

ارزیابی کارایی الگوریتم‌های ماشین بردار پشتیبان جهت طبقه‌بندی کاربری اراضی با استفاده از داده‌های ماهواره‌ای ETM⁺ لندست (مطالعه موردی: حوزه سد ایلام)

صالح آرخ‌ی^{۱*} و مصطفی ادیب نژاد^۲

*- نویسنده مسئول، استادیار، گروه منابع طبیعی، دانشکده کشاورزی، دانشگاه ایلام

پست الکترونیک: saleh148@yahoo.com

۲- کارشناس جنگل‌داری، دانشکده کشاورزی گنبد، دانشگاه علوم کشاورزی و منابع طبیعی گرگان

تاریخ پذیرش: ۸۹/۰۶/۰۴

تاریخ دریافت: ۸۸/۰۹/۱۶

چکیده

طبقه‌بندی کاربری اراضی با استفاده از تصاویر سنجنش از دور یکی از مهمترین کاربردهای سنجنش از دور است و بسیاری از الگوریتم‌ها برای این منظور توسعه یافته‌اند. این مطالعه کارایی الگوریتم‌های ماشین بردار پشتیبان (SVMs) را در طبقه‌بندی تصاویر ماهواره‌ای مورد بررسی قرار می‌دهد. ماشین‌های بردار پشتیبان یک گروه از الگوریتم‌های طبقه‌بندی نظارت شده یادگیری ماشینی هستند که در زمینه سنجنش از دور مورد استفاده قرار گرفته‌اند. دقت طبقه‌بندی حاصل از SVMs با توجه به نوع تابع کرنل متغیر است. در این مطالعه، الگوریتم‌های SVM برای طبقه‌بندی کاربری اراضی حوزه سد ایلام با استفاده از داده‌های ETM⁺ لندست مورد استفاده قرار گرفته است. طبقه‌بندی با استفاده از روش ماشین‌های بردار پشتیبان، بصورت خودکار و با استفاده از چهار نوع کرنل خطی^۱، چندجمله‌ای^۲، شعاعی^۳ و حلقوی^۴ اجرا شده است. در ضمن، کارکرد این روش با روش طبقه‌بندی حداکثر احتمال مقایسه شده است. نتایج نشان می‌دهد که الگوریتم‌های SVM خصوصاً سه کرنل خطی، چندجمله‌ای و شعاعی نسبت به روش طبقه‌بندی حداکثر احتمال از نظر دقت کل (حدود ۱۰٪) و ضریب کاپا (حدود ۱۵٪) برتری دارد. بنابراین این مطالعه کارایی و قابلیت الگوریتم‌های SVM را در طبقه‌بندی تصاویر سنجنش از دور اثبات می‌نماید.

واژه‌های کلیدی: طبقه‌بندی نظارت شده، کاربری اراضی، روش حداکثر احتمال، ماشین‌های بردار پشتیبان، حوزه سد ایلام.

-
- 1- Support Vector Machines
 - 2 - Linear
 - 3 - Polynomial
 - 4 - Radial basis
 - 5 - Sigmoid

مقدمه

امروزه استفاده از داده‌های سنجش از دور به‌عنوان راهکاری مناسب در تهیه نقشه‌های کاربری اراضی مطرح است. این داده‌ها به دلیل ارائه اطلاعات به‌هنگام، تنوع اشکال، رقومی بودن و امکان پردازش رقومی در تهیه نقشه‌های کاربری اراضی از اهمیت بالایی برخوردارند. از این‌رو از این داده‌ها در گوشه و کنار جهان برای تهیه نقشه‌های کاربری اراضی استفاده می‌شود. یکی از روشهای پرکاربرد استخراج اطلاعات از تصاویر سنجش از دور طبقه‌بندی می‌باشد که به کاربران امکان تولید انواع اطلاعات مانند نقشه‌های پوشش گیاهی، کاربری اراضی و... را می‌دهد. از آنجا که هدف اصلی از پردازش تصاویر ماهواره‌ای، تهیه نقشه‌های موضوعی و کارآمد می‌باشد، انتخاب الگوریتم مناسب طبقه‌بندی نقش زیادی در این امر ایفا می‌کند. انواع مختلف روشهای طبقه‌بندی در حال حاضر وجود دارند. به‌طوری‌که روشهای معمول طبقه‌بندی از تکنیکهای آماری به روش پارامتریک استفاده می‌نمایند که شامل روشهای طبقه‌بندی حداکثر احتمال، حداقل فاصله و... می‌باشند. روشهای طبقه‌بندی آماری بستگی به مدل داده‌ها (مثل توزیع نرمال) دارند، بنابراین کارآمدی این روشها بستگی به میزان تطبیق داده‌ها با این مدل‌ها دارند. اگر توزیع داده‌های ورودی تقریباً نرمال باشد، کارایی این روشهای طبقه‌بندی آماری می‌تواند خوب باشد. به‌رغم محدودیتهای این روش که ناشی از فرض توزیع نرمال کلاسیک است (Swain & Davis, 1978) شاید یکی از پرکاربردترین روشهای طبقه‌بندی باشد (Hansen et al., 1996; Wang, 1990).

روشهایی از قبیل شبکه‌های عصبی مصنوعی و طبقه‌بندی درختی با استفاده از رویکرد غیرپارامتریکی

برخی از مشکلات روش طبقه‌بندی حداکثر احتمال (MLC) را بر طرف می‌نماید. اگرچه روشهای شبکه عصبی مصنوعی ممکن است با دقت بالا جهت طبقه‌بندی تصاویر ماهواره‌ای مورد استفاده قرار گیرد، اما تعدادی از مطالعات نشان داده‌اند که استفاده کنندگان از روشهای طبقه‌بندی عصبی مشکلاتی در زمینه انتخاب عامل‌های گوناگون در طول اجرای یادگیری دارند (Wilkinson, 1997). انتخاب معماری شبکه، اندازه نمونه برای آموزش، یادگیری الگوریتم‌ها و تعداد تکرارهای موردنیاز برای آموزش برخی از مشکلات این روش می‌باشند (Vapnik, 1995).

به‌طور کلی در چند سال اخیر یک تکنیک جدید براساس تئوری یادگیری آماری با نام ماشینهای بردار پشتیبان جهت طبقه‌بندی داده‌های سنجش از دور مورد استفاده واقع شده است (Dixon & Candade, 2008; Yao et al., 2008). در اصل، روشهای SVM برای تشخیص متون موجود در تصاویر (تبدیل اسناد موجود به متن کامپیوتری)، تشخیص رقومی دست‌نوشته و شناسایی صورت به کار برده شده است (Vapnik, 1995; Joachims, 1998a, b). نتیجه این آزمایشها این شد که الگوریتم‌های SVM با بهترین روشهای طبقه‌بندی موجود مانند شبکه‌های عصبی، طبقه‌بندی درختی و... می‌تواند رقابت کند. عملکرد فوق‌العاده روشهای SVM همچنین در طبقه‌بندی تصاویر ابر طیفی کسب شده از اسپکترومتر تصویربرداری مرئی/مادون قرمز (AVIRIS) نیز به اثبات رسیده است (Gualtieri & Cromp, 1998). در حالی که صدها متغیر به‌عنوان ورودی در آزمایشهای ذکر شده بالا استفاده شده، اما در داده‌های کسب شده از سنجنده‌های از قبیل لندست، AVHRR و MODIS متغیرهای کمتری وجود دارد. چون این سیستم‌های سنجنده معمول‌ترین

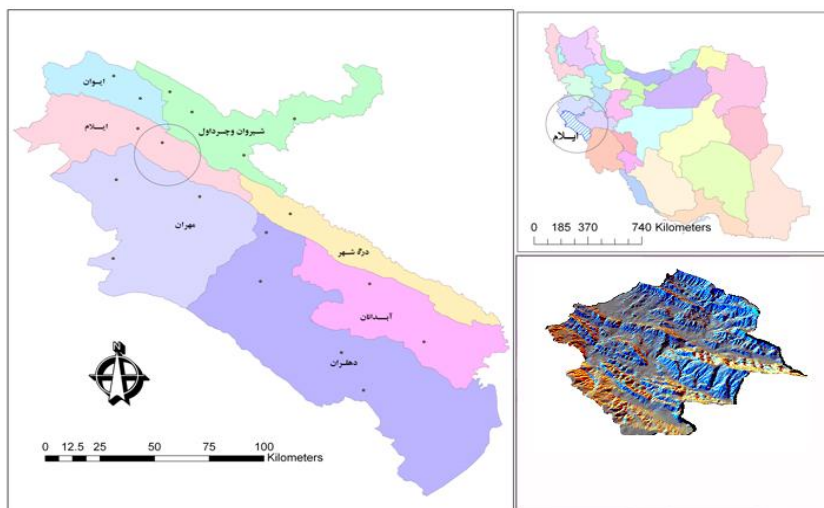
مواد و روشها

ویژگیهای منطقه مورد مطالعه

منطقه مورد مطالعه در این پژوهش، یک حوزه کوهستانی به نام حوزه سد ایلام، واقع در جنوب شرقی استان ایلام است. مساحت این حوزه ۴۷۶۷۵ هکتار می‌باشد که از لحاظ موقعیت جغرافیایی، بین طول‌های شمالی $32^{\circ} 23' 33''$ تا $33^{\circ} 01' 51''$ و عرض‌های شرقی $46^{\circ} 20' 30''$ تا $46^{\circ} 39' 33''$ واقع شده است (شکل ۱). نقاط ارتفاعی منطقه حداکثر ۲۱۷۷ متر و حداقل ۹۴۰ متر بالاتر از سطح دریا می‌باشد. از لحاظ شرایط اقلیمی، این منطقه جزو مناطق نیمه‌خشک (اقلیم مدیترانه‌ای) با متوسط بارندگی ۵۹۲/۷۸ میلی‌متر در سال می‌باشد.

