

بهبود شناسایی تغییرات زمین‌های زیر کشت با تاکید بر استفاده از تصویر هم مرجع شده چندزمانه و روش ترکیب رنگی

فاروق محمودی^{۱*}، مهدی مختارزاده^۲، محمدجواد ولدان زوج^۳

^۱ کارشناس ارشد فتوگرامتری - دانشکده مهندسی نقشه‌برداری-دانشگاه صنعتی خواجه نصیرالدین طوسی
faroughmahmoodi66@gmail.com

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

^۳ دانشیار گروه فتوگرامتری و سنجش از دور - دانشکده مهندسی نقشه‌برداری-دانشگاه صنعتی خواجه نصیرالدین طوسی
valadanouzj@kntu.ac.ir

(تاریخ دریافت مرداد ۱۳۹۳، تاریخ تصویب تیر ۱۳۹۴)

چکیده

در این تحقیق تعیین روال مناسب جهت شناسایی تغییرات زمینهای زیر کشت و برآورد درصد آن تغییرات در یک منطقه نیمه شهری با تکیه بر الگوریتم های شبکه عصبی و SVM بصورت نظارت شده مورد بررسی قرار گرفته است. برای این منظور از تصاویر چندزمانه سنجنده های Landsat استفاده شده است. در واقع در این روش برخلاف روشهای رایج، برای شناسایی تغییرات از مقایسه تصاویر استفاده نشده است بلکه هدف کشف تغییرات با استفاده توام از روش ترکیب رنگی و الگوریتم های طبقه‌بندی می‌باشد. ایده اصلی به این طریق است که با استفاده از دو تصویر، یک تصویر هم مرجع شده چندزمانه تهیه و سپس با استفاده توام از روش ترکیب رنگی جمعی (ترکیب کردن لایه های رنگی تصاویر) و روشهای تشخیص الگو و اعمال آنها بر روی تک تصویر هم مرجع شده بدست آمده، نواحی مناطق تغییر یافته و تغییر نیافته ایجاد و درنهایت با انتخاب نمونه های آموزشی فقط از یک تصویر، الگوریتم بر روی تصویر تلفیقی اعمال و نقشه تغییرات نهایی بدست آمده است. نتایج حاصل شده حاکی از آن است که این روش از جهت کاهش نمونه های آموزشی، افزایش دقت (تقریباً ۳ درصد) و سرعت عمل شناسایی تغییرات بر روشهای معمول که از مقایسه دو تصویر چندزمانه با هم استفاده می‌کنند برتری دارد.

واژگان کلیدی: طبقه بندی نظارت شده، الگوریتم های شبکه عصبی و SVM، شناسایی تغییرات، روش ترکیب رنگ

* نویسنده رابط

۱- مقدمه

امروزه برآورد میزان محصولات کشاورزی و زمین‌های زیر کشت و تغییرات آنها، چنان اهمیتی دارد که امر برنامه ریزی و مدیریت آنها به عنوان یک ضرورت برای همه کشورها تلقی می‌شود. لذا در این راستا علوم سنجش از دور با تکیه بر روشهای تشخیص الگو، گامهای مطلوبی را برداشته‌اند.

کشف تغییرات در واقع شناسایی تفاوتها و دگرگونی‌های ایجاد شده در عوارض و نواحی ایجاد شده در فواصل زمانی متفاوت می‌باشد و اصولاً از طریق تحلیل و بررسی دو تصویر هم مرجع شده در دو فاصله زمانی متفاوت صورت می‌گیرد، برای کشف تغییرات روشهای گوناگونی در فتوگرامتری و سنجش از دور وجود دارد و شاید بتوان گفت که هیچکدام بصورت مطلق در تمام وجوه بهینه نمی‌باشد. انتخاب نوع روش، کار چندان ساده‌ای نیست و وابسته به کاربرد، تعداد و تراکم عوارض مورد نظر، دقت مورد نیاز، دوره بهنگام رسانی، هزینه و پارامترهای بسیار دیگری می‌باشد. روشهای شناسایی تغییرات از یک نگاه به دو دسته کلی تقسیم بندی می‌شوند: روشهایی که الزاماً مبتنی بر طبقه بندی هستند و روشهایی که مبتنی بر طبقه بندی نیستند. اساس تعیین تغییرات در روشهای مبتنی بر طبقه بندی، طبقه‌بندی تصویر می‌باشد که در آن کمیت و کیفیت داده آموزشی، تأثیر بسیار مهمی بر روی نتایج آنالیز نهایی تعیین تغییرات خواهد گذاشت. بطور کلی از مزایای این روشها می‌توان مشخص کردن تغییرات با جزئیات قابل قبول، کاهش اثرات ناشی از اتمسفر و محیط میان تصاویر چندزمانه و ظرفیت خوب آنها در تهیه ماتریس اطلاعات تغییر را عنوان کرد. در این تحقیق از روش مبتنی بر طبقه بندی بصورت نظارت شده استفاده شده است. در این سری روشها علاوه بر تصاویر ورودی به یک سری اطلاعات خارجی در مورد منطقه مورد مطالعه نیاز داریم و معمولاً اطلاعات خارجی به صورت یکسری پیکسل‌های معلوم که منتسب به یک کلاس مشخص در منطقه می‌باشند، به الگوریتم معرفی می‌گردند.

