


Investigating the relationship between drought indices and maize yield using random forest method (case study: Qazvin plain irrigation network)

Ramezani Etedali, H.¹  | Ahmadi, M.²

1. Professor, Department of Water Engineering, Imam Khomeini International University, Qazvin, Iran.
2. PhD in Irrigation and Drainage, Imam Khomeini International University, Qazvin, Iran.

Corresponding Author E-mail: ramezani@eng.ikiu.ac.ir

(Received: 11 Jul 2024, Revised: 25 Sep 2024, Accepted: 22 Oct 2024, Published online: 22 Oct 2024)

Abstract

Pre-harvest crop yield prediction is crucial for food security, grain trade, and policy making. In this research, the use of random forest method in simulating maize yield in ten selected fields in Qazvin plain irrigation network during 2019-2020 period using NDVI, MSAVI, and EVI drought indices has been investigated. Sentinel 2 satellite was used for drought indices calculation. The results were evaluated using R^2 , NRMSE, and MBE GOF (Goodness of Fit) statistical tests. To investigate the relationship between drought indices and maize yield, seven scenarios were defined. The results showed that the random forest model in scenarios one, three, and four in the test stage with a significant probability of 95% respectively (P -value=0.00) and an explanation coefficient of more than 0.8 and a small amount of NRMSE is a suitable estimate of the maize yield.

Keywords: maize yield, drought indicators, Sentinel 2, machine learning

Cite this article: Ramezani Etedali, H., & ahmadi, M. (2024). Investigating the relationship between drought indices and maize yield using random forest method (case study: Qazvin plain irrigation network). Journal of the Nivar, 48(126-127), 127-137. DOI: <https://doi.org/10.30467/nivar.2024.467444.1299>

E-mail: (2) mojganahmadi90@gmail.com



بررسی ارتباط بین شاخص‌های خشکسالی با عملکرد ذرت با استفاده از روش جنگل تصادفی (مطالعه موردی: شبکه آبیاری دشت قزوین)

هادی رمضانی اعتدالی^۱ | مژگان احمدی^۲

۱. استاد، گروه مهندسی آب دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران.

۲. دکتری آبیاری و زهکشی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران.

رایانامه نویسنده مسئول: ramezani@eng.ikiu.ac.ir

(دریافت: ۱۴۰۳/۰۴/۲۱، بازنگری: ۱۴۰۳/۰۷/۰۴، پذیرش: ۱۴۰۳/۰۸/۰۱، انتشار آنلاین: ۱۴۰۳/۰۸/۰۱)

چکیده

برآوردهای سریع و دقیق عملکرد با افزایش دسترسی و تنوع محصولات ماهواره‌ای جهانی و توسعه سریع الگوریتم‌های جدید همچنان یک هدف برای کشاورزی دقیق و امنیت غذایی است. پیش‌بینی عملکرد محصول قبل از برداشت برای امنیت غذایی، تجارت غلات و سیاست‌گذاری بسیار مهم است. سنجش از دور و روش‌های مختلف یادگیری ماشین مانند جنگل تصادفی برای تجزیه و تحلیل داده‌های مقیاس بزرگ با عملکرد محاسباتی بالا، توانایی پیش‌بینی دقیق عملکرد محصول را افزایش داده است. در این پژوهش به بررسی کاربرد روش جنگل تصادفی در شبیه‌سازی عملکرد ذرت در ده مزرعه انتخابی در شبکه آبیاری دشت قزوین طی دوره ۲۰۱۹-۲۰۲۰ با استفاده از شاخص‌های خشکسالی NDVI، MSAVI و EVI پرداخته شده است. جهت محاسبه شاخص‌های خشکسالی از ماهواره سنتینل ۲ استفاده شد. نتایج با استفاده از آماره‌های نکویی برازش R^2 ، NRMSE و MBE ارزیابی شد. به منظور بررسی ارتباط بین شاخص‌های خشکسالی و عملکرد ذرت هفت سناریو تعریف شد. نتایج نشان داد مدل جنگل تصادفی در سناریوهای یک، سه و چهار در مرحله test با احتمال معنی داری به ترتیب ۹۵٪ (P-value=...) و ضریب تبیین بیش از ۰/۸ و مقدار اندک NRMSE تخمین مناسبی از عملکرد ذرت داشته است.

کلیدواژه‌ها: عملکرد ذرت، شاخص‌های خشکسالی، سنتینل ۲، یادگیری ماشین

۱. مقدمه

خوراک دام است که نقش مهمی در سیستم‌های جهانی کشاورزی و تغذیه ایفا می‌کند (رانوم و همکاران، ۲۰۱۴؛ ارنشتیان و همکاران، ۲۰۲۲ و گروت و همکاران، ۲۰۲۱). با پیش‌بینی رشد جمعیت جهان، افزایش تقاضا برای محصولات غذایی و تغییر رژیم غذایی، افزایش عملکرد، ثبات عملکرد و کیفیت ذرت از اهمیت کلیدی برخوردار است (فرونا و همکاران، ۲۰۱۹ و نوپان و همکاران، ۲۰۲۲). تغییرات اقلیمی متعدد از جمله تنش گرمایی و شرایط خشکی منجر به کاهش پر شدن دانه غلات با کاهش باروری سنبلیچه و افزایش سرعت