ابزارهای مورد استفاده در کسب اطلاعات پوشش زمینی می‌باشند، بنابراین بررسی عملکرد الگوریتم‌های SVM با استفاده از تصاویر حاصل از این قبیل سیستم‌های سنجنده می‌تواند کاربردهای عملی را جهت طبقه‌بندی پوشش‌های زمینی داشته باشد.

در این مطالعه، ماشینهای بردار پشتیبان (SVMs) برای طبقه‌بندی کاربری اراضی حوزه سد ایلام و با استفاده از تصویر ماهواره‌ای ETM^+ لندست کسب شده در سال ۲۰۰۲ مورد استفاده قرار گرفته است. چهار نوع کرنل (خطی، چندجمله‌ای، شعاعی و حلقوی) برای فرایند طبقه‌بندی SVM بکار برده شده و کارآمدی طبقه‌بندی این کرنل‌ها آنالیز شده است. همچنین کارآمدی روشهای ماشین‌های بردار پشتیبان و حداکثر احتمال با هم مقایسه و بصورت آماری آنالیز گردیده است.



شکل ۱- موقعیت کشوری و استانی منطقه مورد مطالعه

۲۰۰۲ منطقه (با ۳۱۸۶ ستون و ۲۶۸۶ ردیف) برای تعیین کاربری اراضی مورد استفاده قرار گرفت. این تصویر با استفاده از بسته نرم‌افزاری ENVI4.4 و بکار بردن تبدیل چندجمله‌ای، سیستم تصویر UTM گرفت. مختصات نقاط کنترل زمینی از

روش تحقیق

تصحیح هندسی

در این تحقیق، داده ماهواره‌ای ETM^+ لندست ۷ با شماره گذر ۱۶۷ و ردیف ۳۷ مربوط به ۲۰ آوریل (۳۱ فروردین)

الگوریتم طبقه‌بندی حداکثر احتمال

در این الگوریتم، کلاسی به پیکسل نسبت داده می‌شود که بزرگترین احتمال تعلق پیکسل به آن کلاس را دارا باشد. معمولاً فرض می‌شود که توزیع احتمال برای هر کلاس بصورت توزیع نرمال چندبعدی است که از قانون توزیع گوسین تبعیت می‌کند. در این روش احتمال یافتن پیکسل متعلق به یک کلاس داده شده w_i در موقعیت x از فضای چند طیفی بوسیله تابع زیر انتخاب می‌شود.

$$\max_{\lambda_1, \dots, \lambda_L} \left[-\frac{1}{2} \sum_{i=1}^L \sum_{j=1}^L \lambda_i y_i (x_i, x_j) y_j \lambda_j + \sum_{i=1}^L \lambda_i \right] \quad (1)$$

(Burges, 1998; Osuna *et al.*, 1997). در سال ۱۹۶۵ محقق روسی به نام ولادیمیر وپینگ گامی بسیار مؤثر در طراحی طبقه‌بندی‌کننده‌ها برداشت. وی نظریه آماری یادگیری را به صورت مستحکم‌تری بنا نهاد و ماشین‌های بردار پشتیبان را بر این اساس ارائه داد.

ماشین بردار پشتیبان یا SVM در واقع یک طبقه‌کننده دودویی است. در مورد دو کلاس، روش SVM سعی دارد یک ابر صفحه ایجاد نماید که فاصله هر کلاس را تا فراصفحه حداکثر می‌نماید. داده‌های نقطه‌ای که به فراصفحه نزدیک‌ترند، برای اندازه‌گیری این فاصله بکار می‌روند. از این رو، این داده‌های نقطه‌ای، بردارهای پشتیبان نام دارند (Vipnik, 1995). در شکل ۱ دو کلاس و بردارهای پشتیبان مربوط به آنها نشان داده شده است. فرض کنید داده‌ها از دو کلاس تشکیل شده و کلاس‌ها در

مجموع دارای $x_i, i=1, \dots, L$ نقطه آموزشی باشند که x_i یک بردار است. این دو کلاس با $y_i = \pm 1$ برچسب زده می‌شوند. برای محاسبه مرز تصمیم‌گیری دو کلاس کاملاً

روی نقشه توپوگرافی ۱:۵۰۰۰۰، عکس‌های هوایی ۱:۲۰۰۰۰ و نقاط مرجع زمینی با استفاده از GPS بدست آمدند. این تصویر با توزیع مناسب نقاط کنترلی و میزان خطای ریشه میانگین مربعات (RMSE) حدود ۰/۵ پیکسل ثبت شد. در پایان، روش نمونه‌گیری مجدد نزدیک‌ترین همسایه برای تعیین مقادیر جدید پیکسل بکاررفت و بالاخره دو الگوریتم روش حداکثر احتمال و ماشین‌های بردار پشتیبان برای طبقه‌بندی داده‌های ماهواره‌ای ETM^+ لندست مورد استفاده قرار گرفت.

که $i=1,2,3,\dots$ کلاس‌های پوشش زمین، m_i : بردار متوسط داده در کلاس w_i و \sum ماتریس کواریانس برای هر کلاس است. در عمل، توزیع نرمال چند بعدی بطور کامل بوسیله بردار میانگین و ماتریس کواریانس آن مشخص می‌شود.

در تعیین کلاس یک پیکسل بوسیله بردار x از احتمال شرطی $P(w_i|x)$ استفاده می‌شود. با محاسبه $P(w_i|x)$ برای هر پیکسل در تمام کلاسها، و مشخص کردن بیشترین مقدار احتمال ثانویه برچسب پیکسل مشخص می‌شود. اجرای روش MLC شامل برآورد بردارهای میانگین کلاس و ماتریس‌های کواریانس با استفاده از الگوهای آزمایشی انتخاب شده از نمونه‌های مشخص هر کلاس خاص می‌باشد.


الگوریتم‌های ماشین بردار پشتیبان

ماشین بردار پشتیبان یک روش کلاسه بندی الگو است که اولین بار توسط وپینگ معرفی شد

(۱) تمام نمونه‌های کلاس +۱ در یک طرف مرز و تمام نمونه‌های کلاس -۱ در طرف دیگر مرز واقع شوند.
 (۲) مرز تصمیم‌گیری به گونه‌ای باشد که فاصله نزدیک‌ترین نمونه‌های آموزشی هر دو کلاس از یکدیگر در راستای عمود بر مرز تصمیم‌گیری تا جایی که ممکن است حداکثر شود.

جدا از هم، از روش حاشیه بهینه استفاده می‌شود (Vapnik & Chervonenkis., 1991). در این روش مرز خطی بین دو کلاس به گونه‌ای محاسبه می‌شود که:

$$\left[y_i \frac{(W \cdot X_i + b)}{|W|} \right]$$



شکل ۲- مرز خطی بهینه برای حالتی که دو کلاس کامل از یکدیگر جدا هستند

یک مرز تصمیم‌گیری خطی را در حالت کلی می‌توان به صورت زیر نوشت:

$$w \cdot x + b = 0 \quad (2)$$

ضرب یک ثابت در دو طرف (۲) باز هم تساوی برقرار خواهد بود، برای تعریف یکتای مقدار b و w شرایط زیر روی آنها اعمال می‌شود.

$$\text{اگر } X_i \text{ یک بردار پشتیبان باشد} \Rightarrow Y_i(W \cdot X_i + b) = 1$$

$$\text{اگر } X_i \text{ یک بردار پشتیبان نباشد} \Rightarrow Y_i(W \cdot X_i + b) = -1$$

محاسبه می‌شود. مرز تصمیم‌گیری بهینه، مرزی است که حداکثر حاشیه را داشته باشد. مرز تصمیم‌گیری بهینه با حل مسئله بهینه‌سازی زیر محاسبه می‌شود.

x یک نقطه روی مرز تصمیم‌گیری و W یک بردار n بعدی عمود بر مرز تصمیم‌گیری است. $b/\|W\|$ فاصله مبدأ تا مرز تصمیم‌گیری و $W \cdot X$ بیانگر ضرب داخلی دو بردار W و X است (Foody & Mathur, 2004). از آنجا که با

اولین مرحله برای محاسبه مرز تصمیم‌گیری بهینه، پیدا کردن نزدیک‌ترین نمونه‌های آموزشی دو کلاس است. در مرحله بعد فاصله آن نقاط از هم در راستای عمود بر مرزهایی که دو کلاس را به طور کامل جدا می‌کنند

(۳)

$$\max_{W, b} \min_{i=1, \dots, L} \left[y_i \frac{(W \cdot X_i + b)}{|W|} \right] \quad (4)$$

باتوجه به (۳) و انجام یک سری عملیات ریاضی، رابطه بالا به رابطه زیر تبدیل می‌شود

$$\min_{w, b} \frac{1}{2} |W|^2, y_i (W \cdot X_i + b) - 1 \geq 0 \quad i = 1, \dots, L \quad (5)$$

لاگرانژ این مسئله بهینه‌سازی را می‌توان به فرم زیر تبدیل کرد که λ_i ها ضرایب لاگرانژ می‌باشند.