در ادامه بعنوان پیشینه تحقیق از میان این روشها چهار روش مقایسه پس طبقه‌بندی^۱، آنالیز تصاویر ترکیب‌شده زمانی و طیفی^۲، روشهای مبتنی بر شبکه عصبی مصنوعی^۳ و تشخیص تغییر براساس روشهای ترکیبی^۴ که بسیار رایج می‌باشند بررسی و جایگاه آنها در شناسایی تغییرات با استفاده از تصاویر طبقه بندی شده بیان شده است. در روش مقایسه پس طبقه‌بندی هر یک از تصاویر چند زمانه به طور جداگانه طبقه‌بندی می‌شوند، سپس پیکسل به پیکسل با هم مقایسه و در نهایت نقشه تغییرات تولید می‌کنند. پیشینه تحقیقات نشان می‌دهد که این روش در کاهش دادن اثر تغییرات ناشی از اتمسفر، سنجنده و محیط تأثیر بسیار بسزایی داشته و اینکه تغییرات را غالباً به شیوه مناسب شناسایی می‌کند. نیاز به تجربه بالا در طبقه‌بندی، زمان‌بر بودن و وابستگی دقت به روش‌های طبقه‌بندی از جمله معایب این روش می‌باشد. می‌توان گفت که در این روش دقت نقشه تغییرات بدست آمده بطور تقریبی برابر با حاصلضرب دقت طبقه بندی تصاویر مربوطه می‌باشد. در آنالیز تصاویر ترکیب‌شده زمانی و طیفی همه تصاویر چندزمانه به یک فایل تبدیل شده و به صورت یک‌جا و باهم تواما طبقه‌بندی می‌شوند. سپس تغییرات، شناسایی شده و برچسب‌گذاری می‌شوند. در اینجا نیز دقت نهایی به دقت الگوریتم طبقه بندی نیز بستگی دارد. با توجه به تحقیقات گذشته ایجاد مشابهت مکانی در میان تصاویر چندزمانه، کلاس‌بندی ساده و بدون صرف زمان زیاد از مزایای این روش است. و از جمله معایب این روش می‌توان به مشکل بودن شناسایی تغییرات و برچسب‌گذاری کلاس‌ها اشاره کرد و اینکه اطلاعات کاملی از تغییرات را ارائه نمی‌دهند. این روش بدلیل مشکل بودن شناسایی و برچسب‌گذاری تغییرات در آن کمتر مورد توجه قرار گرفته است. در روشهای مبتنی بر شبکه عصبی مصنوعی تحقیقات نشان داده است که بعد از مطرح شدن این الگوریتم استفاده‌های بسیار گسترده‌ای در راستای شناسایی تغییرات از آن شده است. نتایج استفاده از این الگوریتم در راستای کشف تغییرات حاکی از آن است که این روش از جنبه آموزش شبکه،

^۱ Post-classification comparison

^۲ spectral temporal combined

^۳ Artificial Neural Networks (ANN)

^۴ Hybrid change detection

۲- مروری بر مفاهیم نظری موردنیاز

۲-۱- الگوریتم طبقه بندی کننده SVM^۱

الگوریتم SVM، جزو الگوریتم های تشخیص الگو و طبقه بندی دسته بندی می شود. از این الگوریتم درهرجایی که نیاز به دسته بندی اشیا در کلاس های خاص باشد می توان استفاده کرد درحقیقت SVM یک روش طبقه بندی غیر پارامتریک میباشد که سعی میکند یک صفحه منحصر بفرد را بین هرچفت کلاس پیدا کند. روش این طبقه بندی کننده جدا کردن دو کلاس با کمترین خطا میباشد بطوری که داده های هر کلاس بیشترین فاصله ممکن را داشته باشند. این الگوریتم اولین بار در ۱۹۶۳ توسط Vladimir Vapnik ابداع شد و در سال ۱۹۹۵ توسط Vapnik و Corinna Cortes برای حالت غیرخطی تعمیم داده شد.

