

Analysis and Comparison of Energy and Yield Modeling of Local and High-Yielding Rice Cultivars Using the Multi-Gene Genetic Programming Model

S. Sharifi¹, A. Asakereh^{1*}, M. Kiani Deh Kiani¹, S. Janatrostami²

1- Department of Biosystems Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran

2- Department of Water Engineering, Faculty of Agricultural Sciences, University of Guilan, Rasht, Iran

(*- Corresponding Author Email: a.asakereh@scu.ac.ir)

<https://doi.org/10.22067/jam.2025.92838.1364>

Introduction

Global challenges threaten food security. In Iran, rice is a staple, with 770,000 ha under cultivation and an annual production of 3.75 million tonnes. The northern provinces of Guilan and Mazandaran dominate rice production, with Guilan only supplying about 50% of the nation's demand. Advanced computational techniques such as metaheuristic algorithms and artificial intelligence offer powerful tools for problem-solving and modeling inspired by the adaptability of living organisms, and are increasingly applied to support agricultural management and sustainability. However, multi-gene genetic programming (MGP) has not yet been used for rice yield modeling in Iran. This study addresses that gap by evaluating the effectiveness of MGP and exploring its potential to enhance agricultural decision-making.

Materials and Methods

This research examines the yield performance of local rice cultivars, namely Hashemi and Ali Kazemi alongside high-yielding cultivars, including Fajr and Shiroudi in Rasht County, Iran. It utilizes library documents, face-to-face interviews, and MGP analysis. Data were collected from 385 randomly selected farmers and landowners in the region, during the 2020-2024 rice production years. Inputs from the energy sector, including fuel and electricity, water pumping equipment, agricultural machinery, fertilizers, pesticides, organic materials, and the energy output of paddy production, were examined. Energy equivalents were used to convert various types of energy into a common unit. To predict the yield of the two types of paddy cultivars using MGP, the structure of MGP trees was first designed with two objectives: maintaining the model accuracy and avoiding structural complexity. Parameter setting includes population, generation and tournament sizes, gene limits, tree depth and size, and probabilities for elitism, crossover, and mutation. Additionally, various mathematical functions were utilized.

Results and Discussion

In examining total energy consumption and production in local and high-yielding cultivar farms, the results indicated a significant difference between the two varieties. In farms producing local varieties, the average energy consumption was 41,081.4 MJ, while the average energy production in these farms reached 23,771.9 MJ. In contrast, the average energy consumption in high-yielding cultivar farms was estimated at 41,118.8 MJ, whereas the average energy production in these farms was 42,220.04 MJ. The energy ratio, energy productivity, and specific energy indices for high-yielding varieties were 76.47%, 76.92%, and 77.70% higher, respectively, compared to local varieties, with the net energy gain index showing an improvement of more than 15 times. The higher energy ratio and energy productivity, along with lower specific energy and net energy gain, indicate that the high-yielding cultivar is more energy-efficient in terms of energy consumption. The MGP model converged after 100 iterations, providing the optimal solution. Changes in the best and mean fitness values indicated that as the iterations increased, the error gradually decreased and eventually stabilized, reflecting continuous improvement of the model during the training process and parameter tuning. Through cross-validation with varying training data set sizes, the findings revealed that the MGP model, when utilizing 65% of the total dataset, generated results that were remarkably similar to those achieved with 80% of the data. Hence, 65% is established as the optimal proportion for the training dataset. The coefficient of determination (R^2) for the regression line in the training data set was higher than in the test phase for both varieties. In evaluating the MGP equations to assess the accuracy of the proposed model, the tree depth was increased from 4 to 12. For the local cultivar, the

highest coefficient of determination (R^2) at a tree depth of 4 was 0.95, while for the high-yielding cultivar, it was 0.94. The simpler structure at depth 4 resulted in a simpler mathematical equation. Finally, the effects of independent variables on the dependent variable, paddy yield, were examined. It was found that organic materials, such as compost, seed, rice straw and husks, were the most significant factors influencing the estimation of paddy yield in both varieties.

Conclusion

Since modeling focuses on predicting crop yield and making data-driven scientific and practical decisions, the results of this study represent an important step toward advancing sustainable agriculture. It is recommended that farmers seek up to date insights from consultants and participate in workshops to increase their sustainable yields.

Keywords: Energy indices, Guilan, Rice, Simulation

بررسی و مقایسه انرژی و مدل سازی عملکرد شلتوک ارقام محلی و پرمحصول با مدل برنامه نویسی ژنتیک چندژنی

