



برآورد زیست‌توده گندم زمستانه (*Triticum aestivum* L.) با استفاده از مدل‌های رگرسیون خطی چندگانه، شبکه عصبی مصنوعی و داده‌های سنجش از دور

مریم سلطانیان^۱، مهدی نادری خوراسگانی^{۲*} و علی تدین^۳

^۱دانشجوی دکتری فیزیولوژی گیاهان زراعی، دانشکده کشاورزی، دانشگاه شهرکرد، شهرکرد، ایران

^۲دانشیار گروه خاک‌شناسی، دانشکده کشاورزی، دانشگاه شهرکرد، شهرکرد، ایران

^۳دانشیار گروه زراعت، دانشکده کشاورزی، دانشگاه شهرکرد، شهرکرد، ایران

تاریخ دریافت: ۹۹/۰۵/۰۷ تاریخ پذیرش: ۹۹/۰۹/۲۸

چکیده

سابقه و هدف: زیست‌توده ارتباط حیاتی بین مصرف انرژی خورشیدی و عملکرد گیاه را فراهم می‌کند، بنابراین برآورد صحیح آن برای پیش‌بینی دقیق رشد محصول و پیش‌بینی عملکرد بسیار مهم است و به مدیران کشاورزی برای بهبود مدیریت زمین‌های زراعی کمک می‌کند. در چند دهه اخیر، سنجش از دور به عنوان ابزاری برای تخمین پارامترهای بیوفیزیکی گیاه به صورت گسترده مورد استفاده قرار گرفته است. توانایی فناوری سنجش از دور برای تخمین زیست‌توده گیاهی امید بخش، سریع، دوره‌ای و غیرمخرب است. بدین منظور، این تحقیق با هدف کاربرد فناوری سنجش از دور و مقایسه دو مدل آماری رگرسیون خطی چندگانه و شبکه عصبی مصنوعی برای برآورد زیست‌توده گندم زمستانه در شهرستان شهرکرد، استان چهارمحال و بختیاری در سال ۱۳۹۶ انجام شد.

مواد و روش‌ها: در این پژوهش به منظور برآورد زیست‌توده گیاه گندم به وسیله تصاویر ماهواره لندست ۸، هشت مزرعه زیر کشت گندم زمستانه با مساحت بین ۱۰ تا ۶۰ هکتار در سراسر شهرستان شهرکرد، در نظر گرفته شد. سپس موقعیت ۱۲۰ واحد نمونه‌برداری به صورت تصادفی در مزارع مورد مطالعه توسط GPS تعیین گردید. واحدهای نمونه‌برداری به صورت مربع‌های ۳۰×۳۰ متری مطابق با پیکسل‌های لندست بود. هر یک از این واحدها، شامل ۵ پلات ۰/۲۵ مترمربعی در چهار گوشه و مرکز مربع می‌باشد. در طی فصل رشد در تاریخ‌های ۳۱ فروردین (۲۰ آوریل)، ۱ خرداد (۲۲ می)، ۲ تیر (۲۳ ژوئن) و ۳ مرداد (۲۵ ژولای) سال ۱۳۹۶ همزمان با عبور ماهواره لندست ۸ به مزارع مراجعه و نمونه‌برداری انجام گردید. جمع‌آوری داده‌های میدانی شامل زیست‌توده اندام هوایی و شمارش تعداد بوته‌ها در هر پلات بود. سپس نمونه‌ها به آزمایشگاه منتقل گردید و در آن خشک و در نهایت وزن شدند. همزمان داده‌های مربوط به سنجش از دور ماهواره لندست ۸ در این تاریخ‌ها به دست آمد و شاخص‌های گیاهی به کمک باندهای ماهواره‌ای محاسبه شد. در این بررسی زیست‌توده گندم با استفاده از ۲۵ شاخص گیاهی و دو روش رگرسیون خطی چند متغیره و شبکه عصبی مصنوعی (Artificial Neural Network, ANN) برآورد شد. مدل شبکه عصبی مصنوعی پرسپترون با چندلایه (پیش‌خور) طراحی شد و کارایی آن با نتایج مدل رگرسیون خطی چند متغیره مقایسه گردید. اعتبارسنجی و آزمون مدل‌ها و مقایسه نتایج این دو مدل با استفاده از آماره‌هایی نظیر ضریب تبیین (R^2)، شاخص جذر میانگین مربعات خطا (RMSE)، و میانگین خطا (ME) انجام گرفت.

*مسئول مکاتبه: khnaderi@yahoo.com

یافته‌ها: نتایج نشان داد که مدل شبکه عصبی مصنوعی با $R^2=0/83$ و $RMSE=53/91 \text{ g/m}^2$ برای داده‌های آموزش و $R^2=0/85$ و $RMSE=65/68 \text{ g/m}^2$ برای داده‌های آزمون و مدل رگرسیون خطی چند متغیره با $R^2=0/78$ و $RMSE=65/68 \text{ g/m}^2$ زیست توده را برآورد کرده‌اند. در روش رگرسیون خطی چند متغیره، شاخص‌های EVI ، $CIgreen$ ، $PSRI$ ، CRI ، $VARI$ و $GNDVI$ به ترتیب مؤثرترین شاخص در تخمین میزان زیست توده محصول بودند. شاخص‌های GI ، $SAVI$ ، $ARVI$ ، CRI ، $NDWI$ ، MSR و $NDVI$ به ترتیب بیشترین حساسیت را در رابطه با زیست توده گندم در مدل شبکه عصبی مصنوعی داشتند.

نتیجه‌گیری: یافته‌های پژوهش حاضر نشان داد که با بهره‌گیری از تصاویر ماهواره‌ای و توسعه مدل‌های آماری پارامتری و غیرپارامتری امکان برآورد زیست توده گندم زمستانه در منطقه مورد مطالعه وجود دارد. همچنین، روش شبکه عصبی مصنوعی نسبت به روش رگرسیون خطی چندگانه صحت پیش‌بینی بهتری دارد و لذا استفاده از این روش به عنوان یک رهیافت مناسب در برآورد زیست توده گندم زمستانه پیشنهاد می‌شود.

واژه‌های کلیدی: زیست توده، سنجش از دور، شاخص گیاهی، شبکه عصبی مصنوعی، گندم.

مقدمه

گندم نقش اساسی در تأمین امنیت غذایی دارد. نظارت به موقع وضعیت رشد گندم و بررسی عوامل تهدیدکننده آن کمک بزرگی به امنیت غذایی و حفظ کشاورزی پایدار است (۲۱). زیست توده یکی از مفیدترین شاخص‌های رشد و سلامت پوشش گیاهی محصولات زراعی است (۵۷) که به استفاده از انرژی خورشیدی، عملکرد و کیفیت دانه و تولید ناخالص اولیه مرتبط می‌باشد (۵۹ و ۱۰). بنابراین، برآورد صحیح زیست توده اندام هوایی گیاه برای نظارت دقیق رشد محصول و بهبود کارایی مدیریت زراعی و پیش‌بینی عملکرد محصول بسیار ضروری است (۲۸)، ۳۷، ۳۸، ۴۳، ۵۹ و ۶۰. همچنین، نظارت بر تولید زیست توده یک روش تشخیصی برای ارزیابی نیازهای کودی، به ویژه کمبود نیتروژن (N) در محصولات زراعی است (۹، ۱۱ و ۱۸).

معمولاً دو روش برای اندازه‌گیری زیست توده وجود دارد: ۱- اندازه‌گیری میدانی و ۲- تخمین به کمک داده‌های سنجش از دور. روش اندازه‌گیری میدانی مخرب، گران و وقت‌گیر است و فقط برای بررسی در مقیاس کوچک با گونه‌های گیاهی نسبتاً

یکنواخت امکان‌پذیر است (۴۹، ۵۹ و ۱۴). فناوری سنجش از دور به دلیل پوشش جهانی، تکرارپذیری و مقرون به صرفه بودن یک روش مؤثر برای ارزیابی دقیق زیست توده گیاهی در مقیاس ملی یا منطقه‌ای ارائه می‌دهد (۳۶ و ۴۹). در دو دهه گذشته، از داده‌های چند طیفی جمع‌آوری شده با سنجنده‌های دستی (نظیر CropScan، GreenSeeker و Crop Circle) و تصاویر ماهواره‌ای (مانند Landsat، RapidEye و WorldView-2) یا داده‌های ابرطیفی جمع‌آوری شده با طیف‌سنجی‌های میدانی (نظیر ASD FieldSpec و Ocean Optics SD2000) با استفاده از شاخص‌های گیاهی (Vegetation Index, VI) برای برآورد زیست توده محصول زراعی استفاده شده است (۱۰).