حل کردن مسئله بهینه‌سازی (۵) کار مشکلی است. برای ساده‌تر کردن آن با استفاده از روش ضرایب نامعین

$$\max_{\lambda_1, \dots, \lambda_L} \left[-\frac{1}{2} \sum_{i=1}^L \sum_{j=1}^L \lambda_i y_i (X_i, X_j) y_j \lambda_j + \sum_{i=1}^L \lambda_i \right]$$

$$\lambda_i \geq 0 \quad i = 1, \dots, L$$

$$\sum_{i=1}^L \lambda_i y_i = 0 \quad (6)$$

پس از حل مسئله بهینه‌سازی بالا و یافتن ضرایب لاگرانژ، W با استفاده از رابطه زیر محاسبه می‌شود

$$W = \sum_{i=1}^L \lambda_i y_i X_i \quad (7)$$

طبقه‌بندی تصاویر با استفاده از ماشین بردار پشتیبان به تعداد محدودی نقطه آموزشی نیاز خواهد داشت. پس از یافتن w با استفاده از رابطه زیر مقدار b به‌ازای بردارهای پشتیبان مختلف محاسبه شده و b نهایی با میانگین‌گیری از b های حاصل بدست می‌آید.

λ_i بردارهای پشتیبان بزرگتر از صفر، و λ_i نقاط دیگر صفر خواهد بود. بنابراین با توجه به (۷) و صفر بودن λ_i مربوط به X_i هایی که بردار پشتیبان نیستند، برای بدست آوردن مرز تصمیم‌گیری فقط نیاز به تعدادی محدودی از نقاط آموزشی که همان بردارهای پشتیبان هستند می‌باشد و همه آنها لازم نیستند. در نتیجه

$$y_i (W \cdot X_i + b) - 1 = 0 \quad \lambda_i \quad (8)$$

طبقه‌بندی کننده‌های نهایی (۹) بدست می‌آید.

$$f(X, W, b) = \text{sgn}(W \cdot X + b) \quad (9)$$

کلاسها تداخل کمتری با یکدیگر داشته باشند (Mathur & Foody, 2008a). سپس در فضای جدید با استفاده از معادلات قبلی و جایگزینی X_i با $X_i(\phi)$ و در نظر گرفتن مقداری خطا مرز تصمیم‌گیری بهینه محاسبه می‌شود. با توجه به این امر و (۶) در این حالت یافتن مرز تصمیم‌گیری بهینه و حل مسئله بهینه‌سازی (۱۰) تبدیل می‌شود.

$$\max_{\lambda_1, \dots, \lambda_L} \left[-\frac{1}{2} \sum_{i=1}^L \sum_{j=1}^L \lambda_i \lambda_j Y_i Y_j (\phi(X_i) \phi(X_j)) + \sum_{i=1}^L \lambda_i \right]$$

$$C \geq \lambda_i \geq 0 \quad i=1, \dots, L \quad (10)$$

$$\sum_{i=1}^L \lambda_i Y_i = 0$$

یافتن مرز بهینه جدا کننده دو کلاس تداخل بسیار کمی دارند پیش خواهد رفت. در رابطه (۱۰) معمولاً به جای استفاده از ϕ ، از یک تابع کرنل که به صورت زیر تعریف می‌گردد استفاده می‌شود.

$$K(X_i, X_j) = \phi(X_i) \phi(X_j) \quad (11)$$

مقارن بوده و در شرط مرسر^۱ صدق کند (Vapnik & Chervonenkis, 1991). برخی از مهمترین توابع کرنل (هسته) که در این شرط صدق می‌کند، عبارتند از:

الگوریتم بالا مرز خطی دو کلاس کاملاً جدا از هم را نشان می‌دهد، اما در حالتی که کلاسها با هم همپوشانی داشته باشند جدا کردن کلاسها به وسیله مرز تصمیم‌گیری خطی همواره با خطا همراه خواهد بود. برای حل این مشکل می‌توان ابتدا داده‌ها را از فضای اولیه R^n با استفاده از یک تبدیل غیرخطی ϕ ، به فضای R^m با ابعاد بیشتر منتقل کرد که در فضای جدید

در این مسئله مقدار بهینه‌سازی C یک عدد ثابت است. اگر $C \rightarrow \infty$ ، مسئله بهینه‌سازی به سمت یافتن یک مرز برای کلاس‌های با تداخل بسیار زیادتر پیش می‌رود. از طرفی اگر $C \rightarrow 0$ ، مسئله بهینه‌سازی به سمت

پس از تعیین یک $K(X_i, X_j)$ مناسب در (۱۰) به جای $\phi(X_i) \phi(X_j)$ ، تابع $K(X_i, X_j)$ قرار داده شده و مسئله بهینه‌سازی حل می‌شود $K(X_i, X_j)$ در واقع یک تابع در فضای اولیه می‌باشد که برابر با ضرب داخلی دو بردار در فضای ویژگی است. برای معادل بودن تابع $K(X_i, X_j)$ با ضرب داخلی دو بردار در فضای ویژگی، باید $K(X_i, X_j)$ یک تابع معین و مثبت

$$K(x_i, x_j) = x_i \cdot x_j \quad \text{کرنل خطی}$$

$$K(X, Y) = (X \cdot Y + 1)^P \quad \text{کرنل جمله‌ای}$$

$$K(X, Y) = e^{-\frac{\|X - Y\|^2}{2\sigma^2}} \quad \text{کرنل پایه شعاعی}$$

$$K(X, Y) = \tanh(kx \cdot y - \delta) \quad \text{کرنل حلقوی}$$

روش متفاوت اجرا می‌شود (Goh et al., 2001). در مورد K تعداد کلاس، در روش اول که آن را روش یکی در مقابل بقیه^۴ می‌نامند (Knerr et al., 1990; Weston & Watkins, 1998). طبقه‌بندی‌کننده دودویی که هر کدام برای جدا کردن یک کلاس از بقیه کلاسها می‌باشد طراحی می‌شود. بنابراین در این حالت برای آموزش هر طبقه‌بندی‌کننده از تمام نقاط آموزشی k کلاس استفاده می‌گردد. هر داده آزمایشی با تمام k طبقه‌بندی‌کننده حاصل طبقه‌بندی می‌شود. در نهایت داده مورد نظر با شماره طبقه‌بندی‌کننده‌ای که دارای بیشترین مقدار $w \cdot x + b$ است برچسب زده خواهد شد. چون در این حالت از تمام نقاط آموزشی برای آموزش هر طبقه‌بندی‌کننده استفاده شده، بنابراین زمان آموزش هر طبقه‌بندی‌کننده در این حالت بسیار زیاد است و در عمل به‌ندرت از آن استفاده می‌شود (Huang et al., 2002).

روش دوم که آن را دسته‌بندی کردن زوج-زوج^۵ می‌نامند، $\binom{K}{2} = \frac{k(k-1)}{2}$ طبقه‌بندی‌کننده دودویی که در واقع برابر با تمامی جفت‌های مختلف k کلاس می‌باشد، طراحی می‌شود (Crammer & Singer, 2000). پس هر داده آزمایشی با تمام این طبقه‌بندی‌کننده‌ها طبقه‌بندی شده و در هر طبقه‌بندی به کلاس برنده یک رأی داده می‌شود. کلاسی که حداکثر آراء را آورده است به‌عنوان کلاس داده

توابع کرنل (هسته) مورد استفاده در ماشین‌های بردار پشتیبان معمولاً به چهار گروه تقسیم می‌شود. در این مطالعه نیز این چهار تابع برای طبقه‌بندی تصویر ETM+ لندست مورد استفاده قرار گرفته‌اند. به‌طوری‌که میزان کارایی ماشین‌های بردار پشتیبان با توجه به نوع تابع کرنل متفاوت می‌باشد. اینکه کدام تابع کرنل بهترین نتیجه را برای یک سری داده ارائه می‌دهد، به درستی معلوم نیست. بنابراین، باید بهترین تابع کرنل را تعیین نمود (Hsu et al., 2008).

در ضمن، در این مطالعه، مقادیر عامل جریمه^۱ و سطح هرم^۲ بصورت خودکار و براساس مقادیر قراردادی^۳ در نرم‌افزار به ترتیب ۱۰۰ و ۰ در نظر گرفته شد.