هدف این الگوریتم پیدا کردن یک صفحه جداساز^۲ با بیشترین فاصله از نقاط حاشیه ای است. در این حالت اگر روابط مربوطه برای صفحه جداساز در نظر گرفته شوند، داده های آموزشی در بالا و پایین این صفحه قرار خواهندگرفت. بر اساس شرایط بیان شده، زمانی یک مجموعه از نقاط به صورت بهینه با یک صفحه جداسازی می شوند که اولاً بدون اشتباه در کلاس مربوط به خود قرار گرفته باشند و دوماً اینکه فاصله بین نزدیکترین نقاط هر کلاس داده تا صفحه جدا کننده بیشینه باشد.

۲-۲- الگوریتم طبقه بندی کننده ANN^۳

شبکه عصبی مصنوعی ایده ای است برای پردازش اطلاعات، که از سیستم عصبی الهام گرفته شده و مانند مغز به پردازش اطلاعات می پردازد. این سیستم از شمار زیادی عناصر پردازشی فوق العاده بهم پیوسته به نام نرون^۴ تشکیل شده و برای انجام وظیفه های مشخص، مانند شناسایی الگو ها و دسته بندی اطلاعات، در طول یک پروسه یاد گیری، تنظیم می شود. اولین شبکه های عصبی به کار گرفته شده در مسائل واقعی مدل خطی تطبیقی نورون بود که در سال ۱۹۶۰ توسط ویدرو و هاف

خود سازماندهی، پایداری و انعطاف پذیری، درون یابی و تعمیم دهی بسیار مناسب بوده است. شبکه های عصبی مصنوعی عموماً غیر پارامتری توصیف می شوند و به همین خاطر به هیچ فرضی درباره توزیع آماری داده ها نیاز ندارند. و در نهایت درتشخیص تغییر براساس روشهای ترکیبی در واقع روشهای حدآستانه ای و طبقه بندی با هم در نظر گرفته می شوند و برای شناسایی تغییرات تواما از مزیت های هر دو روش استفاده می کنند. روشهای حد آستانه ای مانند روشهای جبری عموماً برای تشخیص نواحی تغییر یافته استفاده می شوند و سپس روشهای طبقه بندی برای تحلیل نواحی تغییر یافته و طبقه بندی آنها مورد استفاده قرار می گیرند. از جمله مشکلات این روش تعیین کردن حد آستانه برای مشخص کردن مرز تغییرات می باشد.

ذکر این نکته لازم است که هر کدام یک از روشهای توضیح داده شده در بالا یک روش را با یک مرز مشخص و محدود معرفی نمی کنند بلکه هر کدام یک از آنها یک روش کلی است و در عمل بطور کامل وابسته به روشهای طبقه بندی می باشند و عملاً بدون استفاده از روشهای طبقه بندی کارایی روش بطور کلی از بین خواهد رفت. تاکید در این مقاله علاوه بر استفاده از روشهای مبتنی بر طبقه بندی، ترکیب کردن لایه های رنگی تصاویر و استفاده از داده آموزشی فقط در یک تصویر جهت کشف تغییرات نیز می باشد. لذا در واقع می توان هدف از این پژوهش را موارد زیر عنوان کرد:

۱- ارائه روشی بهینه در شناسایی تغییرات بر روی تصاویر ماهواره Landsat با استفاده از روش ترکیب رنگی و با تکیه بر الگوریتم های طبقه بندی شبکه عصبی و SVM.

۲- بهبود شناسایی تغییرات زمینهای زیر کشت با بکار گیری تصویر هم مرجع شده چندزمانه و کاهش داده آموزشی با تکیه بر الگوریتم های مذکور.

۳- مطرح کردن ایده شناسایی تغییرات بدون مقایسه تصاویر چندزمانه با هم و تکیه بر ترکیب رنگ در تک تصویر بدست آمده شامل کل لایه های دو تصویر چندزمانه.