تخمین زیست توده با استفاده از داده‌های ماهواره‌ای مستلزم استفاده از مدل‌های مختلف آماری است (۵۸). این مدل‌ها به دو گروه مدل‌های فیزیکی و مدل‌های رگرسیون تجربی تقسیم می‌شوند (۲ و ۵۸). مدل‌های فیزیکی نظیر مدل PROSAIL (۱۵ و ۳۱)، بر اساس اصول فیزیکی ساخته می‌شوند، اما پارامترهای مختلف این مدل‌ها اغلب به راحتی در

است (۵۸). در سال‌های اخیر از الگوریتم‌های یادگیری ماشین (Machine-Learning Algorithm) برای تولید مدل‌های غیرخطی ورودی-خروجی انعطاف پذیر بین داده‌های سنجش از دور و زیست‌توده تلاش زیادی شده است (۵۷).

رایج‌ترین روش برای تخمین زیست‌توده به کمک داده‌های سنجش از دور استفاده از شاخص‌های گیاهی و تشکیل مدل‌های تجربی است (۴۹، ۱۴ و ۳۶). داده‌های سنجش از دور توسط محققان متعددی برای تخمین زیست‌توده مورد استفاده قرار گرفته است. کروس و همکاران (۲۰۱۵) روابط مثبت و معنی‌داری بین زیست‌توده ذرت و سویا و شاخص‌های گیاهی NDVI، Green-NDVI، RVI و MTVI1 ناشی از تصاویر SPOT و Landsat برقرار کردند (۳۵). گنیپ و همکاران (۲۰۱۴b) دریافتند که SAVI، OSAVI و MTVI2 در مرحله طولی شدن ساقه (jointing) با زیست‌توده برنج نسبت به مرحله سنبله‌دهی (booting) روابط قوی‌تری داشتند (۲۵). گائو و همکاران (۲۰۱۳) پیشنهاد کردند که می‌توان زیست‌توده گیاه ذرت را توسط شاخص‌های گیاهی NDVI، RVI و EVI حاصل از ماهواره زیست محیطی چینی (HJ) برآورد کرد (۱۷).

شبکه‌های عصبی مصنوعی (ANNs) و رگرسیون‌های بردار پشتیبانی (Support Vector Regressions, SVRs) نیز برای ساخت مدل‌های پیش‌بینی دقیق زیست‌توده محصولات زراعی به کمک شاخص‌های گیاهی استفاده شده‌اند (۵۷). به عنوان مثال، ونگ و همکاران (۲۰۰۸) یک مدل مؤثر برای ارزیابی زیست‌توده گندم با ANN و شاخص‌های گیاهی RVI، NDVI، GNDVI، SAVI، OSAVI، RDVI ناشی از داده‌های ASD FieldSpec برقرار کردند (۵۶).

دسترس نیستند و به همین دلیل استفاده عملی از این مدل‌ها برای برآورد پارامترهای محصول زراعی محدود است (۳، ۵ و ۶۰).

در رویکرد آماری، مدل‌های رگرسیون از داده‌های طیفی و ارتباط آن‌ها با زیست‌توده استفاده می‌کنند (۳۹ و ۴۰). این مدل‌ها اساساً در دو دسته قرار می‌گیرند: الف) تکنیک‌های یادگیری ماشین [مثل، شبکه‌های عصبی مصنوعی (Artificial Neural Networks, ANNs)، رگرسیون جنگل تصادفی (Random Forest Regression, RF)، رگرسیون ماشین بردار پشتیبانی (Support Vector Machine Regression, SVM) و ب) تکنیک‌های رگرسیون مرسوم [نظیر رگرسیون خطی چندگانه (Linear Regression, MLR Multiple Stepwise)، تکنیک رگرسیون چندگانه گام به گام (Regression, MSR)، رگرسیون حداقل مربعات جزئی (Partial Least Squares Regression, PLSR)] (۱، ۵۹ و ۶۰).

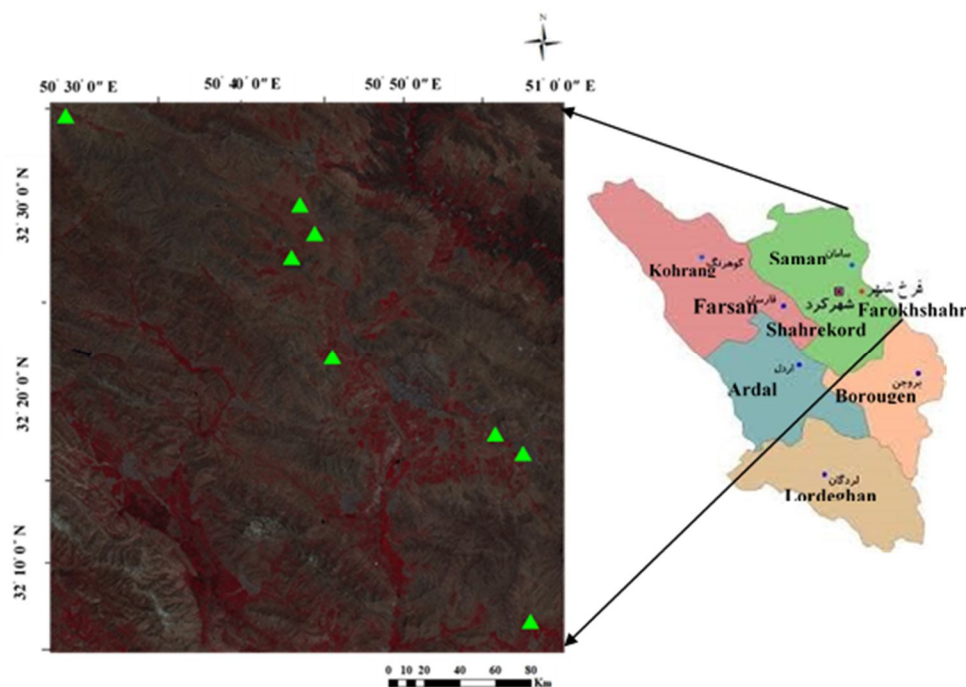
در بین الگوریتم‌های مختلف یادگیری ماشین، شبکه‌های عصبی مصنوعی (ANNs) متداول‌ترین رویکردها برای ایجاد رگرسیون غیرخطی می‌باشند (۵۷). شبکه‌های عصبی مصنوعی سیستم‌های محاسباتی هستند که فرایند یادگیری انسان را برای ایجاد ارتباط بین داده‌های ورودی و خروجی شبیه‌سازی می‌کنند (۵۳). این روش در برخورد با روابط غیرخطی بسیار قدرتمند می‌باشد (۵۸). شبکه‌های عصبی مصنوعی از یک عملکرد پاسخ غیرخطی استفاده می‌کند که بارها در یک ساختار خاص شبکه تکرار می‌شود تا روابط عملکردی پیچیده بین داده‌های آموزش ورودی و خروجی را بیاموزد (۵۲). پردازش شبکه عصبی بر اساس عملکرد بسیاری از واحدهای پردازشی ساده به نام نورون، سلول یا گره است عملکرد آنها شبیه به نورون‌های انسانی

دقیقه تا ۳۲ درجه و ۳۵ دقیقه شمالی و طول جغرافیایی ۵۰ درجه و ۲۹ دقیقه تا ۵۰ درجه و ۵۹ دقیقه شرقی) واقع شده است (شکل ۱). میانگین بارندگی و دمای سالانه منطقه بر اساس ایستگاه سینوپتیک شهرکرد به ترتیب ۳۱۶ میلی‌متر و ۱۲/۱۲ درجه سانتی‌گراد است. ارتفاع متوسط منطقه ۲۰۶۱ متر از سطح دریا می‌باشد. خاک غالب منطقه در گروه Typic Calcixerepts قرار دارد و سیمای اراضی منطقه دشت و دامنه می‌باشد (۴۲).

مطالعه حاضر با هدف مقایسه کارایی مدل‌های شبکه عصبی مصنوعی و رگرسیون خطی چندمتغیره در برآورد زیست‌توده گندم زمستانه براساس داده‌های تصاویر Landsat 8 در شهرستان شهرکرد، استان چهارمحال و بختیاری انجام شد.

مواد و روش‌ها

منطقه مورد مطالعه: منطقه مورد مطالعه در شهرستان شهرکرد، استان چهارمحال و بختیاری در مزارع زیر کشت گندم آبی (عرض جغرافیایی ۳۲ درجه و ۶



شکل ۱- مزارع مورد بررسی و مکان‌های نمونه‌برداری در تصویر ترکیب رنگی مجازی استاندارد شهرستان شهرکرد، استان چهارمحال و بختیاری.

Figure 1- Fields and sampling sites in standard virtual color composite image of Shahrekord county, Chaharmahal and Bakhtiari province.