تخمین عملکرد محصول یک جنبه بسیار مهم در تولید مواد غذایی است زیرا اطلاعاتی را در اختیار سیاست‌گذاران و تصمیم‌گیرندگان قرار می‌دهد که می‌تواند عرضه غذا را نه تنها برای یک کشور هدایت کند، بلکه بر پویایی واردات و صادرات آن نیز تأثیر بگذارد. سنجش از دور این توانایی را دارد که ابزار داده شده را برای پیش‌بینی عملکرد محصول قبل از برداشت فراهم کند. ذرت دومین محصول کشت شده در سطح جهان پس از گندم است و یکی از اجزای کلیدی

استناد: رمضانی اعتدالی، هادی، و احمدی، مژگان. (۱۴۰۳). بررسی ارتباط بین شاخص‌های خشکسالی با عملکرد ذرت با استفاده از روش جنگل تصادفی (مطالعه موردی: شبکه آبیاری دشت قزوین). مجله نیوار، ۴۸ (۱۲۶-۱۲۷)، ۱۳۷-۱۲۷. DOI: <https://doi.org/10.30467/nivar.2024.467444.1299>

رایانامه: (۲) mojganahmadi90@gmail.com



عملکرد محصول در مناطق مختلف محاسبه و استفاده شده‌اند (فنگ و همکاران، ۲۰۲۱ و ما و همکاران، ۲۰۲۱).

انواع مدل‌های یادگیری ماشینی وجود دارد که می‌توان از آنها برای پیش‌بینی عملکرد محصول استفاده کرد (کای و همکاران، ۲۰۱۹ و خاکی و همکاران، ۲۰۲۱). فنگ و همکاران (۲۰۲۱) یک مدل شبکه عصبی مکانی-زمانی ایجاد کردند که از داده‌های سنجش از دور، خاک و آب و هوا برای پیش‌بینی عملکرد گندم زمستانه استفاده می‌کند. آنها همچنین نتایج خود را با سایر مدل‌های معیار مانند رگرسیون بردار پشتیبان مقایسه کردند و نتایج نشان می‌دهد که مدل‌های مکانی-زمانی می‌توانند پیش‌بینی عملکرد گندم زمستانه را تا ۲۶٪ درصد از نظر میانگین درصد مطلق خطا بهبود بخشند.

ما و همکاران (۲۰۲۱) از شبکه‌های عصبی بیزین (BNN) برای پیش‌بینی عملکرد ذرت در ایالات متحده استفاده کردند و به ضریب تبیین ۰/۷۷ دست یافتند. نتایج شبکه عصبی بیزین با سایر مدل‌ها مقایسه شد و نتایج آنها نشان می‌دهد که شبکه عصبی بیزین می‌تواند خطای کلی را ۶ تا ۲۳ درصد کاهش دهد (ما و همکاران، ۲۰۲۱). مطالعه دیگری بر اساس جفت کردن مدل‌های فیزیکی با مدل‌های یادگیری ماشینی گزارش داد که گنجاندن الگوریتم‌های یادگیری ماشینی می‌تواند دقت مدل‌ها را بهبود بخشد (شاهحسینی و همکاران، ۲۰۲۱). مشاهدات ماهواره‌ای می‌تواند در ارائه اطلاعات در مورد نوع محصول، شرایط محصول و عملکرد محصول از سطح مزرعه تا مناطق جغرافیایی گسترده مانند کشورها نقش داشته باشد.

در این پژوهش شبیه‌سازی عملکرد ذرت در ده مزرعه منتخب در شبکه آبیاری دشت قزوین با استفاده از شاخص‌های NDVI، EVI و MSAVI و به کارگیری روش جنگل تصادفی انجام شد.

تغرق می‌شود که در نهایت باعث کاهش قابل توجه عملکرد غلات می‌شود (تیگگلار و همکاران، ۲۰۱۸).

ابزارهای دقیق و قابل اعتماد پیش‌بینی عملکرد می‌توانند نقش اساسی در حمایت از تدوین سیاست، و فرآیند تصمیم‌گیری در کشاورزی ایفا کنند (کوردوبا و همکاران، ۲۰۱۶). عمدتاً به این دلیل که در گذشته منبع محدودی از داده‌ها با وضوح زمانی و مکانی کافی برای برآورد دقیق عملکرد محصول در مزرعه وجود داشت، بیشتر مدل‌های توسعه یافته برای اهداف پیش‌بینی عملکرد بر حوزه‌های بزرگ تمرکز داشتند (دی رینزو و همکاران، ۲۰۰۰). امروزه، داده‌های ماهواره‌ای با تصاویر با وضوح بالا مانند ماهواره‌های Skysat، Sentinel-2 و RapidEye در دسترس هستند (آزاری و همکاران، ۲۰۱۷).