^۱ Support vector machine

^۲ hyperplane

^۳ Artificial Neural Network

^۴ neurons

آموزشی از تصویر اول به تصویر دوم استفاده شده است. ساختار کلی این الگوریتم بصورت شکل ۳ می باشد:



شکل ۲- تصویر هم مرجع شده چندزمانه شامل کل لایه های دو تصویر

این الگوریتم شامل سه مرحله اصلی می باشد که می توان آنها را هسته اصلی روش مطرح شده دانست برای تفهیم فلوچارت این سه مرحله در زیر توضیح داده شده است:


۱- در گام اول بعد از هم مرجع سازی تصاویر، لایه های مختلف تصاویر چندزمانه را تواما با هم در نظر می گیرد و تصاویر به یک تصویر شامل کل لایه ها تبدیل می- شوند.

۲- در گام دوم شناسایی تغییرات را بعد از ایجاد تک تصویر هم مرجع شده چند زمانه حاصل از دو تصویر، با استفاده توام از روش ترکیب رنگی جمعی و الگوریتم های تشخیص الگو انجام می دهد. در واقع در روش ترکیب رنگی جمعی از ترکیب رنگها در باندهای مختلف تصویر استفاده می شود بطوری که نواحی که در آنها تغییرات داریم با رنگهایی متفاوت با رنگ اولیه ظاهر می شوند. روشی است بسیار کارآمد و در عین حال ساده که در آن لایه های مختلف تصاویر چند زمانه با هم ترکیب می شوند و نتیجه تصویری با رنگهایی متفاوت با تصاویر اولیه خواهد بود. همانطور که بیان شد تفهیم این مطلب در شکل ۱ مشهود است. در نهایت بعد از بدست آمدن تصویر رنگی حاصل از تلفیق لایه ها، کاربر خبره با شناسایی چند ناحیه که در آن تغییرات رخ داده است نمونه آموزشی مربوط به نواحی تغییر یافته و تغییر نیافته را انتخاب و بقیه نواحی با توجه به نمونه های انتخاب شده، براساس الگوریتم ها و روشهای طبقه بندی، شناسایی شده است. سادگی و بالارفتن سرعت عمل شناسایی تغییرات را می توان از جمله مزایای این روش به حساب آورد.

(دانشگاه استنفورد) به وجود آمد. اصولا شبکه ی عصبی معمول برای طبقه بندی در سنجش از دور شبکه عصبی چند لایه ای پرسپترون میباشد. عملکرد شبکه های عصبی به نوع آموزش شبکه بستگی دارد و نوع آموزش اهمیت آن را تعیین میکند. شبکه های عصبی با توجه به معماری شبکه و یا ماهیت عملکرد نورونهای شبکه و یا پارامترهای وزن شبکه به انواع مختلفی تقسیم بندی میشوند. شبکه های عصبی با توانایی قابل توجه خود در استنتاج نتایج از داده های پیچیده می توانند در استخراج الگوها و طبقه بندی کردن داده های مختلفی که شناسایی آنها بسیار دشوار است استفاده شوند.

۲-۳- روش ترکیب رنگی جمعی

در این روش از یک ترکیب رنگی استفاده می شود. روشی است بسیار ساده که در آن لایه های مختلف تصاویر چند زمانه با هم ترکیب می شوند (رنگ ها با هم جمع می شوند) و نتیجه تصویری با رنگهایی متفاوت با تصاویر اولیه خواهد بود. تفهیم این مطلب در شکل ۱ مشهود است.




شکل ۱- (a) - یک قطعه از تصویر سال ۱۹۹۹ (b) - یک قطعه از تصویر سال ۲۰۰۲ (c) - تصویر حاصل شده با روش ترکیب رنگ لایه های دو تصویر دیگر

۳- روش پیشنهادی

در این مدل برخلاف روشهای رایج شناسایی تغییرات که اصولا در آنها از مقایسه دو تصویر چندزمانه با هم استفاده می کنند، از تک تصویر هم مرجع شده شامل کل لایه های دو تصویر (شکل ۲) و همچنین توسعه داده های

نهایت با استفاده از داده های آموزشی و روشهای رایج طبقه بندی مانند SVM و شبکه عصبی نوع کلاسها مشخص و برچسب زده شد و دقت نهایی حاصل از آن نیز با استفاده از ماتریس ابهام و دو پارامتر بسیار رایج استخراج شده از آن (دقت کلی و ضریب کاپا) ارزیابی گردید. کل مراحل با استفاده از نرم افزارهای 2011 Matlab و ENVI و Arc GIS پیاده سازی شده است.