سینا شریفی^۱، عباس عساکره^{۱*}، مصطفی کیانی ده کیانی^۱، سمیه جنت رستمی^۲

تاریخ دریافت: ۱۴۰۴/۰۱/۱۱

تاریخ پذیرش: ۱۴۰۴/۰۲/۱۶

چکیده

برنج، به عنوان یکی از قدیمی ترین محصولات کشاورزی، نقشی اساسی در تأمین تغذیه و معیشت مردم دارد و با توجه به سطح زیرکشت، تولید و مصرف، از جایگاه مهمی برخوردار است. در این راستا، این پژوهش با استفاده از مطالعات اسنادی، مصاحبه های میدانی و تحلیل های مبتنی بر مدل برنامه نویسی ژنتیک چندژنی، به بررسی، مقایسه شاخص های انرژی و مدل سازی عملکرد ارقام محلی هاشمی و علی کاظمی و پرمحصول فجر و شیرودی پرداخته است و داده های آن از ۳۸۵ مالک و کشاورز این دو نوع رقم در شهرستان رشت جمع آوری شده است. در مقایسه با ارقام محلی، ارقام پرمحصول از نظر شاخص های نسبت انرژی، بهره وری انرژی و انرژی ویژه به ترتیب ۷۶/۴۷، ۷۶/۹۲، ۷۷/۷۰ درصد و افزوده خالص انرژی بیش از ۱۵ برابر بهبود داشت. در مدل برنامه نویسی ژنتیک چندژنی، اعتبارسنجی مقاطع نشان داد مدل با ۶۵ درصد داده ها نتایجی مشابه استفاده از ۸۰ درصد داده ها ارائه می دهد. با افزایش عمق درخت از ۴ به ۱۲، بیشترین ضریب تبیین برای عمق درخت ۴ در رقم محلی ۰/۹۵ و در رقم پرمحصول ۰/۹۴ بود. همچنین، در تحلیل حساسیت اثر نهاده های مواد آلی (کمپوست، بذر، کاه و کلش برنج) و سوخت و برق به عنوان عامل اصلی در برآورد عملکرد شلتوک در دو رقم شناسایی شدند. نهاده های مواد آلی با بهبود حاصلخیزی خاک، و سوخت و برق با تأثیرگذاری بر عملکرد ماشین های کشاورزی و کارایی عملیات زراعی، نقش کلیدی در عملکرد پایدار مزارع شلتوک دارند. یافته های این تحقیق می تواند به تولیدکنندگان کمک کند تا با مدیریت مناسب منابع مصرفی، کیفیت و کمیت محصول خود را بهبود بخشند.

واژه های کلیدی: برنج، شاخص های انرژی، شبیه سازی، گیلان

مقدمه

افزایش دمای جهانی، کمبود آب، رشد جمعیت و تغییر اقلیم باعث شده است که تأمین غذای جهان به چالشی اساسی برای ذی نفعان و ذی نقشان تبدیل شود (Tchoukouang, Onyeaka & Nkoutchou, 2024). برنج و شلتوک، در کنار گندم، از مهم ترین غلات تأمین کننده تغذیه و معیشت مردم در کشور محسوب می شوند. کشت شلتوک در ۲۱ استان کشور، با سطحی معادل ۷۷۰ هزار هکتار از اراضی زراعی، انجام می شود و سالانه بیش از ۳/۷۵ میلیون تن تولید دارد. استان های گیلان و مازندران، با سهمی معادل ۷۳ درصد از تولید و ۷۶ درصد از سطح زیرکشت، اصلی ترین مناطق تولید این

محصول به شمار می روند. در استان گیلان، ۱۴۲۵ واحد شالیکوبی با ظرفیت تبدیل سالانه ۲۰۰ تا ۴۰۰۰ تن برنج سفید فعالیت دارند. این استان حدود ۵۰ درصد از نیاز برنج کشور را تأمین کرده و بخش کشاورزی برای بیش از نیمی از ساکنان روستایی آن نقش اساسی دارد. میزان تولید برنج در گیلان ۷۲۰ هزار تن برآورد شده است. در حالی که میانگین مصرف سرانه برنج در ایران ۳۴ تا ۳۶ کیلوگرم است، این میزان در گیلان به ۵۳ کیلوگرم می رسد که بر اهمیت کشت و تولید برنج در این استان تأکید دارد (Kavoosi Kalashami, Zani poor, Yavari, & Adibi, 2017).

با پیشرفت علوم، روش های فرااکتشافی^۳ و هوش مصنوعی^۴ در حل مسائل پیچیده و مدل سازی به عنوان مجموعه ای از تکنیک های مؤثر مورد توجه قرار گرفته اند. این روش ها با شبیه سازی رفتار ارگانیسم های زنده، از جمله گیاهان، حیوانات و انسان ها، ویژگی های

۱- گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، اهواز، ایران

۲- گروه مهندسی آب، دانشکده کشاورزی، دانشگاه گیلان، رشت، ایران

(*)- نویسنده مسئول: Email: a.asakereh@scu.ac.ir

<https://doi.org/10.22067/jam.2025.92838.1364>

3- Metaheuristics

4- Artificial intelligence

انعطاف‌پذیری، تطابق‌پذیری و هوشمندی آن‌ها را در فرآیندهای محاسباتی بازآفرینی می‌کنند (Janatrostami, Kholghi, & Bozorg Haddad, 2010; Ayoubikia, Janatrostami, Ashrafzadeh, & Shafiei, 2019). در این راستا، مدل‌های شبیه‌سازی می‌توانند به محققان و تولیدکنندگان در ارزیابی راهکارهای بهینه مدیریت محصولات کشاورزی، با توجه به شرایط پیچیده اقلیمی، کمک کرده و به بهبود بهره‌وری و پایداری کشاورزی یاری رسانند (Panahi, Samadianfard, & Nazemi, 2021).