ماشین بردار پشتیبان برای طبقه‌بندی چند کلاس

ماشین بردار پشتیبان یک طبقه‌بندی‌کننده دودویی است. بنابراین در حالتی که بیش از دو کلاس وجود داشته باشد نمی‌توان مستقیماً از آن استفاده کرد. در حالت کلی برای استفاده از طبقه‌بندی‌کننده‌های دودویی در حالت چندکلاسه باید ابتدا چند طبقه‌بندی‌کننده دودویی طراحی شود. طبقه‌بندی‌نهایی با استفاده از ادغام اطلاعات طبقه‌بندی‌کننده‌های دودویی انجام می‌گردد. برای استفاده از ماشین بردار پشتیبان در حالت چندکلاسه این تکنیک کلی با دو

1 -Penalty Parameter

2 -Pyramid Level

3 -Default value

4-One-against-all

5 - One-against-one

آزمایشی در نظر گرفته خواهد شد. در این روش چون هر طبقه‌بندی با نقاط آموزشی کمتری آموزش داده می‌شود بنابراین زمان آموزش آن بسیار کمتر از حالت قبل است. روشهای یکی در مقابل بقیه و دسته‌بندی کردن زوج-زوج به نحوی سعی در استخراج اطلاعاتی از مرزهای بین کلاس‌ها دارند. در روش دسته‌بندی کردن زوج-زوج میزان اطلاعاتی که از مرز بین کلاس‌ها استخراج می‌شود بسیار بیشتر از اطلاعاتی است که با روش یکی در مقابل بقیه بدست می‌آید. بنابراین به نظر می‌رسد که استفاده از روش دسته‌بندی کردن زوج-زوج طبقه‌بندی بهتری را در اختیار ما قرار می‌دهد (Hsu & Lin, 2002). روش یکی در مقابل بقیه اگرچه مشکل الگوریتم ادغام نهایی را ندارد، اما از آنجا که برای آموزش هر یک از n ماشین بردار پشتیبان از نقاط آموزشی تمامی کلاسها استفاده می‌شود بسیار زمانبر خواهد بود، از طرفی صحت طبقه‌بندی این روش به دلیل کم بودن اطلاعاتی که از مرز بین کلاس‌ها در اختیار دارد، مطلوب نیست؛ بنابراین بنظر می‌رسد که استفاده از دسته‌بندی کردن زوج-زوج برای طبقه‌بندی تصاویر ماهواره‌ای مناسب‌تر از روش یکی در مقابل بقیه است. در این مطالعه نیز از روش طبقه‌بندی زوج-زوج استفاده شده است.

پس از آنکه داده‌ها مورد تصحیح هندسی قرار گرفتند، برای بهره‌مندی از توان اطلاعاتی داده‌ها، به کمک الگوریتم‌های طبقه‌بندی، قابلیت آنها برای تفکیک کلاس‌های موضوعی که در تحقیق مورد نظر هستند، مورد بررسی و آزمون قرار گرفتند. براساس تجربه و نتایج تحقیقات گذشته، باندهای مصنوعی نظیر مؤلفه‌های اصلی و نسبت‌گیریهایی مثل NDVI و RVI به همراه باندهای اصلی سنجنده TM+ (بجز باند ۶) می‌توانند برای تفکیک بهتر کلاس‌ها مورد استفاده قرار گیرند. ایجاد این باندها خود نوعی عملیات

طبقه‌بندی و تهیه نقشه پوشش زمینی

با هدف تفکیک پوشش‌های زمینی عمده منطقه بر روی داده‌های ماهواره‌ای، از روشهای طبقه‌بندی نظارت‌شده و دو الگوریتم ماشین بردار پشتیبان و حداکثر احتمال استفاده گردید. انتخاب نمونه‌های تعلیمی مورد نیاز برای طبقه‌بندی کلاس‌های مختلف در منطقه با شناخت از منطقه و با استفاده از اطلاعات جنبی و استفاده از تصویر رنگی مرکب ۴،۳،۲ (RGB) انجام شد. انتخاب این تصویر رنگی مرکب فقط جهت شناسایی کلاس‌های مورد نظر و انتخاب بهترین نمونه‌های تعلیمی بوده است. برای این منظور در منطقه مورد مطالعه به فراخور سهم هر طبقه تعداد مناسبی نمونه تعلیمی به طور تصادفی با استفاده از برسیهای میدانی، تصاویر گوگل ارث^۲ و تصاویر رنگی مرکب انتخاب گردیدند. برای بررسی تشابه طبقات و میزان تفکیک‌پذیری و تباین کلاس‌ها، از روش ارزیابی کمی تفکیک‌پذیری استفاده و تفکیک‌پذیری آنها با استفاده از شاخص فاصله جفریس ماتوسیتا^۳ بررسی شد. معادله شاخص فاصله جفریس ماتوسیتا به شرح زیر است:

1 - Digital Numbers
2 - Google Earth
3 - jefferies matusita

$$J_{ij} = \sqrt{1 - e^{-\alpha}} \quad (12)$$

که در این رابط

$$\alpha = \frac{1}{8}(m_i - m_j) \left(\frac{\sum_i + \sum_j}{2} \right)^{-1} (m_i - m_j) + \frac{1}{2} \ln \left(\frac{|\sum_i + \sum_j|/2}{|\sum_i|^{1/2} \times |\sum_j|^{1/2}} \right)$$

(al., 2004). از نظر تئوری احتمالات دقت کل نمی تواند معیار خوبی برای ارزیابی نتایج طبقه بندی باشد. زیرا در این شاخص نقش شانس قابل توجه است. دقت کلی از جمع عناصر قطر اصلی ماتریس خطا تقسیم بر تعداد کل پیکسل ها طبق رابطه زیر بدست می آید (علوی پناه، ۱۳۸۴).

$$OA = \frac{1}{N} \sum P_{ii} \quad (13)$$

در این رابطه

OA = دقت کلی

N = تعداد پیکسل های آزمایشی

$\sum P_{ii}$ = جمع عناصر قطر اصلی ماتریس خطا

به دلیل ایرادات وارده بر دقت کلی اغلب در کارهای اجرایی که مقایسه دقت طبقه بندی مدنظر است از شاخص کاپا استفاده می شود. چون شاخص کاپا پیکسل های نادرست طبقه بندی شده را مورد توجه قرار می دهد. شاخص کاپا از رابطه زیر محاسبه می شود (بنیاد و حاجی قادری، ۱۳۸۶):

$$Kappa = \frac{P_o - P_c}{1 - P_c} \times 100 \quad (14)$$

که در رابطه بالا

P_o = درستی مشاهده شده

P_c = توافق مورد انتظار

دقت تولیدکننده، احتمال اینکه یک پیکسل در تصویر کلاسه بندی شده، در همان کلاس در روی زمین قرار

و m_i و m_j به ترتیب بردارهای میانگین برای کلاس های i و j بوده و \sum_i و \sum_j ماتریس های کواریانس برای کلاس i و j هستند.

با هدف انتخاب بهترین مجموعه باندهای که تفکیک پذیری طبقات برای طبقه بندی در آنها بهتر صورت پذیرد از مشخصه های آماری نمونه های آموزشی استفاده گردید که مبتنی بر واگرایی بین نشانه های طیفی مربوط به طبقات بر پایه محاسبه میانگین و ماتریس واریانس- کوواریانس طبقات در نمونه های آموزشی انتخابی می باشند. پس از انتخاب بهترین ترکیبات باندهای عملیات طبقه بندی با استفاده از الگوریتم های ماشین بردار پشتیبان و روش حداکثر احتمال انجام شد. به منظور حذف پیکسل های منفرد و پراکنده در سطح تصویر طبقه بندی شده و همچنین بدست آوردن تصویر مطلوب و با وضوح بیشتر، از فیلتر پایین گذر نما در اندازه 3×3 پیکسل استفاده شد.

ارزیابی دقت طبقه بندی

برآورد دقت برای درک نتایج بدست آمده و به کار بردن این نتایج برای تصمیم گیری حائز اهمیت است. معمول ترین عامل های برآورد دقت شامل، دقت کل^۱، دقت تولیدکننده^۲، دقت کاربر^۳ و ضریب کاپا^۴ هستند (Lu et

-
- 1- Overall accuracy
 - 2- Producer's accuracy
 - 3- User's accuracy
 - 4- Kappa coefficient

نتایج

عمل تطابق هندسی با استفاده از ۲۸ نقطه کنترل زمینی و با پراکنش مناسب و استفاده از معادله درجه اول مقدار خطای ریشه میانگین مربعات (RMSE) معادل ۰/۵ پیکسل انجام شد.

در این تحقیق نتایج بررسی تفکیک‌پذیری طبقات و انتخاب مجموعه باندهای مناسب برای طبقه‌بندی تصویر و تهیه نقشه کاربری اراضی حوزه نشان داد که با وجود استفاده از مجموعه باندهای اصلی و باندهای مصنوعی حاصل از آنالیزهای مختلف (باندهای حاصل از نسبت‌گیریها و تجزیه مؤلفه‌های اصلی)، باندهای اصلی سنجنده ETM+ مناسبترین مجموعه باندهای برای تفکیک کلاسهای مورد نظر بوده‌اند. این امر نشان داد که باندهای پردازش شده تأثیری در تفکیک‌پذیری طبقات در این تحقیق نداشتند.

