



بررسی کارایی استفاده از تصاویر ماهواره‌ای و شبکه‌های عصبی مصنوعی در تخمین درصد پوشش گیاهی در مناطق خشک

علی اکبر متکان^۱، روشنگر درویش زاده^۲، امین حسینی اصل^۳، محسن ابراهیمی خوسفی^۴

چکیده

پوشش گیاهی یکی از مهم‌ترین اجزای اکوسیستم‌هاست و دانستن درصد پوشش گیاهی سطحی برای بررسی میزان فرسایش خاک، شدت خشکسالی، مطالعات زیست محیطی، منابع طبیعی و غیره بسیار ضروری است. هدف از این تحقیق محاسبه درصد پوشش گیاهی با استفاده از تصاویر ماهواره‌ای و شبکه‌های عصبی مصنوعی (پرسپترون چندلایه) می‌باشد. بدین منظور از تصویر ماهواره‌ای ALOS مربوط به تاریخ ۲۷ تیر ماه ۱۳۸۸ و شبکه‌های عصبی مصنوعی پرسپترون چندلایه برای تخمین درصد پوشش گیاهی استفاده شده است. برای انتخاب شبکه‌ی بهینه، از دو نوع تابع انتقال، ۱۲ تابع آموزشی مختلف، تعداد نرون مخفی متغیر بین یک تا شش و شش ترکیب مختلف ورودی متشکل از باندهای مختلف تصویر ماهواره‌ای استفاده شد. برای معرفی خروجی مطلوب به شبکه، درصد پوشش گیاهی در ۵۲ پلات ۵۰ در ۵۰ متر با مطالعه‌ی میدانی اندازه‌گیری شد. در ابتدا، تعداد ۳۰ داده به عنوان داده آموزشی به شبکه معرفی و تعداد ۲۲ داده به عنوان تست در نظر گرفته شد و با استفاده از مدل رگرسیون خطی میزان همبستگی بین داده‌های میدانی اندازه‌گیری شده و مقادیر تخمینی با استفاده از شبکه‌های تشکیل شده، محاسبه شد. سپس برای بررسی تاثیر انتخاب تصادفی بودن داده‌های آموزشی و تست، تعداد ۳۵ داده به عنوان داده‌ی آموزشی و ۱۷ داده به عنوان داده‌ی تست انتخاب گردید. برای حذف خطای احتمالی ناشی از تقسیم تصادفی داده‌های آموزشی و تست، از روش CrossValidation نیز استفاده گردید. نتایج نشان داد که به‌طور کلی شبکه‌های عصبی توانایی تخمین درصد پوشش گیاهی را با دقت مناسبی دارند ($R^2 > 0.74$ و $RMSE < 0.02$).

کلمات کلیدی:

تصویر ALOS، درصد پوشش گیاهی، مناطق خشک، شبکه‌ی عصبی مصنوعی

۱. دانشیار، تهران- اوین- دانشگاه شهید بهشتی- دانشکده علوم زمین- گروه سنجش از دور و GIS
۲. مسئول مکاتبات، استادیار، تهران- اوین- دانشگاه شهید بهشتی- دانشکده علوم زمین- گروه سنجش از دور و GIS، r_darvish@sbu.ac.ir
۳. مربی، تهران- اوین دانشگاه شهید بهشتی- دانشکده علوم زمین- گروه سنجش از دور و GIS
۴. کارشناس ارشد سنجش از دور و GIS، تهران- اوین دانشگاه شهید بهشتی- دانشکده علوم زمین- گروه سنجش از دور و GIS.

مقدمه

درصد پوشش گیاهی^۱ که یکی از پارامترهای مهم در بررسی کمی گیاهان سطح زمین به شمار می‌رود، عبارت است از نسبت سطح پوشیده شده از گیاه به سطح کل که به صورت درصد بیان می‌شود (Zhang et al., 2003). مقدار پوشش گیاهی معمولاً به دو صورت بیان می‌شود: تراکم سطحی^۲ که بیانگر میزان مساحت پوشیده شده از گیاه در واحد سطح و تراکم عمودی^۳ که بیانگر تعداد لایه‌های برگ در مناطق پوشیده از گیاه می‌باشد و میزان فتوسنتز و تبخیر و تعرق گیاهان را کنترل می‌کنند (Gutman and Ignatov., 1998).

درصد پوشش گیاهی یکی از مهم‌ترین فاکتورهای تاثیرگذار در فرسایش خاک محسوب می‌شود. هر چه درصد پوشش گیاهی افزایش یابد، میزان فرسایش خاک کاهش می‌یابد. (Elwell and Stocking., 1976) پوشش گیاهی از طریق حفظ خاک در مقابل ضربات قطره‌های باران، افزایش میزان نفوذپذیری آب به خاک، کاهش سرعت جریان رواناب سطحی و بهبود خواص فیزیکی، شیمیایی و بیولوژیکی خاک، باعث کاهش فرسایش می‌شود (Baver., 1956). هم‌چنین، نوع گیاه پوششی زمین در طول زمستان به‌خصوص در زمین‌های کشاورزی، به شدت بر میزان فرسایش خاک و کیفیت آب تاثیر می‌گذارد (Dabney et al., 2001).

تعیین درصد پوشش گیاهی در بررسی پدیده‌ی خشکسالی، (Ghulam., 2006)، خطر آتش‌سوزی (Burgan et al., 1996) و سایر پدیده‌های موثر بر سطح زمین و جوامع بشری نیز ضروری است. تغییر پوشش گیاهی به صورت مستقیم بر تعادل انرژی از طریق تاثیر بر تعرق گیاهان، آلودگی سطح، گسیل‌مندی و ناهمواری سطحی تاثیرگذار است. (Aman et al., 1992).

تعیین درصد پوشش گیاهی با استفاده از روش‌های سنتی برداشت نه تنها دید کاملی از پوشش گیاهی کل منطقه ارائه نمی‌دهد بلکه باعث صرف زمان و هزینه‌ی زیاد می‌شود. هم‌چنین خطاهای انسانی در تعیین درصد پوشش گیاهی به روش‌های سنتی می‌تواند زیاد باشد. امروزه تصاویر ماهواره‌ای یک تصویر جامع از نظر زمان و مکان از سطح زمین و پوشش‌های مختلف آن فراهم می‌کند. از این‌رو استفاده از این تصاویر می‌تواند برای کاهش زمان و هزینه و افزایش دقت، استفاده شود. بدین منظور تا کنون مطالعات متعددی برای تعیین درصد پوشش گیاهی با استفاده از تصاویر ماهواره‌ای صورت گرفته است.