در پژوهشی از مدل شبکه عصبی مصنوعی^۱ (ANN) برای ارزیابی حداقل پارامترهای ورودی مورد نیاز جهت تعیین عملکرد ذرت و همچنین پیش‌بینی عملکرد ذرت در سطوح مختلف آب و نیتروژن استفاده کردند. آنان گزارش کردند در صورتی که حداقل سه متغیر آب، کود نیتروژن و درجه روز رشد به‌عنوان ورودی به مدل ANN معرفی شوند، می‌توان عملکرد ماده خشک ذرت را با دقت بیشتری پیش‌بینی کرد. همچنین بیان کردند مدل پیشنهادی می‌تواند به اتخاذ تصمیم‌های صحیح توسط تولیدکنندگان منجر شود (Bagheri, Gheysari, Ayoubi, & Lavaee, 2013). در مطالعه‌ای با هدف مدل‌سازی جریان انرژی برای تولید ارقام مختلف برنج در استان گلستان نتایج نشان داد که مدل ANN استفاده شده با ضریب تبیین^۲ (R^2) معادل ۰/۹۹ و ریشه میانگین مربعات خطا^۳ (RMSE) برابر با ۱/۹۳ کیلوگرم در هکتار، دقت بالایی داشته است (Taheri-Rad, Khojastehpour, Rohani, Khoramdel, & Nikkhah, 2017). در یک تحقیق مدل ترکیبی مبتنی بر شبکه عصبی مصنوعی و الگوریتم ژنتیک^۴ (GA) توانست رابطه بین ویژگی‌های ژنتیکی و عملکرد گندم در استان آذربایجان شرقی را با دقت بالا تبیین، توضیح و پوشش دهد. این مدل با ضریب تعیین ۰/۸۷ دقت بالایی در تخمین عملکرد گندم نشان داد (Barikloo, Alamdari, Moravej, & Servati, 2017). ایشان بیان کردند افزایش راندمان تولید کشاورزی مستلزم مدیریت صحیح و درک روابط میان ویژگی‌های محیطی و عملکرد محصول است. در تحقیقی مشابه، از الگوریتم‌های ژنتیک و ازدحام ذرات^۵ (PSO) برای پیش‌بینی عملکرد نیشکر در استان خوزستان استفاده شد که نتایج نشان از بهبود دقت پیش‌بینی داشته است، به‌گونه‌ای که ترکیب این الگوریتم‌ها با شبکه عصبی موجب کاهش خطا و افزایش ضریب همبستگی شده است (Hafezi, Bahrami, Sheikh Davoodi, & Alavi, 2020). در یک تحقیق با به‌کارگیری الگوریتم ژنتیک برای تنظیم فرآیندهای کشاورزی، پیش‌بینی

دقیق عملکرد محصولات با ضریب تبیین مطلوب ۹۲ درصد انجام شده است. داده‌های تحقیق ایشان شامل متغیرهای کشاورزی و اقلیمی مانند نوع محصول، فصل، سال و شرایط آب‌وهوایی ایالت‌های مختلف هند بودند (Malashin et al., 2024). در این تحقیق، پیشنهاد شده است که با یکپارچه‌سازی مدل ارائه‌شده در سامانه‌های مشاوره زراعی، کشاورزان بتوانند تصمیم‌های خود را بر پایه داده‌ها و اطلاعات دقیق بگیرند. این تصمیم‌ها می‌توانند از انتخاب زمان مناسب برای کاشت گرفته تا مدیریت بهینه منابع را در برگیرند. در نتیجه، این رویکرد نه تنها باعث افزایش بهره‌وری می‌شود، بلکه به پایداری بیشتر در بخش کشاورزی نیز کمک می‌کند. در مطالعه‌ای، طبقه‌بندی محصولات مختلف، از جمله برنج، کنف هندی، ذرت و سایر محصولات، بر اساس ویژگی‌هایی مانند سطوح نیتروژن، فسفر، پتاسیم و pH، همراه با متغیرهای آب‌وهوایی نظیر دما، رطوبت و بارندگی، مورد بررسی قرار گرفته است. این ویژگی‌ها به‌عنوان ورودی مدل پیش‌بینی بودند. مدل پیشنهادی با دقت ۹۹/۳ درصدی، نسبت به سایر روش‌های یادگیری ماشینی از خود برتری نشان داد (Mahmud et al., 2024). نوآوری تحقیق آنان در ارائه مدلی با دقت بالا برای پیش‌بینی محصولات کشاورزی بیان شده است؛ مدلی که می‌تواند با کاهش میزان خسارات وارد به محصولات و ارتقای بهره‌وری، زمینه را برای افزایش پایداری و شکوفایی بخش کشاورزی فراهم سازد. این دستاورد می‌تواند نقش مهمی در بهبود تصمیم‌گیری‌های زراعی و استفاده بهینه از منابع ایفا کند. در تحقیقی از پارامترهای ورودی نظیر ویژگی‌های خاک، آب‌وهوا و منابع آبی برای مدل‌سازی دقیق سری‌های زمانی و پیش‌بینی عملکرد محصولات گندم، نیشکر، ذرت و برنج استفاده شد. در تحقیق ایشان از روش اعتبارسنجی متقاطع پنج‌لایه‌ای^۶ در مجموعه داده‌های آموزشی به‌کارگیری شد. نتایج بیانگر آن بود که الگوریتم ژنتیک نسبت به جنگل تصادفی تقویت‌شده^۸ از کارایی و دقت بیشتری برخوردار بوده است. مدل پیشنهادی به بهبود عملکرد اقتصادی محصولات مورد بررسی کمک می‌کند و با ارائه پیش‌بینی‌های دقیق، زمینه را برای تصمیم‌گیری‌های مؤثرتر در مدیریت زراعی و تخصیص بهینه منابع فراهم می‌سازد (Guo, 2024).