۱ نشان داده شده است. سپس مکان ۱۲۰ واحد نمونه‌برداری به صورت تصادفی در ۸ مزرعه مورد مطالعه مشخص شدند. موقعیت مکانی نقاط توسط GPS (Garmin etrex Vista) تعیین گردید. واحدهای نمونه‌برداری به صورت مربع‌های ۳۰×۳۰ متری مطابق با پیکسل‌های لندست ۸ در نظر گرفته شدند. در هر یک از واحدهای نمونه‌برداری فوق، ۵ پلات ۰/۲۵

نمونه‌برداری و جمع‌آوری داده‌های میدانی: در سال زراعی ۹۶-۱۳۹۵ مناطق عمده کشت گندم آبی در شهرستان شهرکرد، استان چهارمحال و بختیاری مشخص شدند. از بین کشت‌زارهای گندم، ۸ مزرعه با کشت وسیع گندم با مساحت بین ۱۰ تا ۶۰ هکتار مربوط به شرکت‌های کشت و صنعت خصوصی برای نمونه‌برداری انتخاب گردید. موقعیت مزارع در شکل

Numbers) سری تصاویر اخذ شده در تاریخ‌های ۳۱ فروردین (۲۰ آوریل)، ۱ خرداد (۲۲ می)، ۲ تیر (۲۳ ژوئن) و ۳ مرداد (۲۵ ژولای) سال ۱۳۹۶ (۲۰۱۷) با استفاده از مدل‌های ارائه شده در متادیتای همراه هر تصویر به تشعشع و در نهایت به بازتاب تبدیل شدند. **شاخص‌های گیاهی:** شاخص‌های گیاهی که سبزینگی گیاه را بر اساس بازتاب در طول موج‌های مادون قرمز نزدیک و مرئی اندازه‌گیری می‌کنند، اغلب برای برآورد زیست‌توده استفاده می‌شوند (۴۷). تعداد بی‌شماری شاخص‌های گیاهی طی این سال‌ها ایجاد و توسعه یافته‌اند که ۲۵ مورد از آن‌ها در جدول ۱ نشان داده شده است.

تجزیه و تحلیل آماری داده‌ها: برای برآورد زیست‌توده از مدل‌های آماری پارامتریک (رگرسیون خطی چندمتغیره) و ناپارامتریک (شبکه عصبی مصنوعی) استفاده شد. کلیه پردازش‌های تصویری در محیط نرم‌افزار ILWIS 3.7 © 52North GmbH و محاسبات آماری توسط نرم‌افزار SigmaPlot 14.0 (IBM SPSS ©2017 Systat Software Inc.) و Statistics Ver. 25 (© IBM Corporation Matlab R2018a © 1984-2018 و 1989.2017) انجام شدند.

در مدل رگرسیون خطی چند متغیره شاخص‌های گیاهی دوره‌های تصویربرداری به‌عنوان متغیرهای مستقل و زیست‌توده به‌عنوان متغیر وابسته به کار برده شد. از ۷۰ درصد داده‌ها به منظور کالیبراسیون مدل رگرسیونی و از ۳۰ درصد داده‌ها برای ارزیابی مدل استفاده شد. مدل شبکه‌ی عصبی مصنوعی با شاخص‌های گیاهی اجرا گردید و میزان زیست‌توده به‌عنوان متغیر هدف تخمین زده شد. بدین‌منظور ۷۰ درصد داده‌های مشاهده‌ای به‌عنوان داده‌های آموزشی، ۱۵ درصد به‌عنوان داده‌های اعتبارسنجی و ۱۵ درصد به‌عنوان داده‌های آزمون در نظر گرفته شدند (۵۴).

مترمربعی در چهار گوشه و مرکز مربع تعیین گردید. جمع‌آوری داده‌های میدانی شامل زیست‌توده اندام هوایی و شمارش تعداد بوته‌ها در هر پلات بود.

زیست‌توده اندام‌های هوایی در چهار مرحله در طول فصل رشد در تاریخ‌های ۳۱ فروردین (۲۰ آوریل)، ۱ خرداد (۲۲ می)، ۲ تیر (۲۳ ژوئن) و ۳ مرداد (۲۵ ژولای) در زمان عبور ماهواره جمع‌آوری شد. تعداد بوته‌ها در سطح ۰/۲۵ مترمربع شمارش و تراکم بوته‌ها در مترمربع محاسبه شد. تمام گیاهان در هر پلات از سطح زمین به صورت دستی برداشت شدند و در کیسه‌های پلاستیکی نگهداری شدند. نمونه‌ها به آزمایشگاه منتقل شدند. سپس این نمونه‌ها در آون تهویه‌دار در دمای ۸۰ درجه سانتی‌گراد به مدت ۴۸ ساعت خشک شدند و پس از آن وزن خشک با ترازوی دیجیتالی با دقت ۰/۰۱ گرم اندازه‌گیری شدند. مقادیر میانگین (گرم بر مترمربع) زیست‌توده گندم ۵ پلات داخل هر واحد نمونه‌برداری زیست‌توده کل پلات در نظر گرفته شد.

داده‌های ماهواره‌ای: جهت انجام این پژوهش از تصاویر ماهواره لندست ۸ (محصولات داده GeoTIFF سطح ۱) قابل دریافت از سایت <http://earthexplorer.usgs.gov> استفاده گردید. داده‌های لندست ۸ شامل ۱۱ باندها می‌باشند که هر ۱۶ روز یکبار برداشت می‌شوند. این ماهواره از دو سنجنده اصلی تشکیل شده است: ۱) سنجنده OLI (Operational Land Imager) که دارای ۹ باندهای طیفی در محدوده مرئی، مادون قرمز نزدیک و مادون قرمز با طول موج کوتاه طیف الکترومغناطیس قرار دارند و ۲) سنجنده TIRS (Thermal Infrared Sensor) که دارای ۲ باندها در محدوده مادون قرمز حرارتی است. همه تصاویر از لحاظ هندسی توسط پایگاه زمینی ناسا اصلاح شده‌اند، لذا هیچ‌گونه تصحیح هندسی در آن‌ها انجام نشد. اعداد رقمی خام (Digital

صورت یک لایه پنهان و ۱۴ نرون در این لایه و الگوریتم آموزشی Levenberg-Marquardt و تانژانت سیگموئید به عنوان تابع فعالیت در لایه پنهان و تابع خطی در لایه خروجی، به دست آمد. برای مدل ۵۰۰ دوره آموزشی در نظر گرفته شد.

برای مدل سازی شبکه عصبی مصنوعی از شبکه پرسپترون چند لایه (پیش خور) استفاده شد. ۲۵ شاخص گیاهی (جدول ۱) به عنوان پارامترهای ورودی و زیست توده به عنوان متغیر هدف در نظر گرفته شدند. پس از آزمون های متعدد سعی و خطا، بهترین توپولوژی برای شبکه عصبی مصنوعی به

جدول ۱- شاخص های گیاهی استفاده شده در این مطالعه و معادلات آنها.

Table 1- Applied vegetation indices in the study and corresponding equations.

شاخص های گیاهی Vegetation Indices	معادله Equation	منبع Reference
شاخص گیاهی تفاضل نرمال شده Normalized Difference Vegetation Index (NDVI)	$(NIR-RED)/(NIR+RED)^*$	(52)
شاخص گیاهی تفاضل نرمال شده سبز Green Normalized Difference Vegetation Index (GNDVI)	$(NIR-GREEN)/(NIR+GREEN)$	(19)
شاخص گیاهی نسبت Ratio Vegetation Index (RVI)	NIR/RED	(45)
شاخص گیاهی تعدیل اثر خاک Soil Adjusted Vegetation Index (SAVI)	$[(NIR - RED)/(NIR + RED + 0.5)] \times 1.5$	(30)
شاخص گیاهی بهینه شده تعدیل اثر خاک Optimized Soil-Adjusted Vegetation Index (OSAVI)	$1.6*(NIR-RED)/(NIR+RED+0.16)$	(50)
شاخص گیاهی اصلاح شده تعدیل اثر خاک Modified Soil Adjusted Vegetation Index (MSAVI)	$((2*NIR+1)-((2*NIR+1)^2 - 8*(NIR-RED))^{0.5})/2$	(48)
شاخص گیاهی تفاضل Difference Vegetation Index (DVI)	$NIR-RED$	(12)
شاخص گیاهی تفاضل دوباره نرمال شده Renormalized Difference Vegetation Index (RDVI)	$(NIR-RED)/(NIR+RED)^{0.5}$	(51)
شاخص گیاهی اصلاح شده Modified Vegetation Index (MVI)	$(NIR-1.2*RED)/(NIR+RED)$	(44)
شاخص گیاهی غیرخطی Nonlinear Vegetation Index (NLVI)	$(NIR^2 - RED) / (NIR^2 + RED)$	(26)
نسبت ساده اصلاح شده Modified Simple Ratio (MSR)	$(NIR/RED-1)/((NIR/RED)^{0.5}+1)$	(8)
شاخص کلروفیل سبز Green Chlorophyll Index (CIgreen)	$(NIR/GREEN)-1$	(20,22)

* کلمات Red, Green, Blue, NIR, و SWIR به ترتیب به مفهوم باندهای قرمز، سبز، آبی، مادون قرمز نزدیک و مادون قرمز کوتاه می باشند.

*The words Red, Green, Blue, NIR, and SWIR mean red, green, blue, near-infrared, and short-infrared bands, respectively.

ادامه جدول ۱- شاخص‌های گیاهی استفاده شده در این مطالعه و معادلات آن‌ها.

Continuation of Table 1- Applied vegetation indices in the study and corresponding equations.