یکی از روش‌های رایج محاسبه‌ی درصد پوشش گیاهی با استفاده از تصاویر ماهواره‌ای بهره‌گیری از شاخص‌های گیاهی است و تا کنون شاخص‌های متعددی ارائه شده است که بسته به نوع منطقه نتایج متفاوتی را

1 . Fraction of Vegetation (Fv)
2 . Horizontal density
3 . Vertical density

نشان داده‌اند. Ebrahimi در سال ۲۰۱۰ در تحقیقی که در یکی از مناطق خشک مرکزی ایران انجام داد به این نتیجه رسید که از بین ۱۷ شاخص رایج، شاخص MSAVI با بالاترین دقت ($R^2=0.64$) می‌تواند برای تخمین درصد پوشش گیاهی استفاده شود. تحقیق دیگری که توسط Baugh و Groeneveld در سال ۲۰۰۹ در یکی از مناطق خشک ایالت کلرادو آمریکا با استفاده از تصاویر TM انجام گرفت نشان داد که می‌توان درصد پوشش گیاهی را با استفاده از شاخص NDVI^۱ و سری زمانی تصاویر با دقت $R^2=0.77$ تخمین زد. در تحقیق دیگری که Darvishzadeh و همکاران در سال ۲۰۰۸ با استفاده از تصاویر ابرطیفی انجام دادند به این نتیجه رسیدند که شاخص SAVI^۲ دارای بالاترین میزان همبستگی با شاخص سطح برگ^۳ (LAI) ($R^2=0.77$) می‌باشد. نتایج تحقیق Lawrence و Ripple نیز که در سال ۱۹۹۷ با استفاده از تصاویر ماهواره‌ای TM صورت گرفت نشان داد شاخص NDVI می‌تواند با دقت $R^2=0.65$ برای تخمین درصد پوشش گیاهی استفاده شود.


یکی دیگر از روش‌هایی که برای محاسبه درصد پوشش گیاهی استفاده می‌شود. تجزیه‌ی پیکسل‌های آمیخته است (Congh.,2005; Elmore et al.,2000). محدودیت این روش در مناطق خشک این است که نیاز به انتخاب پیکسل‌های خالص^۴ دارد و در این مناطق به دلیل پوشش گیاهی کم امکان انتخاب آن برای تخمین درصد پوشش گیاهی وجود ندارد.

یکی از روش‌های استخراج اطلاعات از تصاویر ماهواره‌ای استفاده از شبکه‌های عصبی مصنوعی است. Jang و همکاران در سال ۲۰۰۶ به منظور تشخیص ابر، Nemmour و Chibani در سال ۲۰۰۶ برای بررسی تغییرات در طول زمان و Carpenter و همکاران در سال ۱۹۹۹ برای تهیه نقشه‌ی پوشش گیاهی از شبکه‌ی عصبی مصنوعی استفاده نمودند. تا کنون مطالعه‌ای در زمینه‌ی محاسبه درصد پوشش گیاهی با استفاده از شبکه‌های عصبی مصنوعی و تصاویر ماهواره‌ای انجام نشده است. از این‌رو هدف از انجام این تحقیق تخمین درصد پوشش گیاهی با استفاده از روش مذکور و مقایسه با مطالعات انجام شده با استفاده از شاخص‌های گیاهی است.

شبکه عصبی مصنوعی مدلی ریاضی است که توانایی مدل سازی و ایجاد روابط غیرخطی را برای درونیابی دارد. این مدل با ساختار پرسپترون^۵ چند لایه به‌طور کلی از سه لایه و هر لایه از تعدادی واحد پردازشگر بنام نرون^۶ (سلول، واحد و گره) تشکیل شده است (شکل ۱). اولین لایه‌ی هر شبکه را لایه‌ی ورودی گویند که در آن

- 1 . Normalized Difference Vegetation Index
- 2 . Soil Adjusted Vegetation Index
- 3 . Leaf Area Index
- 4 . Endmember
- 5 - Preceptron
- 6 - Neuron

بردار داده‌های ورودی مورد نظر قرار می‌گیرند و در این لایه، هیچ گونه پردازشی انجام نخواهد شد. لایه‌ی آخر هر شبکه لایه‌ی خروجی است که در آن بردارهای خروجی نگاشت استقرار می‌یابند. همچنین هر پرسپترون از تعدادی لایه‌ی میانی که لایه‌های پنهان نامیده می‌شوند، تشکیل شده است. تعداد این لایه‌ها و تعداد نرون‌ها در هر لایه، توسط طراح شبکه و طی فرآیند آزمون و خطا به دست می‌آید. به طور معمول، نرون‌های هر لایه به کلیه‌ی نرون‌های لایه‌ی مجاور از طریق یک رابطه جهت دار مرتبط هستند. اطلاعات بین نرون‌ها از طریق این اتصالات منتقل می‌شوند. هر یک از این اتصالات دارای مشخصه‌ای (وزن) مختص به خود هستند که در اطلاعات انتقال یافته از یک نرون به نرون دیگر ضرب می‌گردد (Menhaj., 2005).




شکل ۱ - نمای کلی شبکه‌ی عصبی با ساختار پرسپترون چند لایه (Menhaj., 2005).

مواد و روش‌ها

محدوده‌ی مورد مطالعه

ناحیه‌ی مطالعاتی از نظر جغرافیایی بین عرض‌های $25^{\circ} 31' 31''$ و $45^{\circ} 31' 15''$ شمالی و طول‌های $46^{\circ} 45' 55''$ و $56^{\circ} 03' 22''$ شرقی واقع شده است. این منطقه در استان یزد، در بخش جنوبی شهرستان بافق در فاصله حدود ۲۵ کیلومتری شهر بافق از سمت شرق، در حد فاصل مرز استان یزد و کرمان قرار گرفته است (شکل شماره ۲).



شکل ۲- موقعیت محدوده مورد مطالعه


مساحت کل محدوده شیطور برابر ۴۱۶ کیلومترمربع می‌باشد. بلندترین نقطه دارای ارتفاع ۲۹۸۹ متر و پست‌ترین آن ۱۸۴۴ متر می‌باشد. متوسط بارندگی محدوده مورد مطالعه ۱۷۱ میلیمتر، دمای متوسط سالانه ۱۴/۱ درجه سانتی‌گراد و اقلیم منطقه به روش دومارتن اصلاح شده از نوع خشک سرد است و جزو مناطق خشک مرکزی ایران محسوب می‌شود. پوشش گیاهی حوزه از چهار تیپ گیاهی اصلی شامل درمنه زار دشتی، درمنه زارکوهی، هزار خار دشتی و گون تشکیل شده است.

داده‌های مورد استفاده

برای انجام تحقیق حاضر، از تصاویر سنجنده AVNIR2^۱ ماهواره ALOS مربوط به تاریخ ۲۷ تیرماه ۱۳۸۸ (با قدرت تفکیک مکانی ۱۰ متر و ۴ باند طیفی)، نقشه‌های توپوگرافی با مقیاس ۱:۲۵۰۰۰ جهت زمین مرجع کردن تصاویر و هم‌چنین درصد پوشش گیاهی اندازه‌گیری شده در مطالعات میدانی (تیر ماه ۸۸) برای ارزیابی نتایج حاصل از شبکه‌های مصنوعی استفاده شده است.

روش نمونه برداری

برای تعیین درصد پوشش گیاهی با روش میدانی، ابتدا تعداد ۷۰ نقطه به‌طور تصادفی با توجه به مینیمم و ماکزیمم طول و عرض جغرافیایی منطقه‌ی مورد مطالعه انتخاب و سپس ۵۲ نقطه از این نقاط با استفاده از دستگاه GPS دستی برداشت شدند. موقعیت نقاط برداشتی در شکل شماره (۳) آمده است.