رویکرد جدیدی که به‌منظور ارائه مدل در طیف وسیعی از شاخه‌های علمی کشاورزی و زیست‌شناسی مورد استفاده قرار گرفته است، برنامه‌نویسی ژنتیک چندژنی^۹ می‌باشد (Peng, Guan, Zeng, & Zhang, 2024). برنامه‌نویسی ژنتیک شاخه‌ای از الگوریتم ژنتیک است که بر توسعه خودکار برنامه‌های کامپیوتری متمرکز می‌شود. در این روش یک جمعیت اولیه از توابع مرکب که نشان‌دهنده الگوهای

1- Artificial neural network

2- Coefficient of determination

3- Root mean squared error

4- Genetic algorithm

5- Particle swarm optimization algorithm

6- Hyperparameters

7- 5-fold cross validation

8- Reinforced Random Forest Algorithm

9- Multi-gene Genetic Programming

تحقیق با هدف بررسی کارایی این روش در مدل سازی عملکرد شلتوک انجام شده و می تواند به بهبود تصمیم گیری در حوزه کشاورزی کمک کند.

مواد و روش ها

موقعیت منطقه مورد پژوهش

این پژوهش در شهرستان رشت در طول جغرافیایی $49^{\circ}59'21''$ تا $49^{\circ}56'11''$ و عرض جغرافیایی $37^{\circ}17'96''$ تا $37^{\circ}37'30''$ در بازه زمانی ۱۴۰۳-۱۳۹۸ انجام شده است. موقعیت جغرافیایی تحقیق در شکل ۱ آمده است. میانگین سالانه بارندگی در این شهرستان ۱۳۵۹ میلی متر است. میانگین دمای سالانه هوا $15/9^{\circ}$ درجه سلسیوس و میانگین سالانه رطوبت نسبی هوا در رشت $81/9$ درصد گزارش شده است. همچنین، مجموع ساعات آفتابی سالانه در این شهرستان ۱۶۲۱ ساعت می باشد.

گردآوری اطلاعات

برحسب هدف، این پژوهش از نوع کاربردی است، زیرا نتایج آن می تواند برنامه ریزان و سیاست گذاران صنعت برنج را در بهبود تصمیم گیری های کشاورزی یاری دهد و با بهره گیری از یافته های پژوهش، راهکارهای مؤثرتری برای مدیریت این صنعت ارائه کند. به طور کلی، این پژوهش از روش محاسباتی-تحلیلی استفاده می کند که بر پایه مطالعات کتابخانه ای (اسنادی)، مصاحبه های میدانی و تحلیل های مبتنی بر مدل برنامه نویسی ژنتیک انجام می پذیرد. داده ها از پرسشنامه ها، منابع اسنادی و مصاحبه های میدانی گردآوری شد. جامعه آماری این پژوهش شامل ۱۶۰ هزار کشاورز و مالک زمین بود. نمونه گیری به روش تصادفی ساده و بر اساس فرمول کوکران (Cochran, 1977) انجام شد. در نهایت، ۳۸۵ کشاورز و مالک زمین که ارقام محلی هاشمی و علی کاظمی و ارقام پرمحصول فجر و شیرودی را کشت می کردند، انتخاب شدند. این ارقام به دلیل کیفیت بالاتر، عطر مطلوب و بازارپسندی بیشتر، سهم قابل توجهی از سطح زیر کشت را به خود اختصاص داده اند.

$$n = \frac{\frac{Z^2 \times p \times q}{d^2}}{1 + \frac{1}{N} \left(\frac{Z^2 \times p \times q}{d^2} - 1 \right)} \quad (1)$$

جایی که N = جامعه آماری، $q = 0/5$ و p به ترتیب احتمال بهینه بودن و نبودن متغیرها، $Z^2 = 3/8416$ سطح اطمینان ۹۵ درصد و $d = 0/05$ حداکثر دقت نمونه گیری و n = حجم نمونه بود. جهت بررسی پایایی پرسشنامه ها از آزمون ضریب آلفای کرونباخ استفاده شد و برابر با $0/92$ به دست آمد که قابل قبول است. همچنین، شاخص CVI^2

پیش بینی هستند، به صورت تصادفی ایجاد می شوند. سپس، هر یک از افراد آن (ژن ها) با استفاده از توابع برآزش ارزیابی می شوند تا مؤثرترین نمونه ها در ماهیت پدیده شناسایی شوند. در مرحله بعد، ژن های برتر برای تکثیر، جهش، جفت گیری و تولید افراد جدید با صفات اصلاح شده (فرزندان) انتخاب می شوند. این فرآیند توسعه تکراری بر روی فرزندان اعمال شده و تا دستیابی به بهترین پاسخ ادامه می یابد.

کارایی مطلوب برنامه نویسی ژنتیک چندژنی در تحقیقات مختلف مانند پیش بینی اثرات تغییر آب و هوا بر جمعیت ماهی قزل آلا در تایوان (Tung, Lee, Yang, & Chen, 2009)، طبقه بندی پوشش های گیاهی در کشورهای امریکای جنوبی و آفریقا (Lu et al., 2022) و مدل سازی نوسانات سطح ایستابی آب های زیرزمینی در استان خوزستان (Zeinalie, Golabi, Azari, & Farzi, 2022) نشان داده شده است.