شاخص‌های گیاهی Vegetation Indices	معادله Equation	منبع Reference
شاخص سبزیگی Greenness Index (GI)	GREEN/RED	(61)
شاخص گیاهی بارز شده Enhanced Vegetation Index (EVI)	$2.5*((NIR-RED)/(NIR+6*RED-7.5*BLUE+1))$	(31)
شاخص گیاهی مثلثی Triangular vegetation index (TVI)	$0.5[120(NIR-GREEN)-200(R-GREEN)]$	(7)
شاخص تفاضل نرمال شده سبز قرمز Normalized green red difference index (NGRDI)	$(GREEN-RED)/(GREEN + RED)$	(55)
شاخص گیاهی مقاوم به جو Atmospherically Resistant VI (ARVI)	$(NIR - RED - (BLUE - RED))/(NIR + RED - (BLUE - RED))$	(31)
شاخص گیاهی مقاوم به جو مرئی Visible atmospherically resistant index (VARI)	$(GREEN-RED)/(GREEN + RED-BLUE)$	(21)
شاخص تفاضل دامنه پهن پویا Wide Dynamic Range Vegetation Index (WDRVI)	$(0.1*NIR-RED)/(0.1*NIR+RED)$	(19)
شاخص بازتاب کاروتنوئید Carotenoid Reflectance Index (CRI)	$1/GREEN + 1/NIR$	(23)
شاخص رنگدانه غیرحساس به ساختار Structure Insensitive Pigment Index (SIPI)	$(NIR-BLUE) / (NIR - RED)$	(46)
شاخص بازتاب پیری گیاه Plant Senescence Reflectance Index (PSRI)	$(RED-BLUE) / NIR$	(41)
شاخص بازتاب جذب کلروفیل تبدیل شده Transformed chlorophyll absorption reflectance index (TCARI)	$3*((NIR - RED)-0.2*(NIR-GREEN)*(NIR/RED))$	(27)
شاخص آب تفاضل نرمال شده Normalized Difference Water Index (NDWI)	$(NIR - SWIR)/(NIR + SWIR)$	(6)
شاخص نسبت رنگدانه کلروفیل نرمال شده Normalized Pigment Chlorophyll Ratio Index (NPCRI)	$(RED-BLUE)/(RED+BLUE)$	(46)

* کلمات Red, Green, Blue, NIR, و SWIR به ترتیب به مفهوم باندهای قرمز، سبز، آبی، مادون قرمز نزدیک و مادون قرمز کوتاه می‌باشند.

*The words Red, Green, Blue, NIR, and SWIR mean red, green, blue, near-infrared, and short-infrared bands, respectively.

عملکرد در مدل انجام شد. در این مطالعه از روش آنالیز حساسیت هیل استفاده شد که در آن هر یک از متغیرها یا ویژگی‌های ورودی مقدار ۱۰ درصد تغییر داده شدند و تأثیر آن‌ها بر خروجی مدل محاسبه شده و مقدار حساسیت مدل نسبت به متغیر ورودی مورد نظر بدست آمد (۵۴).

آنالیز حساسیت: آنالیز حساسیت، اثر هر ورودی بر مقدار خروجی را نشان می‌دهد. هرچه حساسیت نسبت به متغیر ورودی بیشتر باشد، اهمیت آن در مدل‌سازی بیشتر است و تأثیر بیشتری بر متغیر خروجی یا هدف می‌گذارد (۵۴). آنالیز حساسیت پس از تهیه و آموزش مدل و رسیدن به مناسب‌ترین

می‌باشد.

نتایج و بحث

آماره‌های توصیفی داده‌ها (جدول ۲) نشان داد که اطلاعات جمع‌آوری شده در مرحله اول نمونه‌برداری دارای ضریب تغییرات بالای ۴۳ درصد هستند که می‌تواند به دلیل تاریخ کشت متفاوت، مدیریت جداگانه مزارع و تنوع ویژگی‌های خاک‌های مزارع بوده که در مراحل ابتدایی رشد محصول تغییرات بیشتری را نشان داده است. ضریب تغییرات در مرحله دوم (مرحله گلدهی) کمتر بود (۲۳ درصد) و مقدار متوسط زیست‌توده برابر ۵۴۷ گرم در مترمربع (۵/۵ تن در هکتار) بود. در مرحله آخر نمونه‌برداری (۳ مرداد / ۲۵ جولای)، همزمان با برداشت گندم مقدار زیست‌توده معادل ۱۲۵۶ گرم در مترمربع (۱۲/۶ تن در هکتار) بود. در مطالعه Yue و همکاران (۲۰۱۸) در گندم زمستانه ضریب تغییرات و انحراف معیار در مرحله گلدهی به ترتیب ۲۵/۲ درصد و ۱/۹ تن در هکتار و در مرحله پر شدن دانه به ترتیب ۲۵/۴ درصد و ۲/۸ تن در هکتار در بود (۵۸).

اعتبارسنجی مدل‌ها: در ایجاد و اعتبارسنجی مدل و مقایسه نتایج دو مدل رگرسیونی و شبکه عصبی از آماره‌هایی نظیر ضریب تبیین (R^2)، شاخص جذر میانگین مربعات خطا (Root Square Error, RMSE)، جذر میانگین مربعات خطای نسبی (Relative Root Square Error, RRMSE) و میانگین خطا (Mean Error, ME) و ضریب تغییرات (Coefficients of Variations, CV) استفاده گردید (روابط ۱-۵) (۵۴). طبق تعریف، روشی که میانگین خطای ME آن به صفر نزدیک‌تر و RMSE کوچکتری داشته باشد، مدل بهتری خواهد بود.

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2} \quad \text{رابطه ۱:}$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2} \quad \text{رابطه ۲:}$$

$$RRMSE = \left(\frac{RMSE}{\bar{Y}} \right) \times 100 \quad \text{رابطه ۳:}$$

$$ME = \frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i) \quad \text{رابطه ۴:}$$

$$CV = \left(\frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - \bar{Y})^2}}{\bar{Y}} \right) \times 100 \quad \text{رابطه ۵:}$$

در روابط فوق N ، Y_i و \hat{Y}_i به ترتیب تعداد کل مشاهدات، زیست‌توده مشاهده شده و برآورد شده در نقطه i ، و \bar{Y} میانگین زیست‌توده مشاهده شده

جدول ۲- ویژگی‌های آماری زیست‌توده گندم در تاریخ‌های نمونه‌برداری.

Table 2- Statistical characteristics of wheat biomass at sampling dates.

تاریخ Date	کمترین Min	میانگین Mean g.m ⁻²	بیشترین Max	انحراف معیار Std.	ضریب تغییرات (درصد) Coefficient of variation (%)
2017 04 20	31	90	198	39	43
2017 05 22	253	547	801	128	23
2017 06 23	347	743	1298	188	25
2017 07 25	549	1256	2106	356	28

شد شاخص‌های ۱ خرداد برای برآورد و مدل‌سازی مورد استفاده قرار گرفتند. در این زمان، مزارع گندم در اوایل مرحله سنبله‌دهی (heading) بودند. حساسیت شاخص‌های گیاهی بعد از سنبله‌دهی و در مراحل رشد زایشی کم شده است.

با استفاده از تصاویر اخذ شده در تاریخ‌های ذکر شده شاخص‌های گیاهی ایجاد شد و همبستگی این شاخص‌ها با زیست‌توده گیاه محاسبه گردید (جدول ۳). با توجه به اینکه بالاترین ضرایب همبستگی بین شاخص‌های گیاهی ناشی از داده‌های ماهواره‌ای ۱ خرداد ۱۳۹۶ (۲۲ می ۲۰۱۷) و زیست‌توده مشاهده

جدول ۳- ضرایب همبستگی شاخص‌های گیاهی مورد مطالعه با زیست‌توده گندم.

Table 3- The coefficients of correlation of vegetation indices studied with the wheat biomass.

شاخص‌های گیاهی vegetation indices	2017/04/20	2017/05/22	2017/06/23	2017/07/25
NDVI	0.5648	0.8114	0.6094	0.3740
GNDVI	0.5694	0.8057	0.6670	0.3691
RVI	0.5663	0.8076	0.5951	0.3751
SAVI	0.5277	0.7837	0.6139	0.4307
OSAVI	0.5478	0.7989	0.6114	0.4023
MSAVI	0.5200	0.7829	0.6142	0.4429
DVI	0.4824	0.7519	0.6132	0.4629
RDVI	0.5305	0.7858	0.6142	0.4370
MVI	0.5648	0.8114	0.6094	0.3740
NLVI	0.4960	0.7965	0.6147	0.4565
MSR	0.5655	0.8118	0.6023	0.3745
CIgreen	0.5701	0.8053	0.6644	0.3695
GI	0.5502	0.8141	0.4589	0.1833
EVI	0.5342	0.7910	0.5951	0.4346
TVI	0.5648	0.8114	0.6094	0.3740
NGRDI	0.5499	0.8153	0.4593	0.1827
ARVI	0.5549	0.8088	0.6249	0.3948
VARI	0.5469	0.8182	0.4540	0.2140
WDRVI	0.5660	0.8110	0.5990	0.3748
CRI	0.5711	0.7965	0.5812	0.3737
SIPI	0.5797	0.8032	0.5865	0.3381
PSRI	0.5856	0.8198	0.5466	0.2816
TCARI	0.1274	0.6661	0.2349	0.4633
NDWI	0.5006	0.8069	0.5934	0.3359
NPCI	0.5840	0.8160	0.4894	0.1424

$$6918.84EVI + 1183.24VARI - 173.90CRI + 377.14SIPI - 7656.62PSRI + 514.22TCARI - 10.07NDWI + 1061.18NPCI$$

به منظور ارزیابی مدل رگرسیون چند متغیره در یک نمودار ۱:۱ مقادیر زیست‌توده اندازه‌گیری شده و پیش‌بینی شده مورد مقایسه قرار گرفتند (شکل ۲). شکل ۲ نشان می‌دهد مدل کیفیت مناسبی دارد و نقاط غالباً حول خط ۱:۱ قرار گرفته‌اند. ۸۰ درصد داده‌ها در محدوده سطح اطمینان ۹۵ درصد قرار داشتند.