شکل ۳- پراکنش نقاط برداشتی برای محاسبه‌ی درصد پوشش گیاهی به روش میدانی

با توجه به قدرت تفکیک تصویر مورد استفاده (۱۰ متر) و به‌منظور حذف خطای ناشی از دقت GPS، ابعاد پلات‌های برداشت میدانی با ضریب پنج برابر اندازه‌ی پیکسل و به ابعاد ۵۰ متر در ۵۰ متر انتخاب شدند، سپس مختصات نقاط تصادفی تعیین شده برای برداشت زمینی، به عنوان مختصات مرکز پلات در نظر گرفته و درصد پوشش گیاهی در هر پلات اندازه‌گیری شد.

برای محاسبه‌ی درصد پوشش گیاهی در هر پلات ۵۰ در ۵۰ متر از زیر پلات‌های یک متر مربعی استفاده شد (Darvishzadeh et al., 2008). بدین گونه که با ایستادن در مرکز پلات، به‌طور تصادفی و با پرتاب سنگ موقعیت زیر پلات یک متر مربعی در محیط پلات ۵۰ در ۵۰ متر انتخاب و محل برخورد سنگ به زمین، محل قرار گرفتن گوشه پایین پلات در نظر گرفته شد و درصد پوشش گیاهی برای این زیر پلات با توجه به مساحت پوشیده شده توسط

گیاه تعیین شد. در هر پلات ۵۰ در ۵۰ متر با توجه به میزان همگنی، تعداد شش زیر پلات یک متر مربعی برداشت شد که در نهایت، میانگین زیر پلات‌های برداشتی یک مترمربعی، به عنوان متوسط درصد پوشش گیاهی در پلات ۵۰ در ۵۰ متر در نظر گرفته شد. جدول شماره (۱) بیانگر مشخصات داده‌های برداشت شده‌ی زمینی است.

جدول ۱- مشخصات پلات‌های برداشت شده‌ی زمینی

پلات	میانگین	انحراف معیار	پلات	میانگین	انحراف معیار	پلات	میانگین	انحراف معیار
۱	۳۰/۸۳	۵/۸۵	۱۹	۱۷/۵	۶/۸۹	۳۷	۲۳/۳۳	۵/۱۶
۲	۲۴/۱۷	۷/۳۶	۲۰	۱۸/۳۳	۶/۰۶	۳۸	۳۳/۳۳	۵/۱۶
۳	۲۰/۸۳	۵/۸۵	۲۱	۲۳/۳۳	۸/۱۶	۳۹	۳۷/۵۰	۶/۱۲
۴	۲۲/۵۰	۵/۲۴	۲۲	۲۲/۵۰	۶/۸۹	۴۰	۲۸/۳۳	۶/۰۶
۵	۲۵	۴/۴۷	۲۳	۲۴/۱۷	۵/۸۵	۴۱	۲۲/۵	۶/۸۹
۶	۳۰	۷/۰۷	۲۴	۳۳/۳۳	۵/۱۶	۴۲	۲۹/۱۷	۷/۳۶
۷	۲۵/۸۳	۳/۷۶	۲۵	۲۱/۶۷	۶/۰۶	۴۳	۲۲/۵	۵/۲۴
۸	۲۸/۳۳	۱۰/۳۳	۲۶	۲۱/۵۶	۵/۱۶	۴۴	۲۵/۸۳	۸/۶۱
۹	۲۰	۵/۴۸	۲۷	۲۶/۶۷	۸/۱۶	۴۵	۲۲/۵	۵/۲۴
۱۰	۲۶/۶۷	۸/۷۶	۲۸	۲۴/۱۷	۵/۸۵	۴۶	۲۹/۱۷	۷/۳۶
۱۱	۳۰	۷/۰۷	۲۹	۲۷/۵۰	۸/۲۲	۴۷	۳۰/۸۳	۳/۷۶
۱۲	۲۳/۳۳	۶/۰۶	۳۰	۳۴/۱۷	۵/۸۵	۴۸	۲۴/۱۷	۶/۶۵
۱۳	۲۶/۶۷	۹/۳۱	۳۱	۲۱/۶۷	۹/۳۱	۴۹	۱۹/۱۷	۳/۷۶
۱۴	۲۵/۸۳	۶۵۰۶	۳۲	۲۱/۶۷	۶/۰۶	۵۰	۱۶/۶۷	۵/۱۶
۱۵	۲۶/۶۷	۵/۱۶	۳۳	۲۲/۵۰	۵/۲۴	۵۱	۳۱/۶۷	۶/۰۶
۱۶	۲۳/۳۳	۵/۱۶	۳۴	۳۰/۸۳	۵/۸۵	۵۲	۴۲/۵۰	۵/۲۲
۱۷	۲۷/۵۰	۵/۲۴	۳۵	۲۵/۸۳	۳/۷۶	میانگین ۶ زیر پلات بیانگر درصد پوشش در هر پلات می‌باشد.		
۱۸	۱۸/۳۳	۶/۰۶	۳۶	۲۱/۶۷	۸/۱۶			

لازم به ذکر است که موقعیت شش پلات ۵۰ متر در ۵۰ متر نیز از خاک‌های لخت موجود در منطقه (معادل بیش از ۳۰۰ پیکسل) برای محاسبه‌ی پارامترهای خط خاک و حذف اثرات ناشی از خاک لخت بر بازتاب ثبت شده توسط سنجنده تعیین گردید.

پیش پردازش تصاویر

برای محاسبه‌ی شاخص‌های گیاهی نیاز به میزان بازتاب^۱ واقعی زمینی هر پیکسل می‌باشد، بنابراین عدد رقومی ثبت شده توسط سنجنده، ابتدا به رادیانس^۲ تبدیل شد. به منظور محاسبه‌ی رادیانس برای تصاویر سنجنده AVNIR از رابطه‌ی زیر استفاده می‌شود:

$$L_i = Gain' DN_i \quad i=1-4 \quad \text{رابطه (۱)}$$

که L_i رادیانس در باند i ، $Gain$ عدد ثابتی است و مقدار آن برای هر باند تعریف شده است و DN_i عدد رقومی ثبت شده توسط سنجنده می‌باشد. جهت دستیابی به بازتاب واقعی زمینی و تصحیح اتمسفری تصاویر، از الگوریتم FLAASH در نرم افزار ENVI4.7 استفاده شد. پارامترهای مورد نیاز تصحیح تصاویر AVNIR و مقادیر تنظیم شده در جدول شماره (۲) آمده است.

جدول ۲- پارامترهای تنظیم شده برای تصحیح اتمسفری تصویر مورد استفاده

مقدار تنظیم شده	پارامتر مورد نیاز	مقدار تنظیم شده	پارامتر مورد نیاز
۲۰۰۹/۷/۱۸	تاریخ تهیه‌ی تصویر	۳۱/۸۱	عرض جغرافیایی مرکز تصویر
۲	متوسط ارتفاع زمینی (کیلومتر)	۵۶/۱۰	طول جغرافیایی مرکز تصویر
روستایی	مدل آئروسول	۶۹۲	ارتفاع ماهواره (کیلومتر)
خیر	بازیابی آئروسول و آب	تابستان عرض‌های میانی	مدل اتمسفری

برای تصحیح هندسی تصاویر، تعداد ۱۷ نقطه به صورت پراکنده در تمام تصویر (۹۴۲ کیلومتر مربع) و از روی نقشه‌های ۱/۲۵۰۰۰ انتخاب شد، سپس با استفاده از معادلات پلی نومیال درجه دو با دقت ۰/۶۵ پیکسل و روش نمونه برداری نزدیکترین همسایه، بازنویسی^۳ شد.