برای طبقه‌بندی تصویر ماهواره‌ای ETM+، کلاس‌های کاربری اراضی در شش گروه تحت عنوان کلاس اراضی کشاورزی، مرتع، جنگل، اراضی بایر، باغ و دریاچه تعیین و بعد نمونه‌های آموزشی از سطح منطقه با استفاده از تصاویر ماهواره‌ای گوگل ارث و بازدید میدانی جمع‌آوری شد. در مرحله بعد با استفاده از ویژگی‌های تصاویر، کلاسهای پوشش اراضی در محدوده مورد مطالعه وارد شد و تفکیک‌پذیری کلاس‌ها با استفاده از روش جفریس ماتوسیتا محاسبه شده و نتایج آن در جدول ۱ ارائه گردیده است.

نتایج بررسی تفکیک‌پذیری طبقات با معیار فاصله جفریس ماتوسیتا نشان داد که میزان تفکیک‌پذیری طبقات بجز طبقه زمین زراعی با مرتع که از تفکیک‌پذیری تقریباً کمی برخوردار بودند، با یکدیگر خوب بوده است. علت

بگیرد و دقت کاربر، احتمال اینکه یک کلاس مشخص در روی زمین در همان کلاس بر روی تصویر طبقه‌بندی شده قرار بگیرد، می‌باشد که از طریق روابط زیر محاسبه می‌شوند (بنیاد و حاجی‌قادری، ۱۳۸۶).

$$PA = \frac{ta}{ga} \times 100 \quad (15)$$

$$UA = \frac{ta}{n_1} \times 100 \quad (16)$$

که در روابط فوق

PA = درصد دقت کلاس a برای دقت تولیدکننده

ta = تعداد پیکسل‌های صحیح طبقه‌بندی شده به‌عنوان

کلاس a

ga = تعداد پیکسل‌های کلاس a در واقعیت زمینی

UA = درصد دقت کلاس a برای دقت کاربر

n_1 = تعداد پیکسل‌های کلاس a در نتیجه طبقه‌بندی

براساس دو دقت ذکر شده، دو خطای گماشته‌شده^۱ و

حذف‌شده^۲ به صورت زیر تعریف می‌شوند (فاطمی و

رضایی، ۱۳۸۴).

$$C_e = 1 - UA \quad (17)$$

$$O_e = 1 - PA \quad (18)$$

خطای گماشته‌شده (C_e) که براساس دقت کاربر

محاسبه می‌گردد، معادل آن درصد از پیکسل‌هایی است که

در واقع متعلق به کلاس مورد نظر نبوده، ولی

طبقه‌بندی‌کننده آنها را جزء آن کلاس خاص در نظر

گرفته است. خطای حذف‌شده (O_e) مربوط به آن درصد

از پیکسل‌هایی است که در واقعیت زمینی مربوط به

کلاس مورد نظر است ولی جزء کلاسهای دیگر طبقه‌بندی

شده‌اند.

عدم تفکیک مناسب این دو طبقه را می‌توان در وجود زمین‌های زراعی در منطقه و اراضی مشجر کشاورزی و تشابه طیفی آنها با اراضی مرتعی جستجو کرد.

بنابراین پس از مشخص نمودن میزان تفکیک‌پذیری کلاسها نسبت به طبقه‌بندی به دو روش طبقه‌بندی حداکثر احتمال و ماشین‌های بردار پشتیبان اقدام شد. بدین ترتیب نقشه‌های پوشش اراضی مربوط به سال ۲۰۰۲ بدست‌آمد (شکل ۳). در مرحله بعدی با انجام عملیات میدانی، استفاده از عکس‌های هوایی ۱:۲۰۰۰۰، تصاویر ماهواره‌ای گوگل ارث و نمونه‌برداری تصادفی از سطح منطقه مورد مطالعه، عامل‌های آماری ماتریس خطا (خطای گماشته شده و خطای حذف شده)، دقت تولیدکننده، دقت استفاده‌کننده، دقت کل و ضریب کاپا به شرح جدولهای ۲، ۳، ۴، ۵، ۶، ۷ و ۸ استخراج گردید.

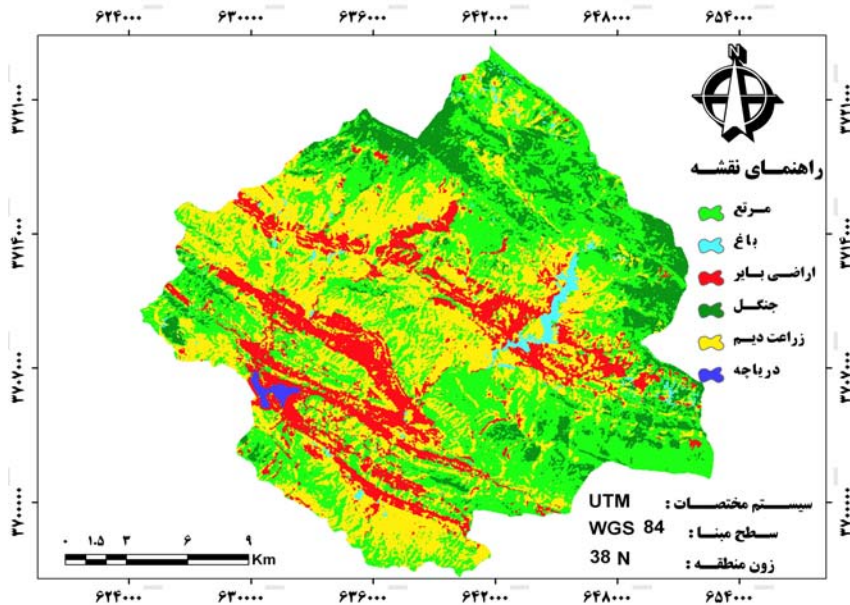
زمانیکه نتایج جدول ۷ آنالیز شد، چندین نتیجه مهم گرفته شد، نخست، مشاهده شد که کلاس آب با دقت تولیدکننده و استفاده‌کننده ۱۰۰٪ طبقه‌بندی شده است (روش حداکثر احتمال و چهار کرنل ماشین بردار پشتیبان). این نشان‌دهنده قابلیت تفکیک طیفی بالا برای این کلاس است. درثانی، طبق نتایج مشاهده شد که پایین‌ترین دقت تولیدکننده در مورد کلاس زراعت دیم بوده است. این کلاس با دقت تولیدکننده ۳۲/۳۶٪ برای تصویر این منطقه طبقه‌بندی شده است (در حالت استفاده از روش حداکثر احتمال). در حالی که الگوریتم‌های روش طبقه‌بندی SVM با استفاده از هر چهار نوع کرنل دقت تولیدکننده بالایی را برای این کلاس نشان داد (۶۳ تا ۸۱٪). در ضمن مشاهده شد که پایین‌ترین دقت استفاده‌کننده در مورد کلاس مرتع بوده است. این کلاس با دقت استفاده‌کننده ۵۰/۲۰٪ برای تصویر این منطقه

طبقه‌بندی شده است (در حالت استفاده از روش حداکثر احتمال). آنالیز تفصیلی ماتریس‌های مجاور نشان می‌دهد که کلاس زراعت با کلاس مرتع آمیخته شده است. دلیل آن را می‌توان در وجود زمین‌های زراعی در منطقه و اراضی مشجر کشاورزی و تشابه طیفی آنها با اراضی مرتعی جستجو کرد. در ضمن هر دو کلاس ذکرشده در بالا در روش ماشین بردار پشتیبان با دقت استفاده‌کننده تقریباً ۹۱٪ طبقه‌بندی شده است و این نشان از توانایی بالای این الگوریتم طبقه‌بندی می‌باشد. ثالثاً روش SVM با تابع کرنل شعاعی، خطی و چندجمله‌ای برای تمام کلاس‌ها بجز زراعت دیم در مقایسه با تابع کرنل حلقوی با دقت تولیدکننده ۱۰۰٪ عملکرد طبقه‌بندی بهتری داشته است. بعلاوه اینکه کمترین دقت تولیدکننده در هر دو روش مربوط به کلاس زراعت دیم بوده است و دلیل این امر می‌تواند پیچیدگی یا نزدیکی مرزهای حاصل از مشابهت طیفی بالای آن با سایر کلاس‌ها باشد. براساس مطالب بالا، علت دقت بالای الگوریتم‌های SVM نسبت به روش حداکثر احتمال را می‌توان این طور بیان کرد که این روش از قوانین بهینه‌سازی جهت مکان‌یابی مرزهای بهینه بین کلاس‌های کاربری استفاده می‌کند، در نتیجه جایگزین مناسبی برای سایر الگوریتم‌های معمول طبقه‌بندی می‌باشد.