۳- در گام سوم در توسعه داده های آموزشی به تصویر دوم ایده بکار برده شده، استفاده از داده های آموزشی در نواحی بدون تغییر بوده است و چنانچه داده آموزشی در نواحی تغییر یافته قرار می گرفت حذف شده است. در واقع بعد از کشف نواحی تغییر یافته با همپوشانی داده های آموزشی با تصویر مشتمل بر نواحی تغییرات، نمونه هایی که در نواحی تغییر یافته قرار داشتند حذف شدند. در



شکل ۳ - مدل پیشنهادی

داده های طیفی بدست آمده توسط سنجنده های مختلف بوسیله فاکتورهای مختلفی مانند اتمسفر، کالیبراسیون دوربین، هندسه تصویر برداری و... تحت تاثیر قرار می گیرند، لذا برای شناسایی تغییرات اصلی بر روی سطح مورد نظر باید تصحیحات رادیومترکی را انجام داد. در این مقاله از روش نسبی^۱ از نوع آماری استفاده شده است. این گروه شامل روشهایی است براساس سرشکنی خطی دو تصویر برای اینکه رنج دینامیکی (مقدار DN)، میانگین

^۱ Relative radiometric normalization

۴- پیاده سازی و ارزیابی نتایج

۴-۱- داده های مورد استفاده

در این مقاله از دو تصویر شکل ۵ و شکل ۶ که در ابعاد ۵۰۰ در ۵۰۰ برش داده شده اند و از ماهواره Landsat در ماه اکتبر سال ۲۰۰۲ و ۱۹۹۹ میلادی از نواحی نیمه شهری جنوب غربی شهر تهران اخذ شده اند استفاده شده است. این شهر در ۵۱ درجه و ۶ دقیقه تا ۵۱ درجه و ۳۸ دقیقه طول شرقی و ۳۵ درجه و ۳۴ دقیقه تا ۳۵ درجه و ۵۱ دقیقه عرض شمالی واقع شده است. قابل ذکر است که

آماري و انحراف استاندارد و ديگر پارامترهاي آماری را در دو تصوير مثل هم کند.



شکل ۴- تصوير برش داده شده landsat سال ۱۹۹۹ ميلادی



شکل ۵- تصوير برش داده شده landsat سال ۲۰۰۲ ميلادی

۴-۲- نتايج

برای ارزیابی دقت نهایی شناسایی تغییرات از دقت کلی حاصل شده از ماتریس خطا و ضریب کاپا استفاده شده است. پیاده سازی با استفاده از دو سری کاملاً متفاوت داده آموزشی و ارزیابی که بوسیله کاربر خبره انتخاب شدند انجام گرفت. تعداد نمونه های آموزشی و ارزیابی مورد استفاده سری اول در زیر مشاهده می شوند:

جدول ۱- تعداد نمونه های آموزشی (سری اول)

نوع کلاس تعریف شده	تعداد نمونه های آموزشی در تصویر اول (پیکسل)	تعداد نمونه های آموزشی در تصویر دوم (پیکسل)
کشاورزی	۱۴۳	۱۷۲
غیر کشاورزی	۱۶۶	۱۸۹

جدول ۲- تعداد نمونه های ارزیابی (سری اول)

نوع کلاس تعریف شده تغییرات	تعداد داده های ارزیابی (پیکسل)
قبلاً بایر بوده، الان کشاورزی است	۱۱۶
بدون تغییرات	۲۱۳
قبلاً کشاورزی بوده، الان نیست	۱۷۰

لازم است یادآوری شود که برای اینکه دقت انتخاب داده های آموزشی در دو روش (روش پیشنهادی و روش معمولی) یکسان باشد و در نتایج نهایی تأثیر یکسانی داشته باشد، در هر دو الگوریتم برای طبقه بندی جهت تهیه نقشه تغییرات از نمونه های یکسانی استفاده شده است. الگوریتم های مورد استفاده بقرار زیر بودند:

۱- الگوریتم SVM با آموزش نظارت شده

نوع تابع کرنل: منحنی درجه دو

مقدار پارامتر بایاس در تابع کرنل استفاده شده: ۱

مقدار پارامتر گاما در تابع کرنل استفاده شده: ۰,۲

مقدار پارامتر تنظیم در نظر گرفته شده: ۱۰۰

۲- الگوریتم SVM با آموزش نظارت شده

نوع تابع کرنل: RBF

مقدار پارامتر گاما در تابع کرنل استفاده شده: ۰,۲

مقدار پارامتر تنظیم در نظر گرفته شده: ۱۰۰

۳- الگوریتم شبکه عصبی مصنوعی نظارت شده

نوع تابع محرک: step function

نرخ آموزش: ۰,۲ و تعداد تکرارها: ۵۰۰

وزن اولیه در نظر گرفته شده: ۰,۹

RMS در نظر گرفته شده: ۰,۱

بعد از اجرای مراحل، نتایج زیر حاصل شد:

جدول ۳- دقت نهایی شناسایی تغییرات روش معمولی (سری اول)

ضریب کاپا برای مدل ۱	دقت کلی برای مدل ۱	الگوریتم طبقه بندی کننده
٪۹۶,۲۸	٪۹۷,۹۵	SVM با تابع کرنل سهمی
٪۹۵,۹۶	٪۹۷,۳۹	SVM با تابع کرنل RBF
٪۹۴,۰۱	٪۹۶,۵۸	شبکه عصبی مصنوعی

جدول ۴- دقت نهایی شناسایی تغییرات روش پیشنهادی (سری اول)

ضریب کاپا برای مدل ۲	دقت کلی برای مدل ۲	الگوریتم طبقه بندی کننده
٪۹۷,۵۲	٪۹۸,۳۹	SVM با تابع کرنل سهمی
٪۹۷,۸۳	٪۹۸,۵۹	SVM با تابع کرنل RBF
٪۹۷,۲۱	٪۹۸,۱۹	شبکه عصبی مصنوعی


جدول ۷- دقت نهایی شناسایی تغییرات روش معمولی (سری دوم)

ضریب کاپا برای مدل ۱	دقت کلی برای مدل ۱	الگوریتم طبقه بندی کننده
٪۹۶،۴۸	٪۹۷،۸۰	SVM باتابع کرنل سهمی
٪۹۶،۱۲	٪۹۷،۵۸	SVM با تابع کرنل RBF
٪۹۶،۴۸	٪۹۷،۸۰	شبکه عصبی مصنوعی

جدول ۸- دقت نهایی شناسایی تغییرات روش پیشنهادی (سری دوم)


ضریب کاپا برای مدل ۲	دقت کلی برای مدل ۲	الگوریتم طبقه بندی کننده
٪۹۸،۶۰	٪۹۹،۱۲	SVM باتابع کرنل سهمی
٪۹۸،۶۰	٪۹۹،۱۲	SVM با تابع کرنل RBF
٪۹۸،۴۴	٪۹۹،۰۳	شبکه عصبی مصنوعی

دوباره مشاهده می شود که دقت کلی و ضریب کاپای حاصل شده از ارزیابی دقت نهایی شناسایی تغییرات مدل پیشنهادی از بقیه نتایج بهتر است. البته با توجه به پیاده سازی الگوریتم ها با دو سری متفاوت از نمونه های آموزشی و ارزیابی باید به این نکته توجه کرد که دقت نمونه های آموزشی تاثیر قابل توجهی در نتایج خواهد داشت و باید نمونه ها با دقت بالایی انتخاب شوند. تصویر نمایش دهنده تغییرات زمینهای زیر کشت در این مرحله با استفاده از این الگوریتم نیز در شکل ۷ مشاهده می شود:



شکل ۷- نمایش تغییرات بدست آمده از سری دوم داده های آموزشی

همانطور که از نتایج بدست آمده در جداول مشهود است مشاهده می کنیم که دقت کلی و ضریب کاپای حاصل شده از ارزیابی دقت نهایی شناسایی تغییرات مدل پیشنهادی از بقیه نتایج بهتر است. در قسمت نتایج با توجه به نمودارها دلایل آن بصورت خلاصه بیان شده است. تصویر خروجی نمایش دهنده تغییرات زمینهای زیر کشت در این مرحله با استفاده از این الگوریتم در شکل ۶ مشاهده می شود:



شکل ۶- نمایش تغییرات بدست آمده از سری اول داده های آموزشی

در ادامه برای سری دوم از داده های آموزشی و ارزیابی، الگوریتم های مذکور پیاده سازی شده است. تعداد نمونه های آموزشی و ارزیابی مورد استفاده این سری و نتایج حاصل از پیاده سازی آنها، دقت کلی و ضریب کاپا در جداول زیر مشاهده می شوند:

جدول ۵- تعداد نمونه های آموزشی (سری دوم)

نوع کلاس تعریف شده	تعداد نمونه های آموزشی در تصویر اول (پیکسل)	تعداد نمونه های آموزشی در تصویر دوم (پیکسل)
کشاورزی	۱۳۰	۱۱۷
غیر کشاورزی	۱۶۲	۱۶۶



جدول ۶- تعداد نمونه های ارزیابی (سری دوم)

نوع کلاس تعریف شده تغییرات	تعداد داده های ارزیابی (پیکسل)
قبلا بایر بوده، الان کشاورزی است	۱۲۵
بدون تغییرات	۲۲۴
قبلا کشاورزی بوده، الان نیست	۱۱۴

۵- جمع بندی و نتیجه گیری

در این مقاله از الگوریتم های طبقه بندی کننده SVM و شبکه عصبی مصنوعی برای دو روش متفاوت و در کنار آن با بهره گیری از روش ترکیب رنگها در روش پیشنهادی و روش تفاضلی در روش معمولی جهت شناسایی تغییرات ایجاد شده در تصاویر لندست استفاده شده است. تلفیق الگوریتم های طبقه بندی و روشهای


ترکیب رنگ با روشهای شناسایی تغییرات و روشهای پیشرفته سنجش از دور و ... می‌تواند بعنوان راهکاری مناسب در شناسایی تغییرات، مورد استفاده قرار گیرد. برای تفهیم و مشاهده بهتر نتایج سعی شده است که نتایج حاصل در قالب نمودارهای استوانه ای نمایش داده شود تا مقایسه نتایج ، بصورت بصری نیز امکان پذیر باشد. دقت کلی حاصل از نتایج در شکل ۸ قابل مشاهده است.



شکل ۸- مقایسه دقت کلی حاصل شده از مدل‌های مختلف برای نمونه ها

همانطور که از نتایج مشهود است مشاهده می‌شود که دقت کلی حاصل از شناسایی تغییرات مدل پیشنهادی از نتایج حاصل شده در روش معمولی بهتر است. دلیل اصلی آن را می‌توان حذف خطاهایی دانست که در روش معمولی ظاهر می‌گردند بطور مثال می‌توان خطای انتخاب نمونه آموزشی از هر دو تصویر و یا خطای طبقه‌بندی تصاویر بصورت مجزا را نام برد. در حالی که در این مدل نمونه آموزشی فقط از یک تصویر و مقایسه مجزایی میان تصاویر صورت نگرفته است. البته دقت حاصل شده در روشهای نظارت شده به پارامترهای دیگری از جمله دقت داده های

آموزشی و ارزیابی نیز وابسته می باشد که می توان این را بعنوان یکی از معایب روشهای نظارت شده عنوان کرد. در ادامه ضریب کاپای حاصل از نتایج نیز باهم مقایسه شده است. لازم به ذکر است که ضریب کاپا این مزیت را نسبت به دقت کلی دارد که از مقادیر غیر قطری ماتریس خطا نیز برای محاسبه دقت استفاده می کند و بنابراین دقت بهتری دارد. معمولاً اینگونه عنوان می شود که دقت کلی یک برآورد خوشبینانه است در حالی که ضریب کاپا برآوردی بدبینانه بوده و دقت را کمتر از مقدار واقعی بیان می کند. نتایج حاصل در شکل ۹ قابل مشاهده است:



شکل ۹- مقایسه ضریب کاپا حاصل شده از مدل‌های مختلف برای نمونه‌ها

۲- در حالتی که در مدل پیشنهادی از تصویر هم مرجع شده چندزمانه برای کشف تغییرات استفاده شد دقت بهتری حاصل شد اگرچه در این حالت از نمونه‌های آموزشی فقط در یک تصویر استفاده شده است و این خود مزیتی جهت کاهش اطلاعات استفاده شده نسبت به مدل اول است.