با توجه به این که ابعاد پلات‌های برداشتی ۵۰ متر و قدرت تفکیک مکانی تصاویر مورد استفاده ۱۰ متر می‌باشد، بنابراین در نهایت برای مقایسه‌ی برداشت‌های میدانی و مقادیر بازتاب باندهای مختلف، فیلتر میانگین پنج در پنج بر روی تصویر اعمال گردید.

محاسبه‌ی درصد پوشش گیاهی با استفاده از شبکه‌های عصبی مصنوعی

در تحقیق حاضر برای تخمین درصد پوشش گیاهی با استفاده از الگوریتم‌های مختلف شبکه‌های عصبی و

1 . Reflectance
2 . Radiance
3 . Resample

بر اساس داده‌های برداشت شده‌ی زمینی، از شبکه‌ی پرسپترون چند لایه استفاده شده است. قبل از آموزش شبکه لازم است تا با نرمالیزه کردن، مقدار ورودی‌ها و خروجی‌های هدف در محدوده معینی قرار گیرد. بنابراین مقادیر تمامی ورودی‌ها و خروجی‌های هدف در محدوده (۱-۱) قرار گرفت. در شبکه‌ها توابع انتقال مختلف معرفی می‌شوند. توانایی محاسبه‌ی مشتقات تابع انتقالی در الگوی آموزشی پس‌انتشار خطا اهمیت دارد. توابع لوگ‌سیگموئید^۱ و تانژانت سیگموئید^۲ معمول‌ترین توابع انتقال در آموزش پس‌انتشار هستند که معمولاً در شبکه‌های چند لایه کاربرد دارند (Menhaj., 2005). تابع لوگ سیگموئید خروجی‌های بین صفر و یک در محدوده مقادیر مثبت و منفی ایجاد می‌کند. هم‌چنین در شرایطی که در داده‌های ورودی مقدار صفر وجود داشته باشد برای بهبود کارایی می‌توان از تابع تانژانت سیگموئید نیز استفاده کرد.

از آن‌جا که دو تابع فوق‌الذکر به دلیل پیوستگی و مشتق پذیر بودن بیشترین کاربرد را در الگوریتم پس‌انتشار خطا دارند (Menhaj., 2005). از این‌رو در تحقیق حاضر کلیه‌ی محاسبات یک‌بار با تابع Logsig و یک‌بار با تابع Tansig انجام شد.

افزایش تعداد واحدها در لایه‌ی میانی همواره باعث کاهش خطای آموزش می‌شود ولی ممکن است باعث افزایش خطای تست شود که به این امر تطبیق بیش از حد گفته می‌شود یعنی این‌که نمونه‌های آموزشی به خوبی آموزش دیده‌اند ولی شبکه تابع مورد نظر را به خوبی آموزش نداده است. این امر زمانی که نویز در میان نمونه‌های آموزشی وجود داشته باشد بیشتر رخ می‌دهد (Menhaj., 2005). یعنی باید در افزایش تعداد نرون‌ها در لایه میانی دقت لازم را انجام داد تا باعث افزایش خطا نشود. در این تحقیق، به ازای هر تابع انتقال، تعداد نرون مخفی متغیر ۱، ۲، ۳، ۴، ۵ و ۶ انتخاب و به ازای هر کدام، کلیه‌ی محاسبات انجام شد و تاثیر تغییر تعداد نرون مخفی مورد بررسی قرار گرفت.

یکی از مراحل انجام محاسبات با استفاده از شبکه‌های عصبی مصنوعی انتخاب تابعی است که برای آموزش شبکه استفاده می‌شود. در این تحقیق از تمامی توابع آموزشی پس‌انتشار خطای موجود در نرم افزار MATLAB – صرف‌نظر از معایب هر کدام – استفاده شد که عبارتند از کاهش شیب با سرعت آموزش ثابت، کاهش شیب با مومنتوم با سرعت آموزش ثابت، کاهش شیب با سرعت آموزش متغیر، کاهش شیب با مومنتوم با سرعت آموزش متغیر، پس‌انتشار ارتجاعی، شیب توام CGF، شیب توام CGP، شیب توام CGB، شیب توام

SCG، شبه نیوتن BFGS، شبه نیوتن OSS و الگوریتم LM.

استفاده از شبکه‌های عصبی مصنوعی این امکان را فراهم می‌آورد تا با تلفیق پارامترهای موثر متعدد بتوان با دقت مناسب‌تری نسبت به سایر روش‌های محاسباتی به تخمین مقدار خروجی مورد نظر پرداخت. در تحقیق حاضر از تصویر ماهواره‌ای ALOS با تعداد چهار باند استفاده گردیده است. برای تعیین مناسب‌ترین الگوریتم شبکه‌های عصبی مصنوعی، ورودی‌های متغیر زیر به شبکه معرفی و به ازای هر کدام تمامی مدل‌ها دوباره اجرا شد:

۱- یک ورودی شامل تنها باند آبی

۲- یک ورودی شامل تنها باند سبز

۳- یک ورودی شامل تنها باند قرمز

۴- یک ورودی شامل تنها باند مادون قرمز نزدیک

۵- دو ورودی شامل باندهای قرمز و مادون قرمز نزدیک

۶- چهار ورودی شامل باندهای آبی، سبز، قرمز و مادون قرمز نزدیک

پس از تعیین ورودی‌های مطلوب، باید تعداد تکرار نیز در هر شبکه تعیین شود. اگر تعداد تکرار کافی نباشد ممکن است شبکه به خوبی آموزش نبیند و نتیجه‌ی مطلوب حاصل نشود. از طرفی، افزایش تکرار ممکن است باعث آموزش بیش از حد شبکه شود و این امر می‌تواند باعث حصول نتایج غیر منطقی شود. بدین صورت که با آموزش بیش از حد^۱، خطای داده‌های آموزشی کاهش می‌یابد ولی هنگامی که داده‌های تست وارد شبکه‌ی شبیه سازی شده می‌شوند، نتایج قابل قبولی حاصل نمی‌شود (Menhaj.,2005). بنابراین باید تعداد تکرار به گونه‌ای انتخاب شود که دقت حاصل از داده‌های آموزشی و تست بهینه باشد. بدین منظور، در تحقیق حاضر، تعداد تکرار ۲۰۰، ۴۰۰، ۶۰۰، ۸۰۰، ۱۰۰۰، ۱۲۰۰ و ۱۴۰۰ برای هر شبکه در نظر گرفته و در نهایت تعداد تکرار بهینه انتخاب شد.