این رویکرد به تازگی در مدل سازی عملکرد محصولات کشاورزی استفاده شده است و توانسته است نتایج مطلوبی در پیش بینی متغیرها ارائه دهد. مدل سازی عملکرد محصولات دیمی در شهر تبریز با استفاده از مدل شبیه سازی برنامه نویسی ژنتیک چندژنی نتایج نشان داده است که برای محصول یونجه این روش نسبت به روش رگرسیون بردار پشتیبان^۱ (SVR) کارایی به نسبت مطلوب تری داشته است. متغیرهای دما، بارندگی، تبخیر-تعرق و شاخص های خشکسالی جزو سناریوها و ترکیب های مختلف داده ورودی بودند. همچنین بیان شده است بهره گیری از مدل های شبیه سازی، ابزاری کارآمد برای تحلیل روندهای آبی در سیستم های پیچیده کشاورزی به شمار می آید. این مدل ها می توانند پژوهشگران، نهادهای دولتی و تولیدکنندگان را در شناسایی و ارزیابی بهینه ترین شرایط مدیریتی برای محصولات کشاورزی، متناسب با وضعیت اقلیمی، یاری رسانند (Panahi et al., 2021). در پژوهشی به پیش بینی مکانی عملکرد گندم با استفاده از نقشه برداری رقومی خاک در منطقه گنوند پرداخته شد. داده های این تحقیق از مدل رقومی ارتفاع و تصاویر ماهواره ای بود. مدل برنامه نویسی ژنتیک با استفاده از مجموع داده ها ارزیابی شد و نتایج آن بیانگر میانگین ریشه مربعات خطا $525/11$ و ضریب تبیین مطلوب $0/82$ بود (Taghizadeh Merjerdi, Seyed Jalali, & Sarmadian, 2016). در جدول ۱ خلاصه تحقیقات پیرامون برنامه نویسی ژنتیک و مدل سازی عملکرد محصولات کشاورزی آورده شده است.


با بررسی پیشینه تحقیق و با توجه به این که تاکنون از برنامه نویسی ژنتیکی برای مدل سازی عملکرد شلتوک در استان گیلان استفاده نشده است، نیاز به انجام این پژوهش وجود داشت. این

برابر با ۰/۸۹ به‌دست آمد که کیفیت مناسب سؤالات از نظر ارتباط، وضوح و سادگی را تأیید می‌کند.

جدول ۱ - خلاصه تحقیقات انجام‌شده مرتبط با برنامه‌نویسی ژنتیک و مدل‌سازی عملکرد محصولات کشاورزی

Table 1– Summary of studies related to genetic programming and agricultural crop yield modeling

منبع Source	هدف Aim	منطقه Region	شاخص خطا Error indices
(Kima, Traore, Wang, & Chung, 2014)	بررسی و مدل‌سازی واکنش عملکرد برنج دیم نسبت به متغیرهای اقلیمی Rainfed rice yield response to climatic variables was studied and modeled	سه ناحیه در بورکینافاسو Three regions in Burkina Faso	coefficient of correlation = 0.88 to 0.97 root relative square error = 0.261 to 0.474 relative absolute error = 0.070 relative root mean squared error $\approx$ 2.107 to 23.638%
(Ali, Deo, Downs, & Maraseni, 2018)	پیش‌بینی و مدل‌سازی عملکرد پنبه Cotton yield was predicted and modeled	سه ناحیه در پاکستان Three regions in Pakistan	relative mean absolute error $\approx$ 1.771 to 22.652% correlation coefficient $\approx$ 0.982 root mean squared error $\approx$ 209.25 kg ha ⁻¹ mean absolute error $\approx$ 182.84 kg ha ⁻¹
(Ali & Deo, 2020)	پیش‌بینی و مدل‌سازی عملکرد گندم Wheat yield was predicted and modeled	هشت ناحیه در پاکستان Eight regions in Pakistan	root mean squared error = 80.8 kg ha ⁻¹ coefficient of correlation = 0.91
(Babae, Maroufpoor, Jalali, Zarei, & Elbeltagi, 2021)	پیش‌بینی و مدل‌سازی عملکرد شلتوک برنج Rice paddy yield was predicted and modeled	ساری در ایران Sari in Iran	



شکل ۱ - موقعیت منطقه مورد پژوهش در ایران

Fig.1. Location of the study area in Iran

به‌عبارت دیگر، میزان انرژی مصرفی از طریق ضرب مقدار نهاده‌های مصرفی و شلتوک تولیدی در ضرایب متناظر انرژی به‌دست آمد (جدول ۲). میزان مصرف انرژی در هر یک از مراحل آماده‌سازی زمین و خاک‌ورزی اولیه، عملیات خزانه‌گیری، خاک‌ورزی ثانویه و کاشت، عملیات داشت و برداشت محصول به‌صورت تفکیک‌شده محاسبه شد. در این راستا، داده‌های نیروی کار مرد و زن، ماشین‌های

نهاده‌های بخش انرژی شامل سوخت و برق، نیروی کار، ماشین‌های کشاورزی، کودها و سموم شیمیایی، مواد آلی، و ستانده بخش انرژی شلتوک مورد بررسی قرار گرفت. برای تبدیل انواع مختلف انرژی به یکدیگر از ضریب هم‌ارز انرژی^۱ استفاده شد.