برآورد زیست‌توده گندم با استفاده از مدل

رگرسیون خطی چند متغیره: در این مرحله با استفاده

از مدل رگرسیون خطی چند متغیره، ۲۵ شاخص

گیاهی به عنوان متغیر مستقل و زیست‌توده گندم به

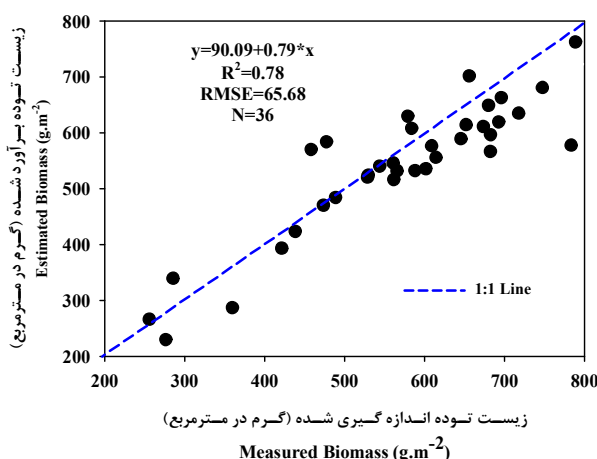
عنوان متغیر وابسته در نرم‌افزار SPSS وارد شدند.

رابطه ۶ با استفاده از روش Enter با ضریب تبیین

۰/۷۸ برای برآورد زیست‌توده گندم به دست آمد.

رابطه ۶: Biomass = 2218.14 + 1501.42GNDVI +

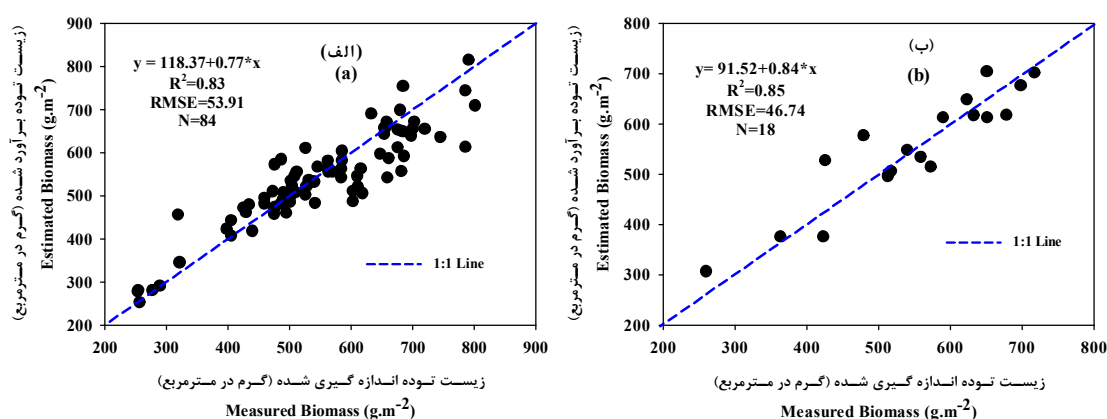
$$311.03DVI + 827.27CIgreen + 605.87GI -$$



شکل ۲- رابطه بین مقادیر زیست توده اندازه گیری شده و پیش بینی شده به کمک مدل رگرسیونی خطی چندگانه.
Figure 2- Relationship between measured and estimated biomass values by multiple linear regression model.

سازي با داده‌های نرمال شده انجام گردید. مدل ANN به دست آمده برای زیست توده دارای ضریب تبیین برابر ۰/۸۳ برای داده‌های آموزشی بود. به منظور آزمون مدل به دست آمده، مقادیر زیست توده پیش بینی شده توسط مدل در مقابل داده‌های اندازه گیری شده در یک نمودار ۱:۱ قرار گرفتند (شکل ۳). شکل ۳ الف و ب نشان می دهند که زیست توده اندازه گیری شده و برآورد شده در مراحل آموزشی و آزمون حول محور ۱:۱ قرار دارند.

برآورد زیست توده گندم با استفاده از مدل شبکه عصبی مصنوعی: به منظور پیش بینی زیست توده گندم، بهترین ساختار ANN پس از آزمون‌های متعدد سعی و خطا به دست آمد. ساختار آموزش دیده دارای ۲۵ گره ورودی و یک گره خروجی بود. گره‌های لایه مخفی ۱۴ و مناسب ترین تعداد تکرار فرآیند یادگیری بر اساس آزمون و خطا ۲۱ دفعه برای زیست توده تعیین شد. لازم به ذکر است که تمام داده‌های ورودی و هدف در بازه ۱ تا ۱- تبدیل خطی شدند و مدل



شکل ۳- رابطه بین زیست توده اندازه گیری شده و پیش بینی شده برای داده‌های آموزشی (الف) و داده‌های آزمون (ب) مدل عصبی مصنوعی با استفاده از شاخص‌های گیاهی.

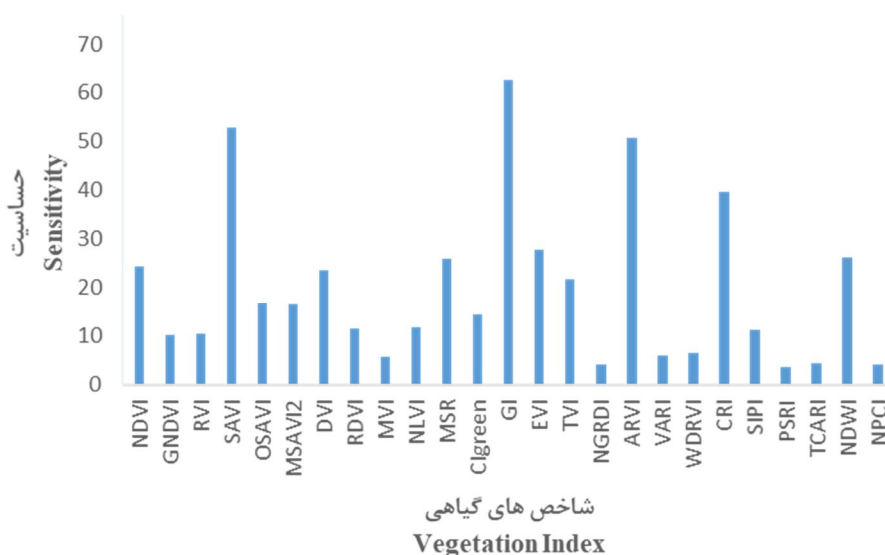
Figure 3- Relationship between measured and estimated biomass for (a) training data and (b) test data of ANN model using vegetation indices.

با توجه به ضرایب رگرسیونی این معادله، شاخص‌های EVI، CIgreen، PSRI، CRI، VARI و GNDVI به ترتیب به‌عنوان مؤثرترین شاخص در تخمین میزان زیست‌توده محصول به حساب می‌آید. به منظور مطالعه اثر هر یک از متغیرهای مستقل ورودی (شاخص‌های گیاهی) بر متغیرهای وابسته (زیست‌توده) در مدل شبکه عصبی مصنوعی آزمون حساسیت انجام شد (شکل ۴). مدل بیشترین حساسیت را به ترتیب به شاخص‌های گیاهی GI، SAVI، ARVI، CRI، EVI، NDWI، MSR و NDVI داشت.

تعیین مهم‌ترین شاخص‌های گیاهی در مدل رگرسیون چندمتغیره و شبکه عصبی مصنوعی: بررسی متغیرهای مستقل (شاخص‌های طیفی) وارد شده (Enter) در مدل رگرسیون خطی چندمتغیره میزان تأثیرپذیری زیست‌توده (متغیر وابسته) از متغیرها را نشان داد (رابطه ۷).

رابطه ۷:

$$\text{Biomass} = 1.13\text{GNDVI} + 0.14\text{DVI} + 5.86\text{CIgreen} + 0.68\text{GI} - 7.63\text{EVI} + 1.32\text{VARI} - 2.76\text{CRI} + 0.64\text{SIPI} - 4.01\text{PSRI} + 0.78\text{TCARI} - 0.01\text{NDWI} + 0.82\text{NPCI}$$



شکل ۴- تجزیه حساسیت مدل شبکه عصبی مصنوعی برای پیش‌بینی زیست‌توده گندم با استفاده از شاخص‌های گیاهی.