در تمامی مراحل فوق، با تغییر هر متغیر (نوع تابع انتقال، تابع آموزشی، تعداد نرون مخفی و تعداد ورودی و تعداد تکرار) مقدار R^2 و RMSE^۲ به سه طریق محاسبه شد: (۱) داده‌ی آموزشی و ۲۲ داده‌ی تست، (۲) ۳۵ داده‌ی آموزشی و ۱۷ داده‌ی تست، (۳) روش CrossValidation اساس این روش به این صورت است که در هر مرحله بر اساس $n-1$ عدد داده‌ی برداشت شده و مقادیر متناظر شبیه‌سازی شده در شبکه عصبی، یک معادله

1 . Overfit

2 . Root Mean Square Error

رگرسیون محاسبه می‌شود و بر اساس آن معادله، مقدار درصد پوشش گیاهی برای یک نقطه‌ای که وارد مدل نشده است محاسبه می‌گردد. این عمل به اندازه‌ی n بار تکرار می‌شود تا مقادیر تخمینی برای تمام نقاط محاسبه گردد. در نهایت، بر اساس مقادیر واقعی و مقادیر تخمین زده شده، میزان R^2 و RMSE برای هر شبکه محاسبه می‌شود (Geladi and Kowalski., 1986).

نتایج

محاسبه‌ی درصد پوشش گیاهی با استفاده از ۳۰ داده‌ی آموزشی و ۲۲ داده‌ی تست

جدول شماره (۳) نتایج مربوط به توابع آموزشی و تعداد نرون مخفی‌ای که به ازای ورودی‌های مختلف و با استفاده از ۳۰ داده‌ی آموزشی و ۲۲ داده‌ی تست که بیشترین دقت را داشته‌اند، نشان می‌دهد. در این جدول، به ازای هر یک از ترکیب‌های ورودی، بهترین مدلی که هم در داده‌های تست و هم در داده‌های آموزشی بیشترین همبستگی با داده‌های زمینی و کمترین میزان RMSE را داشت، آمده است.

جدول ۳- نتایج شبکه عصبی با ۳۰ داده‌ی آموزشی و ۲۲ داده‌ی تست

ورودی	تابع انتقال	تعداد نرون مخفی	تابع آموزشی	R2 آموزشی	RMSE آموزشی (درصد)	R2 تست	RMSE تست (درصد)
B4.B3.B2.B1	LogSig	۱	lm	۰/۷۹	۱/۲	۰/۸۶	۱/۱
B4.B3		۳	oss	۰/۷۵	۱/۳	۰/۷۸	۱/۴
B4		۱	cgp	۰/۶۳	۱/۳	۰/۷۹	۱/۵
B3		۲	cgb	۰/۶۳	۱/۲	۰/۸۲	۱/۸
B1		۲	cgp	۰/۷۳	۱/۴	۰/۴۳	۲/۵
B2		۴	cgp	۰/۴۵	۱/۷	۰/۳۵	۱/۵
B4.B3.B2.B1	Tansig	۱	lm	۰/۷۸	۱/۲	۰/۸۶	۱/۱
B4.B3		۳	oss	۰/۷۶	۱/۴	۰/۷۷	۱/۳
B4		۱	cgp	۰/۶۳	۱/۳	۰/۷۸	۱/۴
B3		۲	cgb	۰/۶۲	۱/۲	۰/۸۱	۱/۹
B1		۲	cgp	۰/۷۳	۱/۲	۰/۴۶	۲/۸
B2		۴	cgp	۰/۴۶	۱/۶	۰/۳۲	۱/۹

جدول فوق نشان می‌دهد که بالاترین میزان R^2 و کمترین میزان RMSE مربوط به حالتی است که از چهار باند

تصویر به عنوان ورودی استفاده شود.

در حالتی که از باندهای قرمز و مادون قرمز نزدیک، به عنوان ورودی استفاده شده است دقت نتایج حاصل شده نسبت به حالت اول کاهش یافته است. این امر به دلیل کاهش تعداد ورودی‌ها است. اگرچه نتایج آزمون t نشان داد که تفاوت معناداری بین نتایج حاصل شده وجود ندارد ($P\text{-value} > 0.05$).

با توجه به جدول شماره (۳)، در حالتی که تنها از یک ورودی استفاده شده است، کارایی باندهای مادون قرمز نزدیک و قرمز بیشتر است و این به دلیل خصوصیت طیفی گیاهان در محدوده‌ی این دو طول موج است.

محاسبه‌ی درصد پوشش گیاهی با استفاده از ۳۵ داده‌ی آموزشی و ۱۷ داده‌ی تست

نتایج حاصل از انتخاب ۳۵ داده‌ی آموزشی و ۱۷ داده‌ی تست در جدول شماره (۴) آمده است. در این جدول برای مقایسه‌ی نتایج با حالت ۳۰ داده‌ی آموزشی و ۲۲ داده‌ی تست، نتایج شبکه‌های با مشخصات مشابه (ورودی، تابع انتقال، تعداد نرون مخفی و تابع آموزشی مشابه) حالت قبل آورده شده است.

جدول ۴- نتایج شبکه عصبی با ۳۵ داده‌ی آموزشی و ۱۷ داده‌ی تست

ورودی	تابع انتقال	تعداد نرون مخفی	تابع آموزشی	R2 آموزشی	RMSE آموزشی (درصد)	R2 تست	RMSE تست (درصد)
B4.B3.B2.B1	LogSig	۱	lm	۰/۸۷	۱	۰/۷۹	۱/۱
B4.B3		۳	oss	۰/۸۵	۱/۱	۰/۷۶	۱/۵
B4		۱	cgp	۰/۸۴	۱/۵	۰/۷۳	۱/۴
B3		۲	cgb	۰/۸۵	۰/۹	۰/۶۹	۱/۲
B1		۲	cgp	۰/۶۷	۱/۴	۰/۵۵	۱/۷
B2		۴	cgp	۰/۷۲	۱/۴	۰/۴۱	۱/۵
B4.B3.B2.B1	Tansig	۱	lm	۰/۸۷	۰/۸	۰/۷۹	۱/۲
B4.B3		۳	oss	۰/۸۴	۱/۴	۰/۷۷	۱/۷
B4		۱	cgp	۰/۸۷	۱/۲	۰/۷۳	۱
B3		۲	cgb	۰/۸۱	۰/۹	۰/۷۰	۰/۹
B1		۲	cgp	۰/۶۷	۱/۵	۰/۵۸	۱/۷
B2		۴	cgp	۰/۷۵	۱/۸	۰/۴۹	۱/۲

با مقایسه‌ی جداول شماره (۳) و (۴) می‌توان مشاهده نمود که اغلب الگوریتم‌های شبکه‌های عصبی به تغییر

تعداد نمونه‌های آموزشی و تست واکنش نشان داده و ضریب R^2 تغییر می‌کند. دلیل این امر آن است که در حالت دوم، تعداد داده‌های آموزشی افزایش یافته و شبکه با داده‌ی بیشتری نسبت به حالت اول آموزش دیده است و این امر باعث افزایش ضریب R^2 در داده‌های آموزشی شده است. از طرفی، با هر بار اجرای یک شبکه، نتایج حاصل شده به دلیل اختصاص دادن وزن‌های تصادفی در داخل شبکه به ورودی‌ها، تغییر می‌کند و این امر نیز می‌تواند عاملی در تغییر ضرایب R^2 و RMSE در حالت دوم محسوب شود. نتایج در این مورد نیز نشان دهنده‌ی افزایش دقت با افزایش تعداد ورودی‌ها می‌باشد.