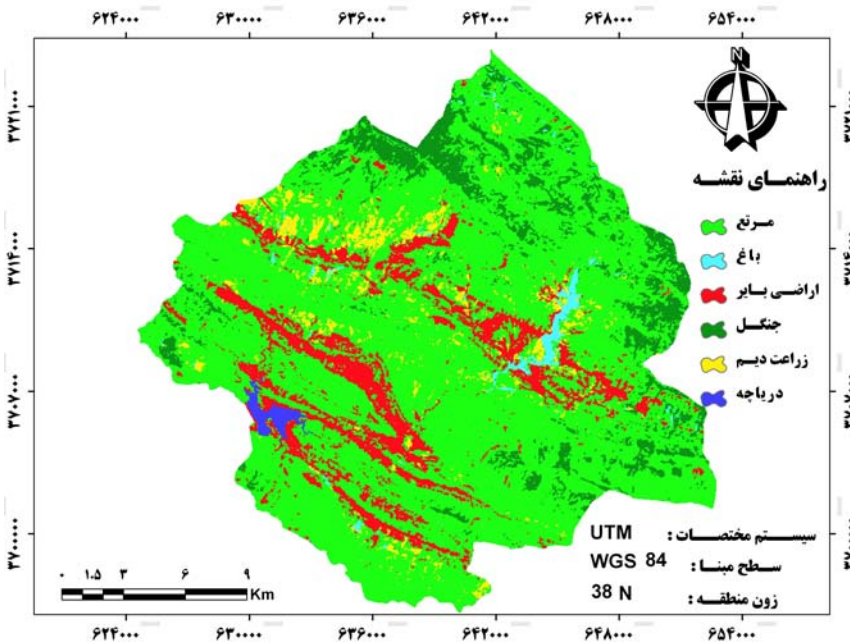
نتایج طبقه‌بندی با استفاده از چهار تابع کرنل روش ماشین بردار پشتیبان و روش حداکثر احتمال در جدول ۸ ارائه شده است. طبق جدول ۸ روش ماشین بردار پشتیبان با سه تابع کرنل خطی، چندجمله‌ای و شعاعی به ترتیب دقت کل ۹۵، ۹۵، ۹۵ و ضریب کاپای ۰/۹۴، ۰/۹۴ و ۰/۹۴ را ایجاد نمودند، در حالی که تابع کرنل حلقوی به ترتیب دقت کل ۹۳ و ضریب کاپای ۰/۹۲ ایجاد نموده

برای سری داده‌های مورد استفاده در این مطالعه از دقت بالاتری برخوردار بوده است.

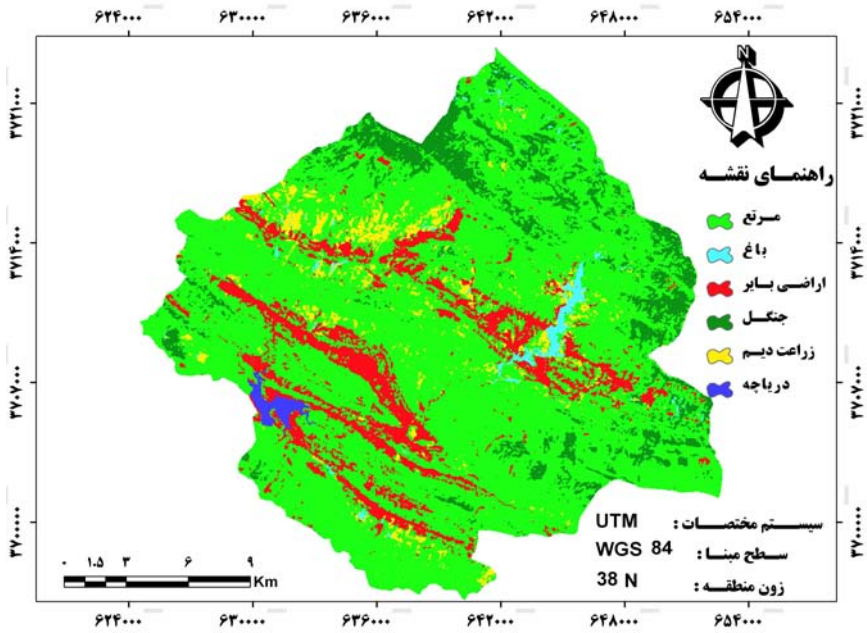
است. از این‌رو، الگوریتم‌های SVMs (با دقت کل ۱۰٪ و ضریب کاپای ۱۵٪ بالاتر) نسبت به روش طبقه‌بندی حداکثر احتمال (با دقت کل ۸۵ و ضریب کاپای ۰/۷۹)



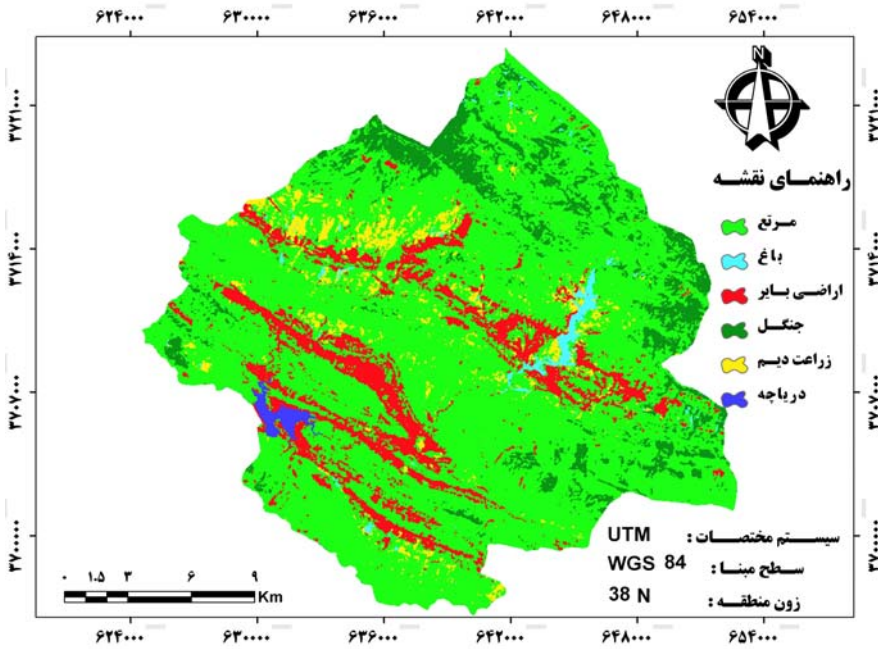
الف- روش حداکثر احتمال



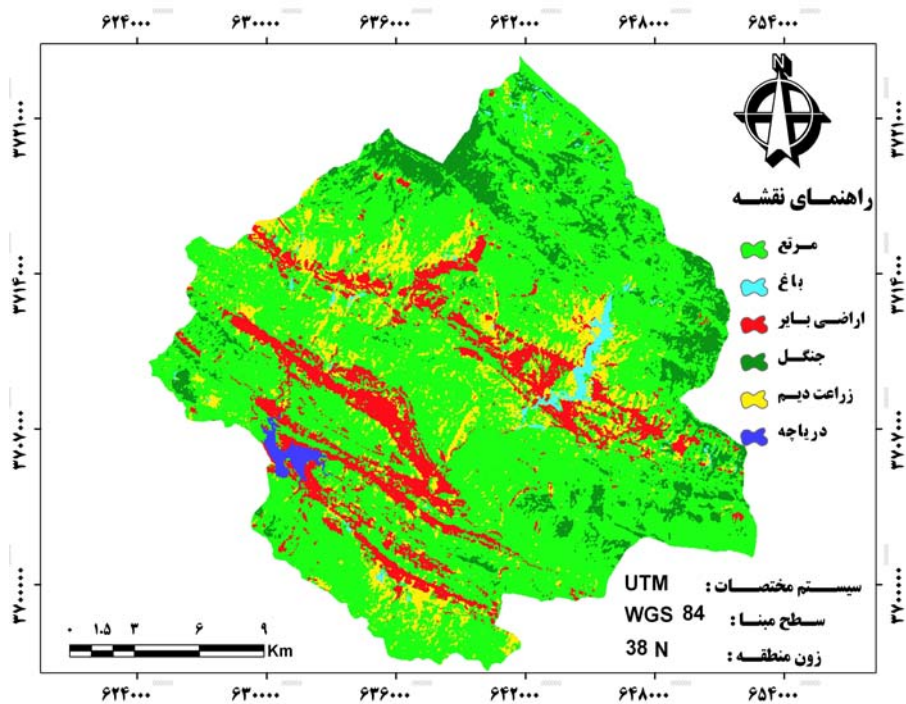
ب- ماشین بردار پشتیبان خطی



ج- ماشین بردار پشتیان چند جمله‌ای



د- ماشین بردار پشتیان شعاعی



ه- ماشین بردار پشتیبان حلقوی

شکل ۳- نتایج حاصل از طبقه‌بندی با استفاده از روش الف) حداکثر احتمال، ب) ماشین بردار پشتیبان خطی، ج) ماشین بردار پشتیبان چندجمله‌ای، د) ماشین بردار پشتیبان شعاعی و ه) ماشین بردار پشتیبان حلقوی

جدول ۱- میزان تفکیک‌پذیری برای کلاس‌های نقشه پوشش اراضی استخراج شده از تصویر ETM⁺

نام کاربری	دریاچه	باغ	اراضی زراعی	مرتع	جنگل	اراضی بایر
دریاچه	۲					
باغ	۲	۲				
اراضی زراعی	۲	۱/۹۴	۲			
مرتع	۲	۱/۹۳	۱/۸	۲		
جنگل	۲	۱/۹۲	۱/۹۶		۲	
اراضی بایر	۲	۲	۲	۲	۲	۲