Figure 4- Sensitivity analysis of ANN model for predicting wheat biomass by using vegetation indices.

شاخص‌های گیاهی محاسبه شده به کمک باندهای مرئی و مادون قرمز نزدیک (NIR) پیش‌بینی‌کننده‌های مناسب‌تری برای فعالیت فتوسنتزی پوشش گیاهی هستند و به طور مؤثر با زیست‌توده ارتباط دارند (۴۸). این شاخص‌ها اغلب برای برآورد زیست‌توده استفاده می‌شوند (۱۹). شاخص NDVI به طور گسترده برای برآورد زیست‌توده مورد استفاده قرار گرفته، اما به شدت تحت تأثیر پس‌زمینه خاک قرار می‌گیرد (۲۷). بنابراین، شاخص SAVI که

شاخص‌های گیاهی مورد مطالعه بر اساس کارایی آن‌ها در برآورد زیست‌توده در منابع مختلف انتخاب شدند (۱۴، ۲۴، ۴۷، ۵۷ و ۵۹). در این مطالعه مؤثرترین شاخص‌ها در برآورد میزان زیست‌توده گندم به ترتیب شاخص‌های EVI، CIgreen، PSRI، CRI، VARI و GNDVI در مدل رگرسیون خطی چندگانه و شاخص‌های GI، SAVI، ARVI، CRI، EVI، NDWI و MSR در مدل شبکه عصبی مصنوعی بودند.

در برخی مطالعات از شاخص‌های کلروفیل برای تخمین زیست‌توده محصول استفاده شد (۱۰ و ۲۲). Gitelson و همکاران (۲۰۰۳b) شاخص CIgreen را برای برآورد زیست‌توده برگ کانوپی ذرت به کار بردند (۲۲). در مطالعه Cheng و همکاران (۲۰۱۷) شاخص کلروفیل گروه CI بهترین رابطه را با زیست‌توده کل ($R^2 = 0.81$) در مراحل رشدی قبل از سنبله‌دهی برنج نشان داد (۱۰). شاخص‌های PSRI (۴۱) و CRI (۲۳) برای برآورد رنگدانه‌های برگ ایجاد شده‌اند.

Wang و همکاران (۲۰۰۸) از شاخص‌های RVI، NDVI، GNDVI، SAVI، OSAVI و RDVI برای برآورد بیوماس گندم استفاده کردند (۵۷). در مطالعه Liu و همکاران (۲۰۱۹) به ترتیب شاخص‌های CIred، edge، NDVI، RVI و VARI به دست آمده از تصاویر UAV به عنوان شاخص‌های مؤثر در برآورد زیست‌توده کلزای زمستانه با مدل RF بود. این شاخص‌ها به ساختار کانوپی و زیست‌توده و همچنین، رنگدانه و محتوای N حساس بودند (۳۸). Prabhakara و همکاران (۲۰۱۵) از شاخص‌های نظیر EVI، NGRD، VARI، NDVI، GNDVI و SAVI برای برآورد زیست‌توده گیاهان پوششی زمستانه با استفاده از سنسور CROPSCAN استفاده کردند (۴۷). مقایسه مدل‌های رگرسیون چند متغیره و شبکه عصبی مصنوعی: جدول ۴ شاخص‌های آماری برای ارزیابی مدل‌های ایجاد شده برای برآورد زیست‌توده گندم را نشان می‌دهد. در این جدول مشاهده می‌شود که مقادیر R^2 به دست آمده برای زیست‌توده گندم برای مدل رگرسیون خطی چندمتغیره برابر 0.78 و برای مدل ANN برای داده‌های آموزش برابر 0.83 و برای داده‌های آزمون 0.85 بوده است. همچنین، مقادیر RMSE به دست آمده برای زیست‌توده گندم برای مدل رگرسیون خطی چند متغیره برابر $65/68$ گرم در

محدود کننده تأثیر پس‌زمینه خاک است ارائه شده است (۳۰).

شاخص ARVI می‌تواند میزان حساسیت شاخص NDVI به اثرات جوی را کاهش دهد (۳۴). مقاومت شاخص ARVI به اثرات جوی، با تصحیح اثر جوی در باند قرمز، با استفاده از تفاضل بین باندهای آبی و قرمز انجام می‌شود (۳۴). شاخص VARI نیز اثرات جوی را توسط تفریق باند آبی در مخرج کاهش می‌دهد (۲۰). حساسیت VARI به اثرات جوی کمتر از NDVI است و برای تخمین پوشش گیاهی توسعه یافته است. باندهایی که در VARI استفاده می‌شوند به دلیل حساس بودن آن‌ها به پوشش گیاهی انتخاب می‌شوند (۲۰).

شاخص EVI، با بهینه‌سازی سیگنال‌های پوشش گیاهی با استفاده از بازتاب باند آبی، به منظور اصلاح همزمان سیگنال‌های پس‌زمینه خاک و کاهش اثرات جوی مانند پراکندگی ذرات ایجاد شده است (۳۰). شاخص EVI حساسیت بهتری را برای اندازه‌گیری پوشش گیاهی که زیست‌توده یا LAI بالایی دارند، نشان می‌دهد (۲۹).

در شاخص NDWI باند قرمز توسط یک باند مادون قرمز که در منطقه جذب آب بین 0.9 و $2/5$ میکرومتر واقع شده، جایگزین شده است (۱۶). طول موج‌های SWIR (مادون قرمز کوتاه) بهتر از طول موج‌های قرمز به داخل کانوپی نفوذ می‌کنند. به این ترتیب، مشکلات اشباع برخی از شاخص‌های گیاهی رایج با استفاده از طول موج‌های قرمز و NIR کاهش می‌یابد. طول موج‌های SWIR مربوط به محتوای آب کانوپی است که ارتباط نزدیکی با زیست‌توده کانوپی و شاخص سطح برگ دارد (۱۳). طیف‌های NIR و SWIR به خصوصیات جذب محتوای آب گیاه، سلولز، لیگنین و نشاسته حساس هستند، و برای برآورد زیست‌توده مفید می‌باشند (۲۴).

اسپکترومتر اندازه‌گیری کردند و پس از محاسبه شاخص‌های گیاهی مدل‌های رگرسیون چندگانه و شبکه عصبی را برای برآورد زیست‌توده گندم زمستانه مورد استفاده قرار دادند و گزارش کردند که مدل‌های شبکه عصبی در برآورد زیست‌توده گیاهی از مدل‌های رگرسیون خطی برترند (۵۸). سایاگو و بوکو (۲۰۱۸) نیز مدل‌های خطی و غیرخطی را برای ارزیابی عملکرد سویا و ذرت با استفاده از داده‌های ماهواره لندست ۸ و اسپات ۵ در آرژانتین به کار بردند و گزارش کردند که ضریب تبیین مدل‌های ANN و رگرسیون چندگانه برای سویا به ترتیب ۰/۹۰ و ۰/۸۲ و برای ذرت به ترتیب ۰/۹۲ و ۰/۸۸ بودند که بسیار نزدیک به نتایج تحقیق حاضر می‌باشد (۵۳).

ایوبی و همکاران (۲۰۱۱) برای تخمین زیست‌توده جو کارایی مدل‌های شبکه عصبی مصنوعی (با $R^2=0.93$ و $RMSE=0.016 \text{ Mg ha}^{-1}$) و رگرسیون خطی چندگانه را (با $R^2=0.79$ و $RMSE=0.047 \text{ Mg ha}^{-1}$) مقایسه کردند که نتایج مدل شبکه عصبی از کیفیت بالاتری برخوردار بودند (۴). جین و همکاران (۲۰۱۵) با استفاده از ترکیبی از شاخص‌های گیاهی و پارامترهای قطبی رادار (Radar Polarimetric Parameters, RPPs) حاصل از ماهواره‌های Huanjing (HJ) و RADARSAT-2 و روش رگرسیون چندگانه گام به گام (multiple stepwise regression, MSR) زیست‌توده گندم زمستانه را برآورد کردند و گزارش کردند که پارامترهای مدل R^2 و $RMSE$ به ترتیب ۰/۸۳ و gm^{-2} بودند (۳۳).

مترمربع (۰/۶۵۶۸ تن در هکتار) و برای داده‌های آموزش و آزمون مدل ANN به ترتیب ۵۳/۹۱ و ۴۶/۷۴ گرم در مترمربع (۰/۵۳۹۱ و ۰/۴۶۷۴ تن در هکتار) بود.

باتوجه به مفاهیم موجود هرچه مقدار ضریب تبیین بیشتر و مقدار ریشه میانگین مربعات خطا برای یک مدل کمتر باشد، دقت مدل بالاتر و توانایی آن برای پیش‌بینی بیشتر است. مقایسه شاخص‌های آماری بدست آمده از مدل‌های رگرسیون خطی چندمتغیره و ANN نشان داد که مدل ANN با مشخصات تعیین شده نسبت به مدل رگرسیون خطی چندمتغیره در پیش‌بینی زیست‌توده گندم بهتر عمل کرده و توانایی بیشتری در برآورد زیست‌توده گندم دارد.