محاسبه‌ی درصد پوشش گیاهی به روش CrossValidation

برای حذف خطای احتمالی ناشی از انتخاب تصادفی نمونه‌ها، از روش CrossValidation نیز استفاده شد. جدول شماره (۵) بیانگر نتایج حاصل از این روش می‌باشد.


جدول ۵- نتایج شبکه عصبی با روش CrossValidation

ورودی	تابع انتقال	تعداد نرون مخفی	تابع آموزشی	R^2	RMSE(%)
B4.B3.B2.B1	LogSig	۱	lm	۰/۸۶	۰/۸
B4.B3		۳	oss	۰/۸۱	۰/۸
B4		۱	cgp	۰/۷۹	۱/۱
B3		۲	cgb	۰/۷۹	۱/۲
B1		۲	cgp	۰/۶۹	۱/۴
B2		۴	cgp	۰/۶۳	۱/۷
B4.B3.B2.B1	Tansig	۱	lm	۰/۸۷	۱/۱
B4.B3		۳	oss	۰/۷۹	۰/۹
B4		۱	cgp	۰/۷۸	۱/۴
B3		۲	cgb	۰/۷۸	۱/۳
B1		۲	cgp	۰/۶۹	۱/۹
B2		۴	cgp	۰/۶۵	۱/۲

جدول فوق نیز نتایج دو حالت اول را تایید می‌نماید. همان‌گونه که از این جدول می‌توان دریافت، افزایش

تعداد ورودی‌ها باعث افزایش دقت در نتایج شده است.

با توجه به نتایج حاصل شده از محاسبه‌ی درصد پوشش گیاهی از دو روش مورد مطالعه، شبکه‌ی عصبی مصنوعی با ورودی چهار باند تصویر، با تابع انتقال LogSig، تابع آموزشی LM، یک لایه‌ی میانی و یک نرون مخفی با بیشترین دقت می‌تواند درصد پوشش گیاهی را تخمین بزند. بر همین اساس، در این تحقیق، برای محاسبه‌ی درصد پوشش گیاهی از این شبکه استفاده گردید (شکل ۴).



شکل ۴- درصد پوشش گیاهی محاسبه شده با استفاده از شبکه‌ی عصبی مصنوعی

بحث و نتیجه گیری

همان‌گونه که در مقدمه اشاره شد، برای محاسبه‌ی درصد پوشش گیاهی با استفاده از تصاویر ماهواره‌ای می‌توان از سه روش شاخص‌های گیاهی، تجزیه پیکسل‌های آمیخته و همچنین شبکه‌های عصبی مصنوعی استفاده نمود. استفاده از روش تجزیه پیکسل‌های آمیخته به دلیل عدم امکان استخراج پیکسل‌های خالص پوشش گیاهی مرتعی در مناطق خشک، امکان پذیر نمی باشد. استفاده از شاخص‌های گیاهی در مناطق مختلف نتایج متفاوتی را نشان داده است. در این میان می‌توان به مطالعه‌ی Behbahani و همکاران در سال ۲۰۱۰ اشاره نمود. آن‌ها شاخص‌های NDVI و MSAVI سنجنده ASTER را به عنوان بهترین شاخص‌ها برای تعیین درصد تاج پوشش تک

درختان مراتع مشجر مناطق خشک معرفی کرده‌اند. Ebrahimi در سال ۲۰۱۰ شاخص MSAVI را برای تخمین درصد پوشش گیاهی در مناطق خشک مرکزی ایران پیشنهاد نمود. در تحقیق دیگری Arzani و همکاران در سال ۲۰۰۹ استفاده از شاخص‌های SAVI، MSAVI2 و PVI را در برآورد تاج پوشش گیاهی مراتع ایران پیشنهاد نمودند. نتایج تحقیقات Baret & Guyot در سال ۱۹۹۱ نشان داد که شاخص‌های SAVI، TSAVI و MSAVI توانایی برآورد تاج پوشش گیاهی را داشته و اثرهای بازتاب خاک زمینه گندمیان مسن و لاشبرگ را حذف می‌نماید. Rondeaux در سال ۱۹۹۵ شاخص گیاهی TSAVI را بهترین شاخص برای برآورد درصد تاج پوشش گیاهی علفزار در شرایطی که پوشش گیاهی همگن باشد معرفی می‌نماید. Richardson & Wiegand در سال ۱۹۹۷ نیز برای بررسی تراکم گیاهی، شاخص‌های PVI، GVI، SBI، DVI، PV16 را به کار برده و نتیجه گرفتند که شاخص PVI برای ارزیابی پوشش گیاهی و اندازه‌گیری تراکم گیاهی مناسب است.

مقایسه‌ی نتایج حاصل از تحقیق حاضر و تحقیقاتی که با استفاده از شاخص‌های گیاهی انجام شده نشان می‌دهد که شبکه‌های عصبی مصنوعی قابلیت و دقت بیشتری در تخمین درصد پوشش گیاهی دارند. دلیل این امر را می‌توان این‌گونه توضیح داد:

الف) رفتار طیفی هر پدیده در طول موج‌های مختلف متفاوت بوده و برای شناسایی یک پدیده به تمامی اطلاعات طول موج‌های مختلف نیاز است. شاخص‌های گیاهی عموماً از اطلاعات موجود در دو یا سه باند استفاده می‌کنند، این در حالی است که گاهی حجم عظیمی از اطلاعات که در باندهای دیگر وجود دارد نادیده گرفته می‌شود. استفاده از شبکه‌های عصبی مصنوعی این امکان را فراهم آورده تا نه تنها بتوان از تمامی اطلاعات اخذ شده توسط سنجنده استفاده نمود، بلکه با وارد کردن اطلاعات واقعی زمینی به شبکه، نتایج بهتری به دست آورد.

ب) شبکه‌ی عصبی پرسپترون (که از نوع شبکه‌های نظارت شده است) مقادیر محاسبه شده را با مقادیر واقعی مقایسه کرده و با تغییر وزن‌های اختصاص یافته به هر ورودی، سعی در کاهش میزان خطا و افزایش دقت دارد و تا زمانی که به حداقل خطا نرسد آموزش شبکه ادامه می‌یابد؛ و این امر باعث ایجاد دقت قابل قبول می‌شود. از طرفی، می‌توان با وارد کردن ورودی‌های تاثیرگذار در شبکه‌های عصبی، از میزان خطای نهایی تخمین درصد پوشش گیاهی کاست. شایان ذکر است که همیشه افزایش تعداد ورودی‌ها باعث افزایش دقت مدل نمی‌شود و اضافه کردن ورودی‌هایی که هیچ رابطه‌ای با مقادیر خروجی ندارند نه تنها باعث افزایش دقت نمی‌شود بلکه ممکن است باعث کاهش دقت مدل نیز شود (Menhaj., 2005).