داده‌های سنجش از دور می‌توانند اطلاعاتی مانند دما، بارش، رطوبت خاک، سلامت پوشش گیاهی و تنش آبی را ارائه دهند. یکی از مزیت‌های داده‌های سنجش از دور، در دسترس بودن آنها است. تحقیقات اولیه (ایدسو و همکاران، ۱۹۹۷) اثربخشی داده‌های سنجش از دور را در پیش‌بینی عملکرد محصول نشان داده است. از آن زمان، مطالعات زیادی (یوان و همکاران، ۲۰۱۶؛ ما و همکاران، ۲۰۲۱ و سان و همکاران، ۲۰۱۹) در مورد استفاده از اطلاعات به دست آمده از ماهواره برای پایش محصول و پیش‌بینی عملکرد انجام شده است. شاخص‌هایی مانند شاخص گیاهی تفاوت نرمال شده (NDVI^۱)، شاخص گیاهی افزایش یافته (EVI^۲)، شاخص گیاهی تعدیل شده با خاک (SAVI^۳)، شاخص کلروفیل سبز (GCI^۴) و شاخص تفاوت نرمال شده آب (NDWI^۵) معمولاً برای توصیف شرایط پوشش گیاهی استفاده می‌شوند و اخیراً برای مطالعه عملکرد محصول استفاده شده است (فنگ و همکاران، ۲۰۲۱؛ هانت و همکاران، ۲۰۱۹؛ ما و همکاران، ۲۰۲۱ و وانگ و همکاران، ۲۰۲۰). NDVI و EVI به عنوان متغیرهای مستقل در ترکیب با چندین متغیر دیگر مانند داده‌های آب و هوا و خاک برای پیش‌بینی