وجود رابطه احتمالاً غیرخطی بین پارامترهای ورودی و هدف یا خروجی مدل ANN سبب بالاتر بودن کیفیت خروجی این مدل شده است، زیرا در مدل شبکه عصبی مصنوعی روابط با استفاده از توابع غیرخطی برآورد می‌شوند و مدل‌های ANN قابلیت انعطاف‌پذیری بیشتری در برآورد روابط غیرخطی نسبت به مدل‌های رگرسیونی دارند. علاوه بر این، قدرت پیش‌بینی‌کنندگی بالاتر روش ANN احتمالاً مربوط به توانایی بیشتر و قدرت تحمل خطای بیشتر این روش نسبت به روش رگرسیون خطی چندمتغیره بود.

نتایج به دست آمده از این تحقیق با دستاوردهای دیگر پژوهش‌گران مطابقت دارد. یو و همکاران (۲۰۱۸) بازتاب گندم زمستانه را به کمک

جدول ۴- مقایسه شاخص‌های آماری در پیش‌بینی زیست‌توده گندم توسط دو مدل رگرسیون خطی چند متغیره (MLR) و مدل ANN.

Table 4- Comparison of statistical indices for prediction of wheat biomass by two models multiple linear regression (MLR) and ANN.

مدل Model	ضریب تیین R ²	خطای استاندارد تخمین SEE	مقادیر F F value	شاخص جذر میانگین مربعات خطا RMSE	جذر میانگین مربعات خطای نسبی RRMSE	میانگین خطا ME	ضریب تغییرات (درصد) CV (%)
رگرسیون خطی چندگانه MLR	0.78	52.26	159.89*	65.68	11.40	29.91	23
شبکه عصبی Train-Data	0.83	45.13	391.39*	53.91	9.80	8.32	20
مصنوعی ANN Test-Data	0.85	45.02	90.80**	46.74	8.52	-4.82	20

نتیجه‌گیری کلی

در این مطالعه، شاخص‌های گیاهی، روش‌های رگرسیون خطی چندمتغیره و شبکه عصبی مصنوعی برای تعیین معادلات رگرسیون تجربی برای تخمین زیست‌توده گندم زمستانه مورد استفاده قرار گرفتند. نتایج نشان دادند که مدل ANN دارای ضریب تبیین بالاتر و شاخص‌های خطای کمتری ($R^2=0/83$) و $RMSE=53/91 \text{ g/m}^2$ برای داده‌های آموزش و $R^2=0/85$ و $RMSE=46/74 \text{ g/m}^2$ برای داده‌های آزمون نسبت به رگرسیون چند متغیره ($R^2=0/78$) و $RMSE=52/26 \text{ g/m}^2$ می‌باشد. به عبارت دیگر، روش ANN در پیش‌بینی زیست‌توده گندم دارای دقت پیش‌بینی بالاتری نسبت به روش رگرسیون خطی چندمتغیره بود. مؤثرترین شاخص‌ها در برآورد میزان زیست‌توده گندم به ترتیب شاخص‌های EVI،

GNDVI و VARI، CRI، PSRI، CIgreen در مدل رگرسیون خطی چندگانه و شاخص‌های SAVI، GI، ARVI، CRI، EVI، NDWI، MSR و NDVI در مدل شبکه عصبی مصنوعی بودند. به دلیل ارتباط مستقیم بین زیست‌توده و عملکرد محصول، زیست‌توده می‌تواند به طور غیرمستقیم برای برآورد عملکرد گندم، پیش‌بینی تولید مازاد و یا کمبود در کشور مورد استفاده قرار گیرد. علاوه بر این، اطلاعات مربوط به رصد زیست‌توده در طول فصل رشد می‌تواند تأثیر عوامل محیطی مثل آبیاری، آفات و امراض و یا کمبود یا مسمومیت عناصر غذایی گیاهی را منعکس نماید. پیشنهاد می‌شود در مطالعات آینده، دیگر روش‌های الگوریتم‌های یادگیری ماشین نیز برای برآورد زیست‌توده مورد آزمون قرار گیرند.

منابع

1. Ali, I., Greifeneder, F., Stamenkovic, J., Neumann, M., and Notarnicola, C. 2015. Review of machine learning approaches for biomass and soil moisture retrievals from remote sensing data. *Remote Sens.* 7: 12. 16398-16421.
2. Atzberger, C., Darvishzadeh, R., Immitzer, M., Schlerf, M., Skidmore, A., and le Maire, G. 2015. Comparative analysis of different retrieval methods

for mapping grassland leaf area index using airborne imaging spectroscopy. *Int. J. Appl. Earth Obs. Geoinf.* 43: 19-31.

3. Atzberger, C., Guérif, M., Baret, F., and Werner, W. 2010. Comparative analysis of three chemometric techniques for the spectroradiometric assessment of canopy chlorophyll content in winter wheat. *Comput. Electron. Agric.* 73: 2. 165-173.

4. Ayoubi, S., and Sahrawat, K.L. 2011. Comparing multivariate regression and artificial neural network to predict barley production from soil characteristics in northern Iran. *Arch. Agron. Soil Sci.* 57: 5. 549-565.
5. Berger, K., Atzberger, C., Danner, M., D'Urso, G., Mauser, W., Vuolo, F., and Hank, T. 2018. Evaluation of the PROSAIL model capabilities for future hyperspectral model environments: a review study. *Remote Sens.* <https://doi.org/10.3390/rs10010085>
6. Bolton, D.K., and Friedl, M.A. 2013. Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics. *Agric. For. Meteorol.* 173: 74-84.
7. Broge, N.H., and Leblanc, E. 2000. Comparing predictive power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. *Remote Sens. Environ.* 76: 2. 156-172.
8. Chen, J.M. 1996. Evaluation of vegetation indices and modified simple ratio for boreal applications. *Can. J. Remote. Sens.* 22: 3. 229-242.
9. Chen, P., Haboudane, D., Tremblay, N., Wang, J., Vigneault, P., and Li, B. 2010. New spectral indicator assessing the efficiency of crop nitrogen treatment in corn and wheat. *Remote Sens. Environ.* 114: 1987-1997.
10. Cheng, T., Song, R., Li, D., Zhou, K., Zheng, H., Yao, X., Tian, Y., Cao, W., and Zhu, Y. 2017. Spectroscopic estimation of biomass in canopy components of paddy rice using dry matter and chlorophyll indices. *Remote Sens.* 9: 319.
11. Cilia, C., Panigada, C., Rossini, M., Meroni, M., Busetto, L., Amaducci, S., Boschetti, M., Picchi, V., and Colombo, R. 2014. Nitrogen status assessment for variable rate fertilization in maize through hyperspectral imagery. *Remote Sens.* 6: 7. 6549-6565.
12. Clevers, J.G.P.W. 1986. The application of a vegetation index in correcting the infrared reflectance for soil background. *Int. Arch. Photogramm. Rem. Sens.*, Balkema, Rotterdam, Boston 26: 221-226.
13. Clevers, J.G.P.W., van der Heijden, G.W.A.M., Verzakov, S., and Schaepman, M.E. 2007. Estimating grassland biomass using SVM band shaving of hyperspectral data. *Photogramm Eng. Remote Sens.* 73: 10. 1141-1148.
14. Du, Y., Wang, J., Liu, Z., and Lin, Y. 2019. Estimation and multiscale transformation of aboveground biomass: an hgsu-oriented approach based on multisource data. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 12: 7. 2388-2396.
15. Feret, J.B., Gitelson, A.A., Noble, S.D., and Jacquemoud, S. 2017. PROSPECT-D: towards modeling leaf optical properties through a complete lifecycle. *Remote Sens. Environ.* 193: 204-215.
16. Gao, B. 1996. NDWI-A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens. Environ.* 58: 257-266.
17. Gao, S., Niu, Z., Huang, N., and Hou, X.H. 2013. Estimating the leaf area index, height and biomass of maize using HJ-1 and RADARSAT-2. *Int. J. Appl. Earth Obs. Geoinf.* 24: 1-8.
18. Gilles, L., Mariehelene, J., and Francois, G. 2008. Diagnosis tool for plant and crop N status in vegetative stage. *Eur. J. Agron.* 28: 4. 614-624.
19. Gitelson, A. 2004. Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. *J. Plant Physiol.* 161: 2. 165-173.
20. Gitelson, A.A., Gritz, Y., and Merzlyak, M.N. 2003a. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *J. Plant Physiol.* 160: 3. 271-282.
21. Gitelson, A.A., Kaufman, Y.J., Stark, R., and Rundquist, D. 2002a. Novel algorithms for remote estimation of vegetation fraction. *Remote Sens. Environ.* 80: 1. 76-87.