1- Energy Equivalent Factor

کشاورزی کمباین، تراکتور، روتیواتور، نشاء کار، خرمن کوب و سوخت
 آن‌ها، بذر و کمپوست، آب، کودهای شیمیایی نیترات، فسفات، پتاس و
 سولفات روی، سموم شیمیایی قارچ کش، حشره کش و علف کش
 جمع‌آوری گردید.

جدول ۲- ضرایب انرژی ورودی‌ها و خروجی در تولید شلتوک

Table 2- Energy coefficients of inputs and output of the paddy production

نهاده و ستانده Input & Output	Unit	Energy-eq (Ref.)	نهاده و ستانده Input & Output	Unit	Energy-eq (Ref.)
الف) نهاده A) Input			سوخت‌ها و برق Fuels & Electricity		
ماشین‌های کشاورزی Agricultural Machinery			دیزل Diesel	MJ L ⁻¹	47.8 (6)
تراکتور Tractor	MJ h ⁻¹	10.944 (1)	بنزین Gasoline	MJ L ⁻¹	46.3 (6)
روتیواتور Rotavator	MJ h ⁻¹	10.283 (1)	برق Electricity	MJ kWh ⁻¹	12 (6)
نشاء کار Transplanter	MJ h ⁻¹	9.405 (1)	مواد آلی Organic matter		
دروگر Reaper	MJ h ⁻¹	5.518 (1)	بذر برنج Rice seed	MJ kg ⁻¹	14.70 (2)
خرمنکوب Thresher	MJ h ⁻¹	7.524 (1)	کمپوست Compost	MJ kg ⁻¹	0.3 (7)
کامباین Combine	MJ h ⁻¹	171 (1)	کاه و کلش برنج Rice straw	MJ kg ⁻¹	6.5 (3)
کودهای شیمیایی Fertilizers			سموم شیمیایی* Biocides*		
نیتروژن Nitrogen	MJ kg ⁻¹	78.7 (6)	علف کش Herbicide	MJ kg ⁻¹	120 (5)
فسفات Phosphate	MJ kg ⁻¹	17.4 (6)	آفت کش Pesticide	MJ kg ⁻¹	120 (5)
پتاس Potash	MJ kg ⁻¹	13.7 (6)	قارچ کش Fungicide	MJ kg ⁻¹	120 (5)
سولفات روی Zinc sulphate	MJ kg ⁻¹	20.9 (1)	ب) ستانده B) Output		
			شلتوک Paddy	MJ kg ⁻¹	14.70 (2)

1- Nassiri and Singh (2009), 2- Ozkan, Akcaoz, and Fert (2004), 3- Gummert *et al.* (2020), 4- Van-hung *et al.* (2019), 5- Chauhan, Mohapatra, and Pandey (2006), 6- Kitani, Jungbluth, Peart, and Ramdani (1999), 7- Taheri-Rad, Khojastehpour, Rohani, & Khoramdel (2017)

* به‌ازای هر کیلوگرم ماده موثره

* Per kilogram of active ingredient

در رابطه (۲)، ME انرژی کاربرد ماشین‌های کشاورزی (مگاژول در هکتار)، G جرم ماشین‌ها (کیلوگرم)، t مدت زمان کاربرد ماشین‌ها (ساعت در هکتار)، M_P انرژی مواد اولیه و T عمر مفید ماشین‌ها (ساعت) می‌باشد. در جدول ۳ عمر مفید ماشین‌های کشاورزی بر حسب ساعت آمده است.

انرژی مصرف‌شده توسط ماشین‌های کشاورزی یکی از فاکتور اساسی در بررسی انرژی تولید محصولات کشاورزی به‌شمار می‌رود. برای تعیین میزان انرژی به‌کاررفته در ماشین‌آلات مورد استفاده، از رابطه (۲) بهره گرفته شد.

$$ME = \frac{G \times M_P \times t}{T} \quad (2)$$

جدول ۳- عمر مفید ماشین‌های کشاورزی (ساعت)

Table 3 - lifetime of agricultural machinery (hr)

تراکتور	10000
Tractor	
روتیواتور	3000
Rotavator	
نشاءکار	3000
Transplanter	
دروگر	3000
Reaper	
خرمنکوب	3000
Thresher	
کmbاین	3000
Combine	

(Almassi, Kiani & Loveimi, 2014)

مصرفی برحسب مگاژول بر هکتار و Yield میزان تولید شلتوک بر حسب کیلوگرم بر هکتار بود.