^۴ Green Chlorophyll Index

^۵ Normalized Difference Water Index

^۶ Bayesian neural network

^۱ Normalized Difference Vegetation Index

^۲ Enhanced Vegetation Index

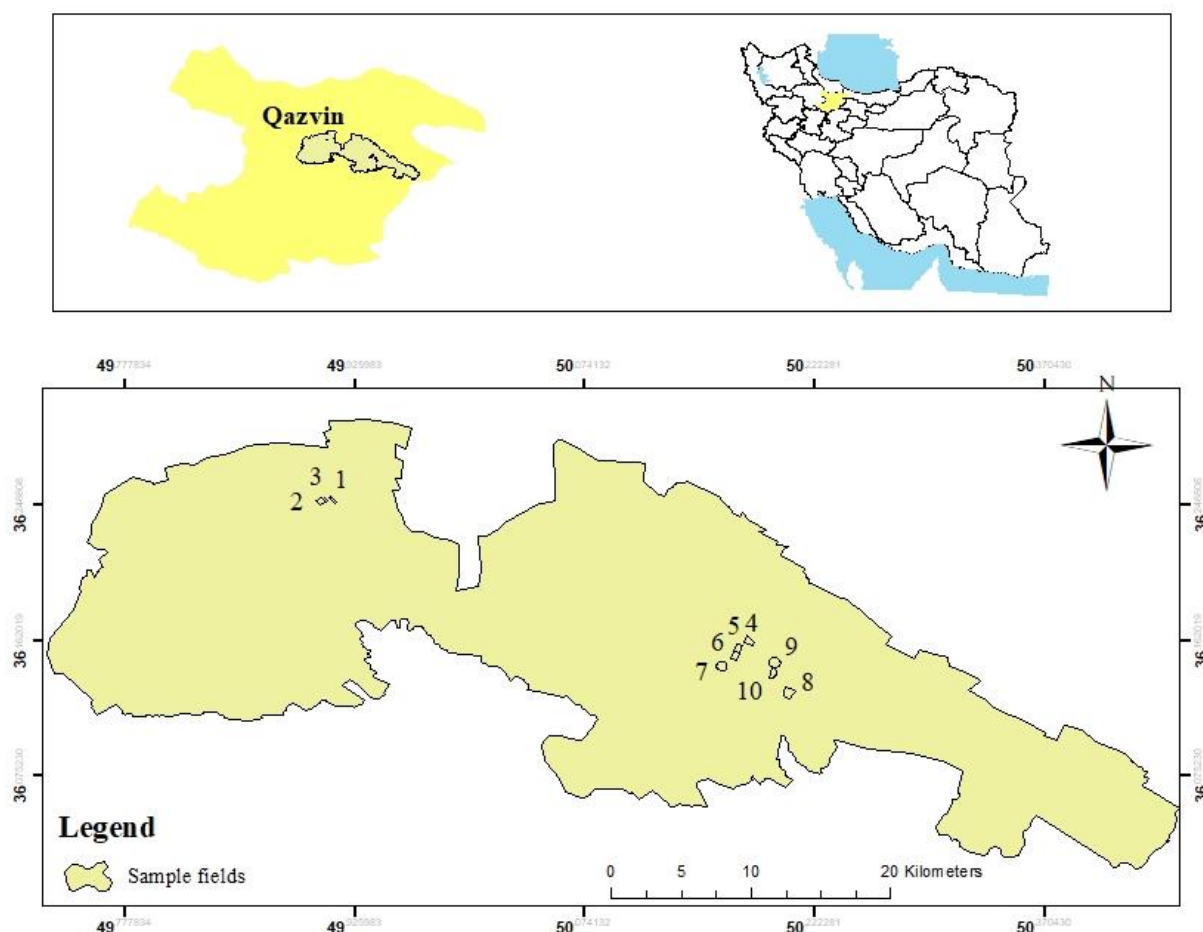
^۳ Soil-Adjusted Vegetation Index

۲. مواد و روش ها

۱-۲. منطقه مورد مطالعه

استان قزوین با مساحت ۱۵۸۲۰ کیلومتر مربع در بخش شمال غربی کشور واقع شده است. این استان در حوزه مرکزی ایران بین ۴۸ درجه و ۴۵ دقیقه تا ۵۰ درجه و ۵۱ دقیقه طول شرقی از نصف النهار گرینویچ و ۳۵ درجه و ۲۴ دقیقه تا ۳۶ درجه و ۴۸ دقیقه عرض شمالی نسبت به خط استوا قرار دارد و با استان‌های مازندران، گیلان، همدان، زنجان، مرکزی و البرز همسایه است. محدوده مورد مطالعه اراضی پایین دست شبکه آبیاری دشت قزوین می‌باشد و در فواصل جغرافیایی بین

عرض‌های شمال سی و شش درجه تا سی و شش درجه و بیست ثانیه و طول‌های شرقی چهل و نه درجه و چهل دقیقه تا پنجاه درجه و سی و پنج دقیقه و سی و پنج ثانیه قرار گرفته است. این دشت دارای اقلیم نیمه خشک، تابستان‌های گرم و زمستان‌های نیمه سرد است. محصولات زراعی عمده استان شامل گندم، جو و ذرت می‌باشد. در این پژوهش عملکرد ده مزرعه ذرت از سازمان جهاد کشاورزی استان قزوین طی دوره ۲۰۲۰-۲۰۱۹ دریافت شد (شکل ۱). مساحت مزارع در جدول (۱) آورده شده است.



شکل ۱- موقعیت منطقه مورد مطالعه

جدول ۱- مساحت مزارع مورد مطالعه

شماره	مساحت زمین (هکتار)	تعداد پیکسل سنتینل ۲
۱	۷/۴۸	۷۴۸
۲	۱۵/۶۰	۱۵۶۰
۳	۵/۰۹	۵۰۹
۴	۲۰	۲۰۰۰
۵	۲۰	۲۰۰۰
۶	۲۰	۲۰۰۰
۷	۳۰	۳۰۰۰
۸	۳۲	۳۲۰۰
۹	۳۷	۳۷۰۰
۱۰	۲۲	۲۲۰۰

۲-۲-۲. شاخص MSAVI

شاخص پوشش گیاهی تعدیل شده خاک MSAVI برای کاهش اثرات خاک در شاخص (SAVI) طراحی شده است. مقادیر MSAVI از منفی یک تا یک متغیر است، که ۱- تا ۰/۲ خاک لخت را نشان می‌دهد. ۰/۲ تا ۰/۴ مرحله جوانه زنی بذر است و ۰/۴ تا ۰/۶ مرحله رشد برگ است.

(۲)

$$MSAVI = \frac{(2 \times NIR + 1 - \sqrt{\text{pow}((2 \times NIR + 1), 2) - 8 \times (NIR - RED)})}{2}$$

۳-۲-۲. شاخص EVI

شاخص پوشش گیاهی پیشرفته (EVI) شبیه شاخص گیاهی تفاوت نرمال شده (NDVI) است. در واقع در این شاخص اثرات پخش اتمسفر حذف یا تعدیل می‌شود. مقادیر EVI از منفی یک تا یک متغیر است، که برای مناطق با پوشش گیاهی سالم معمولاً بین ۰/۲ تا ۰/۸ است. برای ارزیابی رشد محصول

۲-۲. شاخص‌های خشکسالی

۱-۲-۲. شاخص NDVI

شاخص گیاهی تفاوت نرمال شده (NDVI) یک معیار کاربرد برای تعیین کمیت سلامت و تراکم پوشش گیاهی است. از داده‌های طیف سنجی در دو باند خاص قرمز و مادون قرمز نزدیک محاسبه می‌شود (۱). مقادیر NDVI از منفی یک تا یک متغیر است، که در آن مقادیر منفی عمدتاً از ابرها، آب و برف تشکیل می‌شوند و مقادیر نزدیک به صفر عمدتاً از سنگ‌ها و خاک لخت تشکیل می‌شوند. مقادیر متوسط (از ۰/۲ تا ۰/۳) نشان دهنده درختچه‌ها و علفزارها است، در حالی که مقادیر بزرگ (از ۰/۶ تا ۰/۸) جنگل‌های معتدل و گرمسیری را نشان می‌دهد.

$$(1) NDVI = (NIR - RED) / (NIR + RED)$$

در پیش‌بینی، الگوریتم نتایج همه درخت‌ها را با طبقه بندی یا با رگرسیون تجمع می‌کند. جنگل‌های تصادفی به طور گسترده برای طبقه‌بندی و توابع رگرسیون استفاده می‌شوند، که به دلیل توانایی‌شان در مدیریت داده‌های پیچیده، کاهش بیش‌برازش و ارائه پیش‌بینی‌های قابل اعتماد در محیط‌های مختلف شناخته شده‌اند. در مسائل طبقه بندی، خروجی جنگل تصادفی کلاسی است که توسط اکثر درختان انتخاب شده است. در مسائل رگرسیون، میانگین یا میانگین پیش‌بینی درختان منفرد برگردانده می‌شود. در این پژوهش از نرم افزار R برای اجرای الگوریتم جنگل تصادفی استفاده شده است.