22. Gitelson, A.A., Vina, A., Arkebauer, T.J., Rundquist, D.C., Keydan, G.P., and Leavitt, B. 2003b. Remote estimation of leaf area index and green leaf biomass in maize canopies. *Geophys. Res. Lett.* 30: 5. 1248.
23. Gitelson, A.A., Zur, Y., Chivkunova, O.B., and Merzlyak, M.N. 2002b. Assessing carotenoid content in plant leaves with reflectance spectroscopy. *Photochem. Photobiol.* 75: 3. 272-281.
24. Gnyp, M.L., Bareth, G., Li, F., Lenz-Wiedemann, V.I.S. Koppe, W., Miao, Y., Hennig, S.D., Jia, L., Laudien, R., Chen, X., and Zhang, F. 2014a. Development and implementation of a multiscale biomass model using hyperspectral vegetation indices for winter wheat in the North China Plain. *International Journal of Applied Earth Observation and Geoinformation* 33: 232-242.
25. Gnyp, M.L., Miao, Y.X., Yuan, F., Ustin, S.L., Yu, K., Yao, Y.K., Huang, S.Y., and Bareth, G. 2014b. Hyperspectral canopy sensing of paddy rice aboveground biomass at different growth stages. *Field Crops Res.* 155: 42-55.
26. Goel, N.S., and Qin, W.H. 1994. Influences of canopy architecture on relationships between various vegetation indices and LAI and FPAR: a computer simulation. *Remote Sens. Reviews* 10: 4. 309-347.
27. Haboudane, D., Miller, J.R., Tremblay, N., Zarco-Tejada, P.J., and Dextraze, L. 2002. Integration of hyperspectral vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote Sens. Environ.* 81: 2-3. 416-426.
28. Huang, J., Sedano, F., Huang, Y., Ma, H., Li, X., Liang, S., Tian, L., Zhang, X., Fan, J., and Wu, W. 2016. Assimilating a synthetic Kalman filter leaf area index series into the WOFOST model to improve regional winter wheat yield estimation. *Agric. For. Meteorol.* 216: 188-202.
29. Huete, A., Didan, K., Miura, T., Rodriguez, E.P., Gao, X., and Ferreira, L.G. 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sens. Environ.* 83: 195-213.
30. Huete, A.R. 1988. A soil-adjusted vegetation index (SAVI). *Remote Sens. Environ.* 25: 3. 295-309.
31. Huete, A.R., Liu, H.Q., Batchily, K., and Leeuwen, W. 1997. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote Sens. Environ.* 59: 3. 440-451.
32. Jacquemoud, S., Verhoef, W., Baret, F., Bacour, C., Zarco-Tejada, P.J., Asner, G.P., François, C., and Ustin, S.L. 2009. PROSPECT + SAIL models: a review of use for vegetation characterization. *Remote Sens. Environ.* 113: S56-S66.
33. Jin, X.L., Yang, G.J., Xu, X.G., Yang, H., Feng, H.K., Li, Z.H., Shen, J.X., Zhao, C.J., and Lan, Y.B. 2015. Combined multi-temporal optical and radar parameters for estimating LAI and biomass in winter wheat using HJ and RADARSAR-2 data. *Remote Sens.* 7: 10. 13251-13272.
34. Kaufman, Y.J. and Tanre, D. 1992. Atmospherically Resistant Vegetation Index (ARVI) for EOS- MODIS. *IEEE Trans Geosci Remote Sens.* 30: 2. 261-270.
35. Kross, A., McNairn, H., Lapen, D., Sunohara, M., and Champagne, C. 2015. Assessment of RapidEye vegetation indices for estimation of leaf area index and biomass in corn and soybean crops. *Int. J. Appl. Earth Obs. Geoinf.* 34:1. 235-248.
36. Kumar, L. and Mutanga, O. 2017. Remote sensing of above-ground biomass. *Remote Sens.* 9. 935.
37. Liu, Y., Liu, S., Li, J., Guo, X., Wang, S., and Lu, J. 2019. Estimating biomass of winter oilseed rape using vegetation indices and texture metrics derived from UAV multispectral images. *Comput. Electron. Agric.* 166: 105026.
38. Lobell, D.B. 2013. The use of satellite data for crop yield gap analysis. *Field Crops Res.* 143: 56-64.
39. Lu, D. 2006. The potential and challenge of remote sensing-based biomass estimation. *Int. J. Remote Sens.* 27: 7. 1297-1328.

40. Marshall, M., and Thenkabail, P. 2015. Developing in situ non-destructive estimates of crop biomass to address issues of scale in remote sensing. *Remote Sens.* 7: 1. 808-835.
41. Merzlyak, M.N., Gitelson, A.A., Chivkunova, O.B., and Rakitin, Y.R. 1999. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. *Physiol. Plant.* 106: 135-141.
42. Mosleh Ghahfarokhi, Z. 2016. Soil digital mapping, land suitability and optimization cultivation model for major products plains of Shahrekord. PhD thesis pedology, Faculty of Agriculture, University of Shahrekord, Iran. (In Persian)
43. Padilla, F.L.M., Maas, S.J., González-Dugo, M.P., Mansilla, F., Rajan, N., Gavilán, P., and Domínguez, J. 2012. Monitoring regional wheat yield in Southern Spain using the GRAMI model and satellite imagery. *Field Crops Res.* 130: 145-154.
44. Paltridge, G., and Barber, J. 1988. Monitoring grassland dryness and fire potential in Australia with NOAA/AVHRR data. *Remote Sens. Environ.* 25: 3. 381-394.
45. Pearson, R.L., and Miller, L.D. 1972. Remote mapping of standing crop biomass for estimation of the productivity of the shortgrass prairie. *Remote Sens. Environ.* 8: 1348-1355.
46. Penuelas, J., Baret, F., and Filella, I. 1995. Semi-empirical indices to assess carotenoids/chlorophyll-a ratio from leaf spectral reflectance. *Photosynthetica.* 31: 2. 221-230.
47. Prabhakara, K., Hively, W.D., and McCarty, G.W. 2015. Evaluating the relationship between biomass, percent groundcover and remote sensing indices across six winter cover crop fields in Maryland, United States. *Int. J. Appl. Earth Obs. Geoinf.* 39: 88-102.
48. Qi, J., Chehbouni, A., Huete, A.R., Kerr, Y.H., and Sorooshian, S. 1994. A modified soil adjusted vegetation index. *Remote Sens. Environ.* 48: 2. 119-126.
49. Ren, H. and Feng, G. 2014. Are soil-adjusted vegetation indices better than soil-unadjusted vegetation indices for above-ground green biomass estimation in arid and semi-arid grasslands? *J. Br. Grassl. Soc.* 70: 4. 611-619.
50. Rondeaux, G., Steven, M., and Baret, F. 1996. Optimization of soil-adjusted vegetation indices. *Remote Sens. Environ.* 55: 2. 95-107.
51. Roujean, J.L., and Breon, F.M. 1995. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sens. Environ.* 51: 3. 375-384.
52. Rouse, J.W., Haas, R.H., Schell, J.A., and Deering, D.W., 1974. Monitoring vegetation systems in the great plains with ERTS. Third ERTS Symposium, NASA SP. 351: 309-317.
53. Sayago, S., and Bocco, M. 2018. Crop yield estimation using satellite images: comparison of linear and non-linear models. *Agriscientia.* 35: 1-9.
54. Shirani, H. 2017. Artificial neural networks with an application in agricultural and natural resource sciences. Vali-e-Asr University of Rafsanjan Press. 320 p. (In Persian)
55. Tucker, C.J. 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* 8:2. 127-150.
56. Wang, D.C., Wang, J.H., Jin, N., Wang, Q., Li, C.J., Huang, J.F., Wang, Y., and Huang, F. 2008. ANN-based wheat biomass estimation using canopy hyperspectral vegetation indices. *Trans. CSAE* 24: 196-201.
57. Wang, L., Zhou, X., Zhu, X., Dong, Z., and Guo, W. 2016. Estimation of biomass in wheat using random forest regression algorithm and remote sensing data. *Crop J.* 4: 3. 212-219.
58. Yue, J., Feng, H., Yang, G., and Li, Z. 2018. A comparison of regression techniques for estimation of above-ground winter wheat biomass using near-surface spectroscopy. *Remote Sens.*
<https://doi.org/10.3390/rs10010066>
59. Yue, J., Yang, G., Li, C., Li, Z., Wang, Y., Feng, H., and Xu, B. 2017. Estimation of winter wheat above-ground biomass using unmanned aerial

- vehicle-based snapshot hyperspectral sensor and crop height improved models. *Remote Sens.* 9: 7. 708.
60. Yue, J., Yang, G., Tian, Q., Feng, H., Xu, K., and Zhou, C. 2019. Estimate of winter-wheat above-ground biomass based on UAV ultrahighground-resolution image textures and vegetation indices. *ISPRS J. Photogramm. Remote Sens.* 150: 4. 226-244.
61. Zarco-Tejada, P.J., Miller, J.R., Mohammed, G.H., Noland, T.L., and Sampson, P.H., 1999. Optical Indices as Bioindicators of Forest Condition from Hyperspectral CASI data. 19th Symposium of the European Association of Remote Sensing Laboratories (EARSeL).