برنامه‌نویسی ژنتیک

برنامه‌نویسی ژنتیک برای ایجاد و کشف ساختار کلی تابع مناسب به کار می‌رود، در حالی که الگوریتم ژنتیک برای بهینه‌سازی ضرایب یک تابع مشخص استفاده می‌شود. به عبارت دیگر، برنامه‌نویسی ژنتیک تعیین می‌کند که چه تابعی برای یک مسئله مناسب‌تر است، در حالی که الگوریتم ژنتیک مقدار بهینه ضرایب آن تابع را پیدا می‌کند. روش برنامه‌نویسی ژنتیک در جهت خودکاری‌سازی برنامه‌نویسی و استقراء برنامه‌ها توسعه داده شده است. در این روش اندازه کروموزوم‌ها یا پاسخ (به‌ازای مقادیر مختلف مصرف نهاده‌ها) به‌وسیله عملگرهای ژنتیک اصلاح‌شده، تغییر می‌کند. برخلاف، الگوریتم‌های ژنتیک، در این روش تفاوتی بین فضای جستجو و فضای نمایش وجود ندارد. فضای جستجو علاوه‌بر فضای مسأله، فضای نمایش را نیز در برمی‌گیرد و قادر به نمو نمایش مسأله است. در تئوری، فضای جستجوی عبارت است از فضای همه ترکیب‌های ممکن از سمبول‌های اولیه‌ای که مسأله از آن‌ها ساخته می‌شود. برنامه‌ها در قالب یک درخت ارائه شده و از تلفیق به‌عنوان عملگر اصلی در این روش استفاده می‌شود. در واقع الگوریتم‌های زیر درخت‌های مربوط به والدین را بدون این که خدش‌های در نحو برنامه ایجاد شود، با هم مبادله می‌کند. همچنین، جهش یک زیر درخت تصادفی ایجاد کرده و آن را جایگزین می‌کند. در این روش برنامه اولیه در جهت بهبود کارایی رشد می‌کند. البته رشد برنامه به گونه‌ای است که در نتیجه نهایی تغییری حاصل نشود. این روش قابل اعتماد، مطلوب و کارا در شرایط مواجه با عدم قطعیت‌های مختلف و داده‌های گسترده می‌باشد که در یک سیستم کشاورزی وجود دارد. شکل ۲ طرح‌واره مدل برنامه‌نویسی ژنتیک چندژنی را نشان می‌دهد.

همچنین برای محاسبه انرژی مصرفی پمپ تأمین آب از رابطه (۳) استفاده شد.

$$E_{wp} = \frac{\rho g H Q}{\eta_1 \times \eta_2} \times 10^{-6} \quad (3)$$

جایی که، E_{wp} برابر با انرژی مصرفی پمپ تأمین آب (برحسب مگاژول بر هکتار)، ρ برابر با چگالی آب (1000 kg m^{-3}) و g شتاب جاذبه (9.8 N kg^{-1})، H فشارکل پمپ (m)، Q ظرفیت مورد نیاز ($\text{hr}^3 \text{ m}^{-1}$)، η_1 بازده پمپ به‌صورت اعشار و معمولاً برابر 0.7 تا 0.9 در نظر گرفته می‌شود که در این تحقیق برابر با 0.8 بود و η_2 بازدهی کل تبدیل انرژی و توان به‌صورت اعشار و برای پمپ برقی 0.98 تا 0.99 در نظر می‌گیرند که در این تحقیق 0.99 بود (Janatrostami & Mahmoudpour 2020; Mirshekari, 2011).

از شاخص‌های انرژی نسبت انرژی^۱، بهره‌وری انرژی^۲، انرژی ویژه^۳ و افزوده خالص انرژی^۴ برای بررسی و مقایسه دو نوع رقم محلی و پرمحصول براساس رابطه‌های (۴) تا (۷) استفاده شد.

$$ER = \frac{\text{Output energy (MJ ha}^{-1}\text{)}}{\text{Input energy (MJ ha}^{-1}\text{)}} \quad (4)$$


$$EP = \frac{\text{Yield (kg ha}^{-1}\text{)}}{\text{Input energy (MJ ha}^{-1}\text{)}} \quad (5)$$

$$SE = \frac{\text{Input energy (MJ ha}^{-1}\text{)}}{\text{Yield (kg ha}^{-1}\text{)}} \quad (6)$$

$$NEG = \text{Output energy (MJ ha}^{-1}\text{)} - \text{Input energy (MJ ha}^{-1}\text{)} \quad (7)$$

در رابطه‌های مذکور، Output energy برابر با انرژی تولید شلتوک برحسب مگاژول بر هکتار، Input energy برابر با انرژی


- 1- Energy Ratio (ER)
- 2- Energy Productivity (EP)
- 3- Specific Energy (SE)
- 4- Net Energy Gain (NEG)



شکل ۲- فلوچارت برنامه‌نویسی ژنتیک چندژنی
Fig.2. Flowchart of multi-gene genetic programming

بیان‌کننده نمایش مدل برنامه ژنتیکی $x_2 - \tan(x_3 \times x_4)$ است.

در این مطالعه برای مدل‌سازی عملکرد شلتوک از مدل برنامه‌نویسی ژنتیک چندژنی استفاده می‌شود. به‌عنوان مثال، شکل ۳



شکل ۳- نمایش برنامه ژنتیکی $x_2 - \tan(x_3 \times x_4)$
Fig.3. Display genetic program of $x_2 - \tan(x_3 \times x_4)$

انرژی نهاده‌های مصرفی و شلتوک تولیدی می‌باشد که در محیط نرم‌افزار MatLab 2016 بررسی شد. این ورودی‌ها و نمادهای آنان عبارتند از: ماشین‌های کشاورزی (AM)، کودهای شیمیایی (Fe)، سوخت‌ها و برق (FE)، مواد آلی (OM)، سموم شیمیایی (B)، پمپ آب (WP) و شلتوک (P).