۲-۴. سنتینل ۲

ماهواره سنتینل ۲ توسط سازمان فضایی اروپا به عنوان بخشی از برنامه کوپرنیک برای پشتیبانی از خدماتی همچون بررسی زمین و تغییرات آن، مدیریت مخاطره، امنیت و تغییر اقلیم در ۲۳ ژوئن ۲۰۱۵ (Sentinel-2A) و ۷ مارس ۲۰۱۷ (Sentinel-2B) به فضا پرتاب شد. این ماهواره ۱۳ باند در محدوده مرئی، مادون قرمز نزدیک و مادون قرمز میانی طیف الکترومغناطیس را در سه توان تفکیک ۱۰، ۲۰ و ۶۰ متر با توان رادیومتریکی ۱۲ بیتی برداشت می‌کند. در این پژوهش از تصاویر سنتینل ۲ با قدرت تفکیک مکانی ده متر استفاده شد. ماه‌های تیر، مرداد و شهریور سال ۲۰۲۰ برای محاسبه شاخص‌ها در نظر گرفته شد. برای محاسبه شاخص‌های NDVI، MSAVI و EVI در محیط گوگل ارث انجین از Shape file مزارع استفاده شد و سپس با استفاده از نرم افزار Arc Map میانگین شاخص‌های خشکسالی برای هر Shape file مزرعه محاسبه شد.

۲-۵. آماره‌های ارزیابی

ضریب تبیین یکی از مهم‌ترین معیارهای ارزیابی ارتباط میان دو متغیر X و Y است که به صورت بی بعد نمایش داده می‌شود. این ضریب ارتباط مستقیمی با ضریب همبستگی دارد. به این ترتیب که با جذر گرفتن از ضریب تبیین می‌توان ضریب همبستگی میان دو سری مورد بررسی را به دست آورد. همانند ضریب همبستگی هر چه مقدار ضریب تبیین به

در شرایط پوشش گیاهی متراکم و پوشش گیاهی کم استفاده می‌شود.

(۳)

$$EVI = 2.5 \times ((NIR - RED) / ((NIR + (6 * RED)) - (7.5 * BLUE)) + 1)$$

در این روابط، NIR، باند مادون قرمز نزدیک، RED، باند قرمز و BLUE باند آبی تصاویر سنتینل ۲ است. برای ارزیابی ارتباط بین شاخص‌های خشکسالی و عملکرد ذرت، هفت سناریو در نظر گرفته شده است (جدول ۲). در سناریوهای یک تا سه هر شاخص به صورت جداگانه انتخاب شده است تا ارتباط بین شاخص‌های خشکسالی و عملکرد ذرت بررسی شود. در سناریوهای چهار تا شش شاخص‌ها به صورت ترکیب دوتایی انتخاب شده است و در سناریو هفت اثر ترکیبی هر سه شاخص در ارزیابی ارتباط بین عملکرد و شاخص‌های خشکسالی در نظر گرفته شده است.

جدول ۲- معرفی سناریوها

Index	Scenario number
NDVI	S1
MSAVI	S2
EVI	S3
NDVI-MSAVI	S4
NDVI-EVI	S5
MSAVI-EVI	S6
NDVI-MSAVI-EVI	S7

۲-۳. جنگل تصادفی^۱

جنگل تصادفی یک الگوریتم یادگیری ماشین پر کاربرد است که به تکنیک یادگیری نظارت شده تعلق دارد. الگوریتم جنگل تصادفی یک تکنیک یادگیری درختی قدرتمند در یادگیری ماشینی است. با ایجاد تعدادی درخت تصمیم در مرحله آموزش کار می‌کند. هر درخت با استفاده از یک زیرمجموعه تصادفی از مجموعه داده‌ها برای اندازه‌گیری زیرمجموعه تصادفی از ویژگی‌ها در هر بخش ساخته می‌شود.

¹ Random Forest

شاخص ریشه میانگین نرمال شده مربعات خطا (NRMSE)^۱ سطح تخمین را نشان می‌دهد. تقسیم‌بندی NRMSE توسط جمیسون و همکاران (۱۹۹۱) در جدول (۳) آورده شده است. (۴)

$$NRMSE = \frac{1}{\bar{O}} \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}}$$

جدول ۳- تقسیم‌بندی نتایج شبیه‌سازی بر اساس NRMSE

NRMSE	۰-۱۰	۱۰-۲۰	۲۰-۳۰	>۳۰
نتیجه تخمین	عالی	خوب	متوسط	ضعیف

۳. نتایج و بحث

عملکرد ذرت با استفاده از شاخص‌های خشکسالی تحت ۷ سناریو (جدول ۱) و به کارگیری روش جنگل تصادفی شبیه سازی شد (شکل ۲). ۷۰ درصد داده‌ها برای بخش واسنجی و ۳۰ درصد برای بخش صحت سنجی انتخاب شد. رابطه بین شاخص‌های خشکسالی و عملکرد ذرت با استفاده از آماره‌های آماری بررسی شد.


