Polar Orbits**, International Journal of Remote Sensing, V. 13, P. 209-234.
- Hansen, M., Dubayah, R., and DeFries, R., 1996, **Classification Trees: an Alternative to Traditional land Cover Classifiers**, International Journal of Remote Sensing, V. 17, P. 1075-1081.
- Hutchison, K. D., Etherton, B. J., and Topping, P. C., 1997, **Cloud Top Phase Determination from the Fusion of Signatures in Daytime AVHRR Imagery and HIRS Data**, International Journal of Remote Sensing, V. 28, P. 3245-3262.
- Jensen, J. R., 2007, **Remote Sensing of the Environment, An Earth Resource Perspective**, 2nd Ed., Upper Saddle River, NJ: Prentice Hall, P. 592.
- Kass, G., 1980, **An Exploratory Technique for Investigating Large Quantities of Categorical Data**, Applied Statistics, V. 29, P. 119-127.

- Loh, W. Y., and Shih Y. S., 1997, **Split Selection Methods for Classification trees**, *Statistica Sinica*, V. 7, P. 815-840.
- Pedersen, C. A., 2007, **Optical Properties of Snow and Sea Ice. Field Measurements, Parameterization Schemes and Validation**. Ph.D. Thesis, University of Tromsø, Faculty of Science, Department of Mathematics and Statistics. P. 150.
- Podgorelec, V., Kokol, P., Stiglic, B., and Rozman, I., 2002, **Decision Trees: an Overview and their Use in Medicine**, *Journal of Medical Systems* Kluwer Academic/Plenum Press, V. 26, P.445-463.
- Porhemmat, J., Saghafian, B. and Sedghi, H., 2002, **Snow, Cloud and Land Separation in NOAA AVHRR data**, *Journal of Pajouhesh and Sazandegi*, V.56, P.2-14.
- Promcharoen, S., Ranganseri, Y., Suwitongsomwang, S., Jarupatt, J., 1999, **Supervised Classification of Multispectral Satellite Images Using Fuzzy Logic and Neural Network**, In *Proceeding of the 20th Asian Conference on Remote Sensing*, November 22-25, Hong Kong, China.
- Quinlan, J. R., 1993, **C45: Programs for Machine Learning**, Morgan Kaufmann Publishers Inc, San Francisco, CA. P.302.
- Saunders, R.W., and Kriebel, K.T., 1998, **An Improved Method for Detecting Clear Sky and Cloudy Radiances from AVHRR Data**, *International Journal of Remote Sensing*, V. 9, P. 123-150.
- Shiffman, S., and Nemani, R., 2005, **Evaluation of Decision Trees for Cloud Detection from AVHRR Data**, *IEEE International Geoscience and Remote Sensing Symposium*, P. 5610–5613.
- Stowe, L., Davis, P.A., and McClain, E.P., 1999, **Scientific Basis and Initial Evaluation of the CLAVR-1 Global Clear/cloud Classification Algorithm for the Advanced Very high Resolution Radiometer**, *Journal of Atmospheric and Oceanic Technology*, V. 16(6), P. 656-681.
- Tian, B., Shaikh. M. A., Azimi-Sadjadi, M.R., Vonderhaar, T. H., and Reinke, D.L., 1999, **A Study of Cloud Classification with Neural Networks Using Spectral and Textural Features**, *IEEE TRANSACTIONS ON NEURAL NETWORKS*, V. 10, P. 138-151.
- Warren, S., 1982, **Optical Properties of Snow**, *Reviews of Geophysics and Space Physics*, 20, 67.
- Yamanouchi, T., and Kawaguchi, S., 1992, **Cloud Distribution in the Antractic from AVHRR data and Radiation Measurements at the Surface**, *International Journal of Remote Sensing*, V. 13, P. 111-127.