۳- روش ترکیب رنگها و تلفیق آن با روشهای طبقه بندی جهت شناسایی تغییرات ایده بسیار ساده و در عین حال بسیار کارآمدی می‌باشد که کمتر از آن استفاده شده است و استفاده از آن نتایج مطلوبی را بدنبال خواهد داش

همانند نتایج حاصل برای دقت کلی، مشاهده می‌شود که ضریب کاپای بدست آمده مدل پیشنهادی بطور میانگین از نتایج حاصل شده در روش معمول بهتر است. در حالت کلی دقت حاصل شده در روش پیشنهادی بطور میانگین ۲،۵ تا ۳ درصد بر روش معمولی برتری دارد. از جمله نتایج حاصل شده در استفاده از این الگوریتم می‌توان موارد زیر را نام برد:

۱- چنانچه داده‌های نمونه در این الگوریتم بصورت دقیق نمونه برداری شوند دقت آن در کشف تغییرات نسبت به روشهای رایج که درمدل معمولی مطرح شد بمراتب بیشتر خواهد بود.

مراجع

- [1] Kuo, B. & Landgrebe, D., "Nonparametric Weighted Feature Extraction for Classification", IEEE Transactions on Geoscience and Remote Sensing, vol.42, pp.1096-1105, 2004.
- [2] T.Kavzoglu, I.Colkesen, 2009, A kernel functions analysis for support vector machines for land cover classification, International Journal of Applied Earth Observation and Geoinformation, 352-359.
- [3] Hall, O., 2003. A Multiscale Object-Specific Approach to Digital Change Detection. In: International Journal of Applied Earth Observation and Geoinformation, vol.4, pp.311-327
- [4] Bach F R. Consistency of the group Lasso and multiple kernels learning [J]. The Journal of Machine Learning Research, 2008, 9(6):1179-1225.
- [5] Mahesh Pal, 2005, Multiclass Approaches for Support Vector Machine Based Land Cover Classification, MapIndia 2005 conference, 1-16.
- [6] Luis Gómez-Chova, Gustavo Camps-Valls, Jordi Muñoz-Marí, and Javier Calpe, 2007, Semisupervised Image Classification with Laplacian Support Vector Machines, IEEE Geoscience and Remote Sensing Letters, vol.XX, no. Y, 1-5.

- [7] Burges, C., 1998. A tutorial on support vector machines for pattern recognition. In: Data mining and knowledge discovery, vol. 2, pp. 121–167.
- [8] Mo, D., Lin, H., Li, J., Sun, H., Zhang, Z., Xiong, Y., 2008. A SVM-Based Change Detection Method from Bi-Temporal Remote Sensing Images in Forest Area. In: First International Workshop on Knowledge Discovery and Data Mining, pp. 209-212.
- [9] Zhigao, Y., Qianqing, Q., Qifeng, Z., 2006. Change Detection in High Spatial Resolution Images Based on Support Vector Machine. In: IEEE International Symposium on Geoscience and Remote Sensing, pp. 225-228.
- [10] Baofeng Guo, Steve R. Gunn, R. I. Damper, and James D. B. Nelson, 2008, Customizing Kernel Functions for SVM-Based Hyperspectral Image Classification, IEEE Transactions On Image Processing, vol. 17, no. 4, 622-629.
- [11] Malila, W.A.: Change vector analysis: An approach for detecting forest changes with Landsat. In: LARS Symposia, p. 385 (1980)
- [12] Tarabalka, Y., Benediktsson, J. A., & Chanussot, J., "Spectral-Spatial Classification of Hyperspectral Imagery Based on Partitional Clustering Techniques", IEEE Transactions on Geoscience and Remote Sensing, vol. 47, pp. 2973-2987, 2009.
- [13] Li, X., and Yeh, A. G. O., "Principal component analysis of stacked multitemporal images for the monitoring of rapid urban expansion in the Pearl River Delta". International Journal of Remote Sensing, 19, 1501-1518, 1998.
- [14] Lu, D., Mausel, P., Brondizio, E., & Moran, E., Change detection techniques", International Journal of Remote Sensing, 25, 2365–2407, 2004.
- [15] Weismiller, R. A., Kristof, S. J., Scholz, D. K., Anuta, P. E., and Momin, S. A., "Change detection in coastal zone environment." Photogrammetric Engineering and Remote Sensing, 43, 1533-1539, 1977.
- [16] M. Linderman, J. Liu, J. QI, L. AN, Z. Ouyang, J. Yang and Y. Tan, 2003, using artificial neural networks to map the spatial distribution of understory bamboo from remote sensing data, 1692-1693