ج) یکی از خصوصیات دیگر شبکه‌های عصبی مصنوعی که آن‌ها را نسبت به سایر روش‌ها و الگوریتم‌ها متمایز می‌نماید، حساسیت کمتر آن‌ها نسبت به وجود خطا در ورودی‌ها است. علت این امر پردازش توزیعی اطلاعات می‌باشد. در این سیستم فعالیت‌های پیچیده با ساختاری موازی شبیه سازی می‌شوند و به جای آنکه تمام بار فعالیت بر دوش یک واحد محاسباتی سریع قرار گیرد، تعداد زیادی واحدهای محاسباتی ساده به صورت مشترک انجام آن را به عهده دارند. این تقسیم کار، پیامد مثبت دیگری نیز در پی دارد و آن این است که چون تعداد زیادی نرون در یک زمان درگیر فعالیت هستند، سهم هر یک از نرون‌ها چندان حائز اهمیت نیست. بنابراین وجود خطا در یکی از آن‌ها و نتیجه‌ی آن تاثیر چندانی بر روی سایر واحدهای محاسباتی نخواهد داشت (Jang, et al., 2006).

د) نکته قابل توجه در نتایج حاصل از شبکه‌های عصبی این است که تقریباً نتایج حاصل از شبکه‌های مختلف دقت قابل قبولی دارد زیرا پارامترهای متعددی (تابع انتقال، تابع آموزشی، تعداد نرون مخفی، ترکیب نوع ورودی‌ها، تعداد تکرار) در تنظیم هر شبکه وجود دارد که باعث انعطاف پذیری آن‌ها شده است. به عنوان مثال در صورتی که از چهار باند تصویر ماهواره‌ای به عنوان ورودی استفاده شود، تنها تابع LM با یک نرون مخفی نیست که می‌تواند نتایجی با R^2 برابر ۰/۸۶ و RMSE مساوی ۰/۸ درصد ارائه دهد. بلکه با استفاده از سایر توابع آموزشی نیز چنین نتایج مشابهی حاصل شده که در جداول شماره ۲ و ۳ و ۴ تنها نتایج بالاترین دقت آمده است.

با توجه به شکل شماره (۴) بیش از ۹۵ درصد حوضه‌ی مورد مطالعه دارای پوشش کمتر از ۳۵ درصد می‌باشد و مناطقی که پوشش بیش از ۳۵ درصد دارند جزء اراضی زراعی و باغی منطقه هستند. مناطق شمالی و شرقی حوضه‌ی مورد مطالعه نسبت به سایر مناطق از درصد پوشش گیاهی بیشتری برخوردار است که این امر به دلیل واقع شدن این مناطق در ارتفاع بیش از ۲۵۰۰ متر است و مقدار بارندگی بیشتری نسبت به سایر مناطق دارد. از طرفی گیاه غالب این مناطق تیپ گون و بادام کوهی و ارس می‌باشد که مقاومت بیشتری نسبت به شرایط کم آبی دارند.

پوشش گیاهی مناطق مرکزی و غربی حوضه، کمتر از ۲۵ درصد است. این مناطق در ارتفاع کمتر از ۲۰۰۰ متر واقع شده‌اند و نسبت به ارتفاعات از مقدار بارندگی کمتر و دمای بیشتری برخوردارند. تیپ غالب گیاهی این مناطق درمنه‌ی دشتی می‌باشد.

کمترین میزان درصد پوشش گیاهی مربوط به مناطقی است که دخالت انسان (احداث سد خاکی) باعث از بین

رفتن پوشش گیاهی شده است.

جدول شماره (۶) بیانگر نتایج مربوط به توابع آموزشی مختلف با ورودی چهار باند تصویر به روش

CrossValidation می‌باشد.

جدول ۶- بالاترین دقت حاصله از توابع آموزشی مختلف به روش CrossValidation

تابع آموزشی	تابع انتقال	تعداد نرون مخفی	تعداد تکرار	R2	RMSE
gd	Logsig	۳	۱۰۰۰	۰/۸۷	۰/۸
gda	Logsig	۲	۱۰۰۰	۰/۸۸	۰/۸
gdm	tansig	۱	۱۲۰۰	۰/۸۵	۰/۸
gdx	Logsig	۱	۱۰۰۰	۰/۸۷	۰/۷
scg	Logsig	۲	۸۰۰	۰/۸۸	۰/۹
cgb	Logsig	۴	۱۰۰۰	۰/۸۵	۰/۷
cgp	Tansig	۲	۱۰۰۰	۰/۸۶	۰/۷
cgf	Tansig	۳	۱۰۰۰	۰/۸۷	۰/۹
rp	Logsig	۲	۱۰۰۰	۰/۸۷	۰/۸
bfg	Logsig	۱	۱۲۰۰	۰/۸۶	۰/۸
oss	Logsig	۲	۱۰۰۰	۰/۸۶	۰/۸
lm	Logsig	۲	۱۰۰۰	۰/۸۸	۰/۷

با توجه به جدول فوق، با تغییر پارامترهای مربوط به هر شبکه، می‌توان با استفاده از تمامی توابع آموزشی به نتایج قابل قبولی دست یافت. زیرا این توابع به گونه‌ای طراحی شده‌اند که با معرفی دقت مدنظر به شبکه، خطای آن‌ها کاهش می‌یابد. حال ممکن است که برخی از این توابع در تکرارهای پایین و در برخی موارد در تکرارهای بالا به آن دقت برسند. ذکر مجدد این نکته ضروری است که تعداد تکرار باید بهینه باشد زیرا ممکن است که افزایش تکرار باعث آموزش بیش از حد شبکه شود و نتایج غیر منطقی حاصل شود. دقت نتایج داده‌های آموزشی در تحقیق حاضر با داده‌های تست ارزیابی و سپس تعداد تکرار مناسب (۱۰۰۰) انتخاب شد. در روش CrossValidation نیز همان تعداد تکرار ۱۰۰۰ به عنوان تکرار بهینه مبنا قرار گرفت.

تعداد نرون مخفی در تحقیق حاضر تا شش عدد افزایش یافت و با توجه به نتایج به‌دست آمد، تنها در برخی از توابع آموزشی (cgp و gda) در تعداد چهار نرون دقت مناسبتری حاصل شده و در بقیه‌ی توابع تعداد نرون کمتر از

چهار عدد نتایج بهتری ارائه داده است. افزایش بیش از چهار نرون در تمامی توابع آموزشی دقت پایین‌تری داشت؛ برای نمونه، جدول زیر بیانگر نتایج حاصل از تابع انتقال Logsig، تابع آموزشی LM و ورودی‌های چهار باند تصویر می‌باشد (جدول شماره ۷).