جدول ۲- ماتریس خطای طبقه‌بندی تصویر ETM+ در سال ۲۰۰۲ (روش حداکثر احتمال)

خطای گماشته شده (درصد)	مجموع	دریاچه	زراعت دیم	جنگل	اراضی بایر	باغ	مرتع	کلاس
۱۱/۵۹	۷۷	۱	۰	۲	۵	۰	۶۹	مرتع
۱/۴۹	۶۸	۰	۰	۰	۰	۶۷	۱	باغ
۱۶/۳۲	۱۱۴	۱۶	۰	۰	۹۸	۰	۰	اراضی بایر
۴/۱۰	۷۶	۰	۰	۷۳	۰	۰	۳	جنگل
۵۶/۸۱	۶۹	۰	۲۵	۰	۰	۰	۴۴	زراعت دیم
۰	۳۳	۳۳	۰	۰	۰	۰	۰	دریاچه
-	۴۳۷	۵۰	۲۵	۷۵	۱۰۳	۶۷	۱۱۷	مجموع
-	-	۳۴	۰	۲/۶۷	۴/۸۵	۰	۴۱/۰۳	خطای حذف شده (درصد)

جدول ۳- ماتریس خطای طبقه‌بندی تصویر ETM+ در سال ۲۰۰۲ (ماشین بردار پشتیبان- خطی)

خطای گماشته شده (درصد)	مجموع	دریاچه	زراعت دیم	جنگل	اراضی بایر	باغ	مرتع	کلاس
۱۰/۴۰	۱۲۴	۰	۲	۳	۸	۰	۱۱۲	مرتع
۰	۶۷	۰	۰	۰	۰	۶۷	۰	باغ
۰	۹۵	۰	۰	۰	۹۵	۰	۰	اراضی بایر
۰	۷۲	۰	۰	۷۲	۰	۰	۰	جنگل
۱۷/۸۶	۲۸	۰	۲۳	۰	۰	۰	۵	زراعت دیم
۰	۵۰	۵۰	۰	۰	۰	۰	۰	دریاچه
-	۴۳۷	۵۰	۲۵	۷۵	۱۰۳	۶۷	۱۱۷	مجموع
-	-	۰	۸	۴	۷/۷۷	۰	۴/۲۷	خطای حذف شده (درصد)

جدول ۴- ماتریس خطای طبقه‌بندی تصویر ETM+ در سال ۲۰۰۲ (ماشین بردار پشتیبان- چندجمله‌ای)

خطای گماشته شده (درصد)	مجموع	دریاچه	زراعت دیم	جنگل	اراضی بایر	باغ	مرتع	کلاس
۱۰/۴۸	۱۲۴	۰	۲	۳	۸	۰	۱۱۱	مرتع
۰	۶۷	۰	۰	۰	۰	۶۷	۰	باغ
۰	۹۵	۰	۰	۰	۹۵	۰	۰	اراضی بایر
۰	۷۲	۰	۰	۷۲	۰	۰	۰	جنگل
۲۰/۶۹	۲۹	۰	۲۳	۰	۰	۰	۶	زراعت دیم
۰	۵۰	۵۰	۰	۰	۰	۰	۰	دریاچه
-	۴۳۷	۵۰	۲۵	۷۵	۱۰۳	۶۷	۱۱۷	مجموع
-	-	۰	۸	۴	۷/۷۷	۰	۵/۱۳	خطای حذف شده (درصد)

جدول ۸ - ارزیابی دقت طبقه‌بندی برای نقشه‌های کاربری استخراج شده از تصاویر ETM+ با استفاده از دو روش مورد مطالعه

بهرترین ترکیب باندی	روشها یا الگوریتمها	دقت کل (درصد)	ضریب کاپا (درصد)
باندهای اصلی ۷۵۴۳۲۱	روش حداکثر احتمال	۸۵	۷۹
	تابع خطی	۹۵	۹۴
	تابع چند جمله ای	۹۵	۹۴
	تابع حلقوی (سگموئید)	۹۳	۹۲
	تابع پایه شعاعی	۹۵	۹۴

بحث

استفاده از تصاویر ماهواره‌ای به‌عنوان یکی از منابع مهم مدیریت عرصه‌های منابع طبیعی می‌باشد. استفاده و کاربرد این تصاویر در زمینه‌های مختلف می‌تواند قابلیت و محدودیت‌های این داده‌ها را مشخص کند. آنچه که مهم است بررسی قابلیت این داده‌ها با توجه به پیشرفت‌های روزافزون قابلیت‌های طیفی و مکانی آنها می‌باشد. همچنین بررسی این داده‌ها در شرایط محیطی با تنوع کاربری‌ها و پوشش گیاهی ضروری بنظر می‌رسد. به‌طوری‌که، این تحقیق در ادامه تحقیقات سایر تحقیقات در خارج از کشور (Hopkins et al., 1988؛ Williams, 1992) و در داخل کشور (فرزانه، ۱۳۷۰؛ ریاحی بختیاری، ۱۳۷۹) ولی در شرایط متفاوت از آنها می‌باشد.

با وجود ترکیبات مختلف حاصل از آنالیزهای مختلف، نتایج نشان‌دهنده مناسب‌بودن باندهای اصلی سنجنده ETM+ برای طبقه‌بندی کاربرها می‌باشد. این امر نشان داد که باندهای پردازش شده تأثیری در تفکیک‌پذیری طبقات در این تحقیق نداشتند که نتیجه حاصل با نتایج شتایی و عبدی (۱۳۸۶) مطابقت دارد. نتایج بررسی تفکیک‌پذیری طبقات با معیار فاصله جفریس ماتوسیتا شده نشان داد که میزان تفکیک‌پذیری طبقات بجز طبقه اراضی زراعی با

مرتع که از تفکیک‌پذیری تقریباً کمی برخوردار بودند، با یکدیگر خوب بوده است. علت عدم تفکیک‌پذیری این دو طبقه را می‌توان در تشابه طیفی آنها جستجو کرد. نتایج ارزیابی دقت نشان داد که صحت تولید طبقه دریاچه و باغ (در روش حداکثر احتمال) و دریاچه، باغ، اراضی بایر و جنگل در روش ماشین بردار پشتیبان در مقایسه با سایر طبقات کاربری، از صحت تولیدکننده بالاتری برخوردار بود.

الگوریتم‌های ماشین بردار پشتیبان (SVMs) برای بسیاری از مشکلات طبقه‌بندی مورد استفاده قرار گرفته است. اگرچه گزارش شده است که این الگوریتم نتایج طبقه‌بندی دقیق‌تری نسبت به روشهای معمول دارد، اما انتخاب بهترین نوع کرنل مبحث مهمی است که کارایی این الگوریتم را تحت تأثیر قرار می‌دهد. در این مطالعه، توابع خطی، چندجمله‌ای، شعاعی و حلقوی به‌عنوان توابع کرنل برای طبقه‌بندی تیپ‌های اصلی کاربری زمین در حوزه سد ایلام مورد استفاده قرار گرفتند. در این مطالعه، کارآمدی طبقه‌بندی SVMs با توابع کرنل مختلف با روش طبقه‌بندی حداکثر احتمال مقایسه شد. نتایج نشان داد که روش SVMs نسبت به روش طبقه‌بندی حداکثر احتمال از لحاظ دقت کل (حدود ۱۰٪) و ضریب کاپا (حدود

منابع مورد استفاده

- بنیاد، ا.ا. و حاجی قادری، ط.، ۱۳۸۶. تهیه نقشه جنگل‌های طبیعی استان زنجان با استفاده از داده‌های سنجنده ETM+ ماهواره لندست ۷. مجله علوم و فنون کشاورزی و منابع طبیعی، ۴۲(۱۱): ۶۳۸-۶۲۷.
- ریاحی بختیاری، ح.، ۱۳۷۹. تعیین مناسب‌ترین روش تهیه نقشه‌های پوشش منابع طبیعی در مقیاس ۱:۲۵۰۰۰ با استفاده از داده‌های ماهواره ای، پایان‌نامه کارشناسی ارشد، دانشگاه تربیت مدرس.
- ساروئی، س.، ۱۳۷۸. بررسی امکان طبقه‌بندی جنگل به لحاظ تراکم در جنگل‌های زاگرس به کمک داده‌های ماهواره‌ای در منطقه سپید دشت شهرستان درود- لرستان. پایان‌نامه کارشناسی ارشد جنگلداری، دانشگاه تهران.
- شتایی، ش. و عبدی، ا.، ۱۳۸۶. تهیه نقشه کاربری اراضی در مناطق کوهستانی زاگرس با استفاده از داده‌های سنجنده ETM+ (منطقه مورد مطالعه: حوزه سرخاب خرم آباد لرستان). مجله علوم کشاورزی و منابع طبیعی ۱۴(۱): ۲۳-۱۳.
- علوی پناه، س.ک.، ۱۳۸۴. کاربرد سنجنش از دور در علوم زمین. انتشارات دانشگاه تهران، ۴۷۸ صفحه.
- فاطمی، س.ب. و رضایی، ی.، ۱۳۸۴. مبانی سنجنش از دور، انتشارات آزاده، ۲۶۸ صفحه.
- فرزانه، ع.، ۱۳۷۰. بررسی کاربرد تصاویر ماهواره‌ای به‌منظور نظارت و شناسایی منابع طبیعی در شمال غربی ایران (منطقه اردبیل)، مجله جنگل و مرتع. ص ۴۵-۵۱.
- Burges, C.J.C., 1998. A tutorial on support vector machines for Pattern Recognition, Data mining and knowledge discovery, 2:121-158,1998.
- Crammer, K. and Singer, Y., 2000. On the learnability and design of output codes for multiclass problems. In: Proceedings of the 13th Annual Conference on Computational learning theory. pp. 35-46.
- Dixon, B. and Candade, N., 2008. Multispectral land use classification using neural networks and support vector machines: one or the other, or both?, International Journal of Remote Sensing 29, 1185-1206.
- Foody, G.M. and Mathur, A., 2004. A relative evaluation of multiclass image classification by support vector machines. IEEE Transactions on Geoscience and Remote Sensing 42, 1335-1343.
- Goh, K., Chang, E. and Cheng, K.T., 2001. SVM Binary classifier ensembles for image classification, ACM Int. Conf. on Information and Knowledge Management (CIKM), pp. 395-402, Nov.