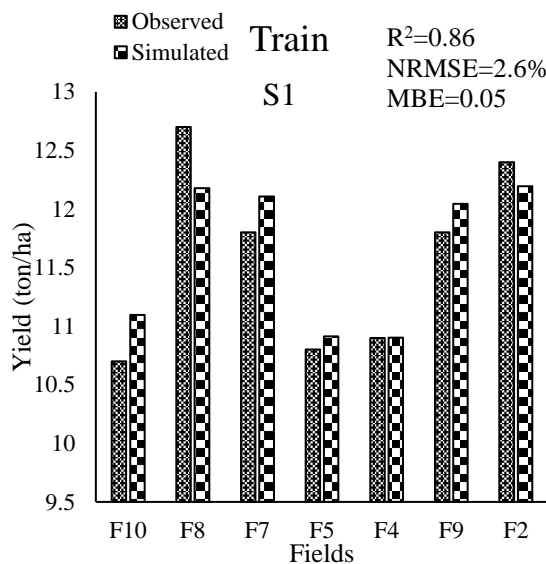
یک نزدیک تر باشد، ارتباط قوی تری میان دو متغیر وجود دارد. در صورت ضرب ضریب تبیین در عدد ۱۰۰ مقدار به دست آمده بیانگر درصد واریانس تغییرات متغیر X است که با متغیر Y توصیف می‌شود (جونور و همکاران، ۲۰۱۷). برای محاسبه ضریب تبیین از نرم‌افزار اکسل استفاده شد.

میانگین خطای اریب (MBE^۲).

$$MBE = \frac{\sum_{i=1}^n (P_i - O_i)}{n} \quad (5)$$




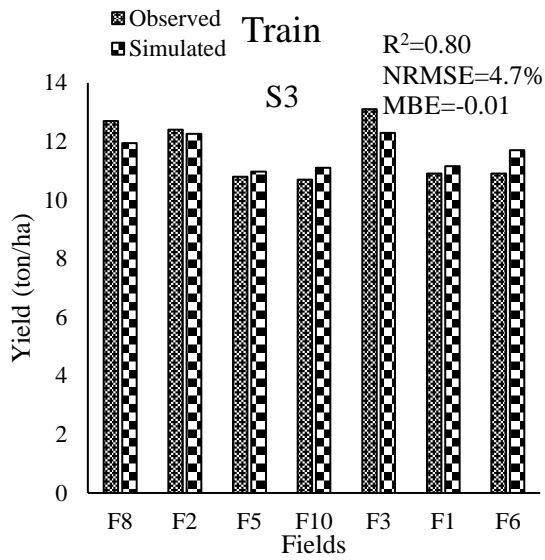
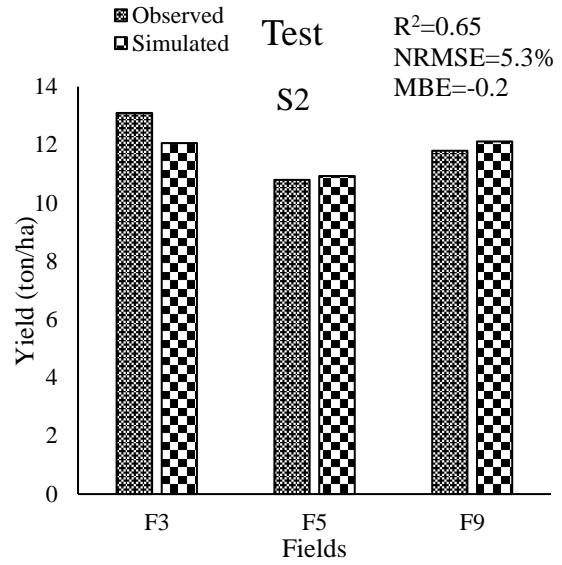

در روابط بالا P_i و O_i مقدار مشاهده‌ای و پیش‌بینی شده، \bar{O} میانگین مقادیر مشاهده‌ای و n تعداد داده‌ها یا طول سری زمانی است.



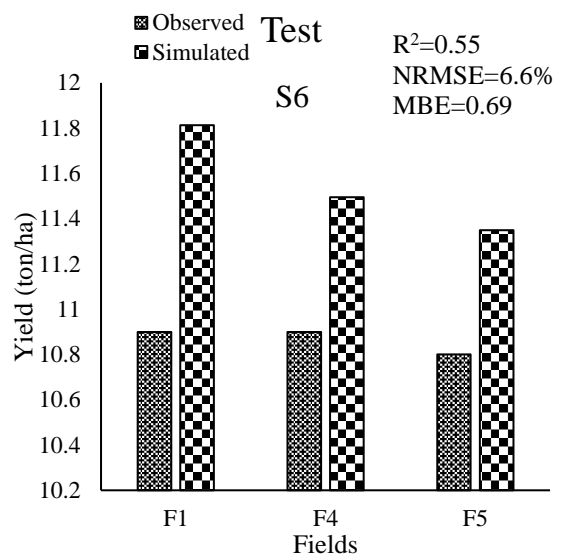



شاخص MBE بیانگر میزان اریبی روش است، در یک تخمین نسبتاً دقیق بایستی نزدیک به صفر باشد.