جدول ۷- تغییر مقادیر R2 و RMSE با تغییر تعداد نرون مخفی به روش Cross Validation

تعداد نرون مخفی	R2	RMSE	تعداد نرون مخفی	R2	RMSE
۱	۰/۸۱	۰/۹	۴	۰/۷۵	۰/۷
۲	۰/۸۷	۰/۷	۵	۰/۷۹	۰/۸
۳	۰/۸۴	۰/۸	۶	۰/۷۸	۰/۸

شبکه‌های عصبی برای اکثر مسائل پیش‌بینی به بیش از دو لایه مخفی نیاز ندارند. بسیاری از محققان از یک لایه مخفی در تحقیقات خود استفاده نموده‌اند. تعداد نرون مخفی بدین دلیل اهمیت دارد که نقشی اساسی در خاصیت مدل‌بندی غیرخطی شبکه‌های عصبی دارد. اگرچه روش سیستماتیک برای تعیین تعداد گره‌های مخفی وجود ندارد لیکن در ادبیات شبکه‌های عصبی، تعداد گره‌های مخفی به ندرت بیشتر از دو برابر تعداد گره‌های ورودی در نظر گرفته می‌شوند (Zhang, 2003).

استفاده از برخی توابع آموزشی نتایجی با دقت بیش از ۹۹ درصد را نشان داد. این نتیجه اگرچه از نظر محاسباتی ایده آل است ولی اصولاً قابل قبول نیست. زیرا در انجام مراحل مختلف تحقیق، همیشه خطاهایی ناخواسته (خطای دستگاه GPS، خطای عدم اندازه‌گیری دقیق درصد پوشش گیاهی در پلات ۵۰×۵۰ متر، خطای ناشی از زمین مرجع کردن تصاویر، تغییرات فنولوژیکی گیاه در فاصله‌ی زمانی ۱۵ روزه‌ی تصویربرداری و برداشت میدانی، ...) وجود دارد که رسیدن به چنین دقتی را عملاً غیر ممکن می‌سازد. لازم به ذکر است که طی مراحل مختلف انجام تحقیق سعی شده چنین خطاهایی به حداقل برسد اما بدیهی است که نمی‌توان به‌طور کلی تمامی خطاها را حذف نمود. دلیل رسیدن به چنین نتایجی آموزش بیش از حد^۱ شبکه می‌باشد.

منابع و مآخذ

1. Aman, A., Randriamanantena, H. P., Podaire, A and FROUTIN, R (1992). "Upscale integration of normalized difference vegetation index: The problem of spatial heterogeneity". *IEEE Transactions on Geoscience and Remote Sensing*, vol 42 (3): pp. 326–338.
2. Arzani, H., Noori, S., Kaboli, S. H., Moradi, H. R and Ghelichnia, H (2009). Determination of Suitable Indices for Vegetation Cover Assessment in Summer Rangelands in South of Mazandaran. *Journal of the Iranian Natural Res.* 61 (4): pp. 997-1016.
3. Baugh, W.M and Groeneveld, D.P (2009). "Broadband vegetation index performance evaluated for a low-cover environment. *International Journal of Remote sensing*, vol 27 (3): pp. 4715-4730.
4. Baret, F and Guyot, G (1991). "Potentials and limits of Vegetation indices for LAI and APAR assessment" *Remote Sensing of Environment*, vol 35: pp. 161-173.
5. Baver, L.D (1956). Soil Physics. Third ed. John Wiley & Sons Inc, New York.
6. Behbahani, N., Fallah Shamsi, R., Erfanifard, Y and Ramezani, M (2010). "Estimation of single tree crown cover using vegetation indices and ASTER-L 1B imagery in arid rangelands. Case study; tag Ahmad Shahi - South Khorasan". *Journal of range*, vol 4 (1): pp. 93-103.
7. Burgan, R.E., Hartford, R. A and Eidenshink, J. C. (1996). "Using NDVI to assess departure from average greenness and its relation to the fire business". *Intermountain Research Station: USDA Forest Service*, vol 8: pp. 121-137.
8. Carpenter, G., Gopal, S., Macomber, S., Martens, S., Woodcock, C and Franklin J (1999). "A Neural Network Method for Efficient Vegetation Mapping". *Remote Sensing of Environment*, vol 70: pp. 326–338.
9. Conghe, S (2005). "Spectral mixture analysis for subpixel vegetation fractions in the urban environment: How to incorporate endmember variability" *Remote Sensing of Environment*, vol 95: pp. 248–263.
10. Dabney, S., Delgado, J., and Reeves, D (2001). Using winter crops to improve soil and water quality. *Communication in Soil Science Plant Annals*, pp. 1221–1250.
11. Darvishzadeh, R., Skidmore, A.K., Atzberger, C and Wieren, S.V (2008). "Estimation of

vegetation LAI from hyperspectral reflectance data: Effects of soil type and plant architecture". *International Journal of applied earth observation and geoinformation*, vol 10: pp. 358-373.

12. Ebrahimi, M (2010). "Estimation of vegetation fraction using vegetation indices and artificial neural network in order to improve modified perpendicular index". In. *RS & GIS department*. Tehran: Shahid Beheshti university.

13. Elmore, A.J., Mustard, J. F., Manning, S. J and Lobell, D. B (2000). "Quantifying vegetation change in semiarid environments: Precision and accuracy of spectral mixture analysis and the normalized difference vegetation index". *Remote Sensing of Environment*, vol 73: pp. 87- 102.

14. Elwell, H.A and Stocking, M.A. (1976). "Vegetal cover to estimate soil erosion hazard in Rhodesia". *Geoderma*, vol 15: pp. 61-70.

15. Geladi, P and Kowalski, B.R (1986). "Partial least-squares regression: a tutorial". *Analytica Chimica Acta*, vol 185: pp. 1-17.

16. Ghulam, A. (2006). Remote monitoring of farmland drought based n-dimensional spectral feature space. PhD Dissertation, Peking University, China: Beijing.

17. Gutman, G., and Ignatov, A (1998). "The derivation of the green vegetation fraction from NOAA/AVHRR data for use in numerical weather prediction models". *International Journal of Remote sensing*, vol? pp. 1533-1543.

18. Jang, J.D., Vian, A.A., Ancil, F., Bartholome, E (2006). "Neural network application for cloud detection in SPOT VEGETATION images". *International Journal of Remote sensing*, vol 27, pp. 719-736.

19. Lawrence, R.L and Ripple, W.J (1998). "Comparisons among Vegetation Indices and Bandwise Regression in a Highly Disturbed, Heterogeneous Landscape: Mount St. Helens, Washington". *Remote Sensing of Environment*, vol 64: pp. 91-102

20. Menhaj, M.B. (2005). *Principles of Artificial Neural Network*. Tehran: Amir kabir university.

21. Nemmour, H and Chibani, Y (2006). "Fuzzy neural network architecture for change detection in remotely sensed imagery". *International Journal of Remote sensing*, vol 27: pp. 705-717

22. Richardson, A.J and Wiegand, C.L (1997) "Distinguishing Vegetation from soil background

information", *Photogrammetric Engineering and Remote Sensing*. Vol 43: pp. 1541-1552.

23. Rondeaux, G (1995). Analysis of soil spectral properties with the Ger single Field-of-view IRIS. *Internal report. GeogRaphy Department*, University of Nottingham, UK.

24. Zhang, Y.X., Li, X.B and Chen, Y.H (2003). "Overview of field and multi-scale remote sensing measurement approaches to grassland vegetation coverage". *Adv. Eearth science*, vol 18: pp. 85-93