۱۵٪) برتر بود. این نتایج به طور کلی تصدیق‌کننده مطالعات پیشین می‌باشد که در آنها روش SVM دقیق‌تر از حداکثر احتمال است. (Mathur & Foody (2004)؛ Huang et al., (2002)؛ Pal & Mather (2004)؛ Kavzoglu & Colkesen (2009) در تحقیقات خود به این نتیجه رسیدند. همچنین این روش در تمامی کلاس‌ها نسبت به روش دیگر دقیق‌تر می‌باشد. علت دقت بالای الگوریتم SVM نسبت به دیگر روشها را می‌توان این طور بیان کرد که این روش از لحاظ محاسباتی سریع بوده و همچنین این روش از قوانین بهینه‌سازی جهت مکان‌یابی مرزهای بهینه بین کلاس‌ها کاربری استفاده می‌کند، در نتیجه جایگزین مناسبی برای سایر الگوریتم‌های معمول طبقه‌بندی می‌باشد.

درضمن، همه روشهای طبقه‌بندی، تمام پیکسل‌های آب را بدرستی شناسایی کردند. دقت بالای طبقه‌بندی کلاس آب می‌تواند ناشی از خصوصیات طیفی متمایز یا قابلیت تفکیک‌پذیری طیفی آن در مقایسه با سایر تیپ‌های پوشش باشد. زمانی که توابع کرنل مورد آنالیز قرار گرفت، مشخص گردید که سه تابع کرنل خطی، چندجمله‌ای و شعاعی نسبت به تابع کرنل حلقوی نتایج دقیق‌تری (حدود ۲٪ هم از لحاظ دقت کل و ضریب کاپا) داشت. در این تحقیق، بالاترین دقت طبقه‌بندی مربوط به سه کرنل خطی، چندجمله‌ای و شعاعی می‌باشد. این مطالعه نشان می‌دهد که الگوریتم‌های ماشین بردار پشتیبان مزیت‌های زیادی نسبت به روش طبقه‌بندی حداکثر احتمال دارد و می‌تواند دقت طبقه‌بندی بالاتری داشته باشد. در نتیجه جایگزین خوبی برای الگوریتم‌های معمول طبقه‌بندی می‌باشد.

- Lu, D., Mausel, P., Brondi'zio, E. and Moran, E., 2004. Change detection techniques. *INT. J. REMOTE SENSING*, 20 JUNE, 2004, VOL. 25, NO. 12, 2365–2407.
- Mathur, A. and Foody, G.M., 2008a. Multiclass and binary SVM classification: Implications for training and classification users. *IEEE Geoscience and Remote Sensing Letters* 5, 241–245.
- Osuna, E., Freund, R. and Girosi, F., 1997. Support vector machines: training and application, A.I. Memo 1602, MIT A. I.Lab.
- Pal, Mahesh and Mather, P.M., 2004. Assessment of the effectiveness of support vector Machines for hyperspectral data, *FGCS* 20,1215-1225.
- Swain, P.H. and Davis, S.M. (editors)., 1978. *Remote Sensing: the Quantitative Approach* (New York: McGraw-Hill).
- Vapnik, V. and Chervonenkis, A., 1991. The necessary and sufficient conditions for consistency in the empirical risk minimization method," *Pattern Recognition and Image Analysis*, vol. 1, no. 3, pp. 283-305.
- Vapnik, V.N., 1995. *The Nature of Statistical Learning Theory* (New York: Springer Verlag).
- Wang, F., 1990. Fuzzy supervised classification of remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 28, 194–201.
- Weston, J. and Watkins, C., 1998. Multi-Class Support Vector Machines. Technical Report CSD-TR-98-04, Department of Computer Science, Royal Holloway, University of London, Egham, England, p. 10.
- Wilkinson, G.G., 1997. Open questions in neurocomputing for earth observation. In *Neuro-Computation in Remote Sensing Data Analysis*, edited by I. Kanellopoulos, G. G. Wilkinson, F. Roli and J. Austin. London: Springer, 3-13.
- Williams, J.A., 1992. Vegetation classification using landsat TM and SPOT-HRV imagery in mountainous terrain. Kananaskis country, S.W. Alberta. Committee on resources and the environment, University of Calgary, p.126-135.
- Yao, X., Tham, Lg. and Dai, F.C., 2008. Landslide susceptibility mapping based on support vector machine: a case study on natural slopes of Hong Kong, China, *Geomorphology* 101,572–582.
- Gualtieri, J.A. and Crompton, R.F., 1998. Support vector machines for hyperspectral remote sensing classification. *Proceedings of the 27th AIPR Workshop: Advances in Computer Assisted Recognition*, Washington, DC, October 27, 221-232.
- Hansen, M., Dubayah, R. and DeFries, R., 1996. Classification trees: an alternative to traditional land cover classifiers. *International Journal of Remote Sensing*, 17, 1075–1081.
- Hopkins, P.F., Maclean, A.L. and Lilleasand, T., 1988. Assessment of thematic mapper imagery for forestry application under Lake state conditions, *photogrammetric Engineering and remote sensing*, Vol.54, No.1,61-68.
- Hsu, C.W., Chang, C.C. and Lin, C.J., 2008. A practical guide to support vector classification. <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>.
- Hsu, C.W. and Lin, C.J., 2002. A comparison of methods for multiclass support vector machines. *IEEE Transactions on Neural Networks* 13, 415–425.
- Huang, C., Davis, L. S. and Townshend, J. R. G., 2002. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23, 725–749.
- Kavzoglu, T. and Colkesen, I., 2009. A Kernel function analysis for support vector machines for land cover classification. *International Journal of Applied earth observation and Geoinformation* 11, 352-359.
- Kner, S., Personnaz, L. and Dreyfus, G., 1990. Single-layer learning revisited: a stepwise procedure for building and training a neural network. In: Fogelman- Soulie, Hérault, (Eds.), *Neurocomputing: Algorithms, Architectures and Applications*. NATO ASI Series, Springer.
- Joachims, T., 1998a. Making large scale SVM learning practical. In *Advances in Kernel Methods—Support Vector Learning*, edited by B. Scholkopf, C. Burges and A. Smola (New York: MIT Press).
- Joachims, T., 1998b. Text categorization with support vector machines—learning with many relevant features. In *Proceedings of European Conference on Machine Learning*, Chemnitz, Germany, April 10, 1998 (Berlin: Springer), pp. 137–142.

Efficiency assessment of the of Support Vector Machines for land use classification using Landsat ETM⁺ data (Case study: Ilam Dam Catchment)

Arekhi, S.^{1*} and Adibnejad, M.²

1*- Corresponding Author, Assistant Professor, Faculty of Agriculture, Ilam University, Ilam, Iran, Email: saleh148@yahoo.com

2-BSc of Forestry, Gonbad College of Agriculture, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran.

Received: 07.12.2009

Accepted:26.08.2010

Abstract

Land use classification using remotely sensed images is one of the most common applications in remote sensing, and many algorithms have been developed and applied for this purpose in the literature. This study investigates the efficiency of Support Vector Machines algorithms in image classification. Support Vector Machines (SVMs) are a group of supervised classification algorithms of machine learning that have been used in the remote sensing filed. The classification accuracy produced by SVMs may show variation depending on the choice of the kernel function. In this study, SVMs were used for land use classification of Ilam dam catchment using Land sat ETM⁺ data. The classification using SVM method was implemented automatically by using four kernel types, linear, polynomial, radial basis, sigmoid and the results were analyzed thoroughly. Results showed that SVMs, especially with use of radial, polynomial and linear function kernels, outperform the maximum likelihood classifier in terms of overall (about 10%) and kappa coefficient(about 15%) accuracies. So, this study verifies the efficiency and capability of SVMs in classification of remote sensed images.

Key words: Supervised classification, Land use, Maximum likelihood method, Support Vector Machines, Ilam Dam catchment