² Mean Bias Error

¹ Normalized Root Mean Square Error





شکل ۲- شبیه سازی و ارزیابی آماری عملکرد ذرت با استفاده از شاخص‌های خشکسالی تحت سناریوهای مختلف

۴. نتیجه گیری

نتایج نشان داد که دقت مدل جنگل تصادفی در تخمین عملکرد ذرت در منطقه مورد مطالعه در حالت *test* و *train* مناسب و قابل قبول می‌باشد. مدل جنگل تصادفی در سناریوهای یک، سه و چهار در مرحله *test* با ضریب تبیین بیش از ۰/۸ و مقدار اندک NRMSE تخمین مناسبی از عملکرد ذرت داشته است. داده‌های ماهواره‌ای و روش مورد استفاده در این مطالعه می‌تواند برای پیش بینی عملکرد سایر محصولات در مناطق مختلف استفاده شود. پیشنهاد می‌شود دقت دیگر شاخص‌های خشکسالی با استفاده از تصاویر سنتینل ۲ در منطقه مورد مطالعه ارزیابی شود.

۵. تشکر و قدردانی

نویسندگان بر خود لازم می‌دانند از پژوهشگاه فضایی ایران که در پیشبرد پژوهش حاضر صمیمانه همکاری نموده، تشکر و قدردانی نمایند.

منابع

۱. امینی، س.، علیزاده، ا.، فرید حسینی، ع.، اکبری، م. (۱۴۰۱). پیش بینی مقدار تولید محصول ذرت علوفه ای با استفاده از اطلاعات ماهواره ای. آبیاری و زهکشی ایران، دوره ۱۶، شماره ۲، صفحات ۳۸۶-۳۷۱.
۲. گنجی خرم دل، ن.، خالقی، غ. (۱۳۹۹). تخمین عملکرد و زیست توده ذرت علوفه ای در هر بازدید ماهواره ای در طی فصل رشد (مطالعه موردی: دشت فراهان). تولید و فرآوری محصولات زراعی و باغی، دوره ۱۰، شماره ۱، صفحات ۱۲۶-۱۱۳.
3. Azzari, G., Jain, M., & Lobell, D. B. (2017). Towards fine resolution global maps of crop yields: Testing multiple methods and satellites in three countries. *Remote Sensing of Environment*, 202, 129-141.
4. Cai, Y.; Guan, K.; Lobell, D.; Potgieter, A.B.; Wang, S.; Peng, J.; Xu, T.; Asseng, S.; Zhang, Y.; You, L. 2019. Integrating satellite and climate data to predict wheat yield in Australia using machine learning approaches. *Agric. For. Meteorol.* 274, 144-159.

نتایج شکل (۲) نشان می‌دهد مدل جنگل تصادفی در سناریوهای یک، سه و چهار در مرحله *test* با احتمال معنی داری به ترتیب ۹۵٪ (P-value=...) و ضریب تبیین بیش از ۰/۸ و مقدار اندک NRMSE تخمین مناسبی از عملکرد ذرت داشته است. همچنین نتایج نشان می‌دهد مدل در سناریوهای یک، دو و سه اندکی کم برآورد در مرحله *test* داشته است. در مقایسه سناریوهای ۴ تا ۷ که شاخص‌های ترکیبی استفاده شده است شاخص NDVI و MSAVI در مرحله *test* با احتمال معنی داری به ترتیب ۹۵٪ (P-value=...) و ضریب تبیین ۰/۹۶ و مقدار اندک NRMSE تخمین مناسبی از عملکرد ذرت داشته است. امینی و همکاران (۱۴۰۱) مقدار تولید محصول ذرت علوفه‌ای را با استفاده از اطلاعات ماهواره‌ای پیش بینی کردند. آنها با استفاده از مقادیر NDVI رابطه خطی با ضریب همبستگی قابل قبول ۰/۸۱ برای برآورد عملکرد تر ذرت علوفه‌ای در منطقه مورد مطالعه ارائه کردند. نتایج آنها نشان داد که با استفاده از نتایج NDVI یک تا سه هفته قبل از برداشت محصول و استفاده از رابطه بدست آمده می‌توان عملکرد ذرت علوفه‌ای را با دقت قابل قبولی پیش‌بینی کرد. گنجی خرم دل و خالقی (۱۳۹۹) به تخمین عملکرد و زیست توده ذرت علوفه ای در دشت فراهان استان مرکزی پرداختند. نتایج آنها نشان داد شاخص NDVI با ضریب همبستگی قابل قبولی ۰/۷۳ عملکرد را برآورد کرد. چن و همکاران (۲۰۲۱) با استفاده از شاخص‌های گیاهی NDVI و EVI و پارامترهای اقلیمی و تکنیک‌های یادگیری ماشین عملکرد ذرت را در چین شبیه سازی کردند. نتایج آنها نشان داد بالاترین ضریب همبستگی برای روش های جنگل تصادفی و ماشین بردار پشتیبان به ترتیب برابر ۰/۸۱ و ۰/۷۴ بود که با نتیجه پژوهش حاضر همخوانی دارد. نگی و احمد (۲۰۱۸) با استفاده از الگوریتم جنگل تصادفی و شاخص NDVI عملکرد ذرت را در آفریقای جنوبی شبیه سازی کردند. در نتایج آنها مقدار ضریب همبستگی ۰/۹ و آماره MBE=0.004 بود که با نتایج مطالعه حاضر همخوانی دارد.

- analysis based on remotely sensed variables using a Bayesian neural network approach. *Remote Sens. Environ.* 259, 112408.
17. Neupane, D., Adhikari, P., Bhattarai, D., Rana, B., Ahmed, Z., Sharma, U., & Adhikari, D. (2022). Does climate change affect the yield of the top three cereals and food security in the world?. *Earth*, 3(1), 45-71.
 18. Ranum, P., Peña-Rosas, J. P., & Garcia-Casal, M. N. (2014). Global maize production, utilization, and consumption. *Annals of New York academy of sciences*, 1312(1), 105-112.
 19. Shahhosseini, M.; Hu, G.; Huber, I.; Archontoulis, S.V. 2021. Coupling machine learning and crop modeling improves crop yield prediction in the US Corn Belt. *Sci. Rep.* 11, 1606.
 20. Sun, J.; Di, L.; Sun, Z.; Shen, Y.; Lai, Z. County-level soybean yield prediction using deep CNN-LSTM model. *Sensors* 2019, 19, 4363.
 21. Tigchelaar, M., Battisti, D. S., Naylor, R. L., & Ray, D. K. (2018). Future warming increases probability of globally synchronized maize production shocks. *Proceedings of the National Academy of Sciences*, 115(26), 6644-6649.
 22. Wang, Y.; Zhang, Z.; Feng, L.; Du, Q.; Runge, T. 2020. Combining multi-source data and machine learning approaches to predict winter wheat yield in the conterminous united states. *Remote Sens.* 12, 1232.
 23. Yuan, W.; Chen, Y.; Xia, J.; Dong, W.; Magliulo, V.; Moors, E.; Olesen, J.E.; Zhang, H. 2016. Estimating crop yield using a satellite-based light use efficiency model. *Ecol. Indic.* 60, 702-709.
 24. Erenstein, O., Jaleta, M., Sonder, K., Mottaleb, K., & Prasanna, B. M. 2022. Global maize production, consumption and trade: trends and R&D implications. *Food security*, 14(5), 1295-1319.
 25. Joinior W, Loireau M, Fargette M, Filho B, Wele A. 2017. Correlation between soil erodibility and satellite data on areas of current desertification: a case study in Senegal. *Ci Trop. Recife.* 42 (2):51-66.
 5. Chen, X., Feng, L., Yao, R., Wu, X., Sun, J., & Gong, W. 2021. Prediction of maize yield at the city level in China using multi-source data. *Remote Sensing*, 13(1), 146.
 6. Córdoba, M. A., Bruno, C. I., Costa, J. L., Peralta, N. R., & Balzarini, M. G. (2016). Protocol for multivariate homogeneous zone delineation in precision agriculture. *Biosystems engineering*, 143, 95-107.
 7. DiRienzo, C., Fackler, P. L., & Goodwin, B. K. (2000). Modeling spatial dependence and spatial heterogeneity in county yield forecasting models.
 8. Erenstein, O., Jaleta, M., Sonder, K., Mottaleb, K., & Prasanna, B. M. (2022). Global maize production, consumption and trade: trends and R&D implications. *Food security*, 14(5), 1295-1319.
 9. Feng, L.; Wang, Y.; Zhang, Z.; Du, Q. 2021. Geographically and temporally weighted neural network for winter wheat yield prediction. *Remote Sens. Environ.* 262, 112514.
 10. Fróna, D., Szenderák, J., & Harangi-Rákos, M. (2019). The challenge of feeding the world. *Sustainability*, 11(20), 5816.
 11. Grote, U., Fasse, A., Nguyen, T. T., & Erenstein, O. (2021). Food security and the dynamics of wheat and maize value chains in Africa and Asia. *Frontiers in Sustainable Food Systems*, 4, 617009.
 12. Hunt, M.L.; Blackburn, G.A.; Carrasco, L.; Redhead, J.W.; Rowland, C.S. 2019. High resolution wheat yield mapping using Sentinel-2. *Remote Sens. Environ.* 233, 111410.
 13. Idso, S.B.; Jackson, R.D.; Reginato, R.J. 1977. Remote sensing for agricultural water management and crop yield prediction. *Agric. Water Manag.*, 1, 299-310.
 14. Khaki, S.; Pham, H.; Wang, L. 2021. Simultaneous corn and soybean yield prediction from remote sensing data using deep transfer learning. *Sci. Rep.* 11, 11132.
 15. Ma, Y.; Zhang, Z.; Kang, Y.; Özdoğan, M. 2021. Corn yield prediction and uncertainty analysis based on remotely sensed variables using a Bayesian neural network approach. *Remote Sens. Environ.* 259, 112408.
 16. Ma, Y.; Zhang, Z.; Kang, Y.; Özdoğan, M. 2021. Corn yield prediction and uncertainty