جدول ۵ تنظیمات پارامترهای مختلف در برنامه‌نویسی ژنتیک را نشان می‌دهد که برای افزایش دقت و کاهش خطا مدل از روش آزمون و خطا استفاده شد. افزایش عمق درختان باعث افزایش میزان

در شکل ۳، برگ‌های درخت، متغیرهای مستقل x_2 ، x_3 و x_4 می‌باشند که به آن‌ها ترمینال گفته می‌شود. به عبارت دیگر، این نمودار درختی شامل مجموعه‌ای از نقاط انتهایی (متغیرهای تصمیم و مقادیر ثابت) و گره‌ها (علائم ریاضی) است که بر این اساس نمودار رابطه‌ها به دست خواهد آمد. عملگرهای محاسباتی در شکل ۳ ($\times$ و $\tan$) مجموعه توابع نامیده می‌شوند. توابع و ترمینال‌ها در کنار هم مجموعه اولیه یک نمونه از مدل غیرخطی برنامه ژنتیکی را تشکیل می‌دهند (Hushyar & Ashraf Talesh, 2016). ورودی مدل، محتوای

دقت و پایین آمدن خطا می‌شود، اما بر میزان پیچیدگی مدل نهایی می‌افزاید. انتخاب عمق مناسب درخت باید دارای پیچیدگی نه چندان زیاد همراه با دقت و خطا مطلوب باشد.

جدول ۴- تنظیم پارامترها در برنامه‌نویسی ژنتیک

Table 4- Parameter setting in genetic programming

تنظیمات Settings	پارامترها Parameters
100, 400, 800, 1000	اندازه جمعیت Population size
100, 300, 500, 700	تعداد نسل Number of generations
4, 8, 10, 12	بیشینه تعداد ژن Maximum number of genes
4, 8, 10, 12	بیشینه عمق درخت Maximum tree depth
12	اندازه تورنمنت Tournament size
0.01	احتمال نخه‌گرایی Elitism probability
0.85	احتمال تقاطع Crossover probability
0.1	احتمال جهش Mutation probability
+, -, *, /, ^, sin, cos, tanh, log, sqrt	مجموعه توابع Function set

مقدار مشاهده‌شده j ، $C(j)$ مقدار محاسباتی برای این معیار در بازه زمانی $t = 5$ سال و r بیانگر میزان تابع شایستگی بود.

خطایابی و بررسی صحت نتایج مدل‌سازی

مدل‌های غیرخطی ریاضی براساس ویژگی‌های مقدار خطا توسط مدل برنامه‌نویسی ژنتیک توسعه می‌یابند. به‌منظور ارزیابی، مقایسه و پیش‌بینی پارامترهای اندازه‌گیری‌شده در مورد دقت و صحت اطلاعات در شرایط مختلف، از شاخص‌های ارزیابی مانند جذر میانگین مربعات خطا $(RMSE)$ ضریب تبیین (R^2) ، درصد میانگین مطلق خطا $(MAPE)$ و فاکتور بازده مدل (EF) استفاده خواهد شد (رابطه‌های ۹ تا ۱۲).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (A_i - P_i)^2} \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (A_i - P_i)^2}{\sum_{i=1}^n (A_i - \bar{A}_i)^2} \quad (10)$$

اندازه جمعیت و تعداد نسل به‌ترتیب تعداد برنامه‌ها در جمعیت و تعداد سطوح الگوریتم مورد استفاده قبل از توقف اجرا را تعیین می‌کنند. بیشینه تعداد ژن، تعداد ژن‌های مجاز در یک پاسخ (کوروموزوم) را نشان می‌دهد. براساس جدول ۴ و ردیف‌های ۱ تا ۴، $4 \times 4 \times 4 \times 4 = 256$ آرایش پارامتری وجود خواهد داشت. تمامی این ترکیبات (معادلات) همراه با ۲ تکرار برای هر کدام مورد آزمایش قرار خواهد گرفت. بنابراین، $256 \times 2 = 512$ اجرای منحصر به فرد انجام می‌شود. در واقع با تنظیمات پارامتری در فرآیندهای مرتبط با شبیه‌سازی روند تکامل یک ساختار جمعیتی ایجاد می‌شود و براساس قوانین انتخاب، تلفیق و جهش، جمعیت پرورش داده می‌شوند. سپس جمعیت پرورش‌یافته ارزیابی شده و در نهایت تعیین می‌شود که کدامیک از آن‌ها در جمعیت جدید ابقا شود. شرط توقف در برنامه‌نویسی ژنتیک و شبیه‌سازی روند تکامل ساختار جمعیتی بیشترین شایستگی در نظر گرفته شد. یعنی برنامه زمانی متوقف شد که بهترین مقدار شایستگی حاصل از تابع شایستگی یا برازندگی مشخص شد. تابع شایستگی در تحقیق حاضر برابر بود با افزایش یا بیشینه‌سازی مقدار مشاهده‌شده تولید برنج، که در این صورت تابع شایستگی برابر بود با رابطه (۸):

$$r(i, t) = \sum |s(i, j) - c(j)| \quad (8)$$

جایی که $S(i, j)$ مقدار حاصل از برنامه i برای معیار بیشینه‌سازی

- 1- Root Mean Square Error
- 2- Coefficient of determination
- 3- Mean Absolute Percentage Error
- 4- Efficiency Factor

مصرفی آن‌ها به ۴۱/۴۷ درصد می‌رسد. پس از مواد آلی، کود شیمیایی در ارقام محلی ۳۷/۲۱ درصد و ارقام پرمحصول به میزان ۳۸/۵۵ بوده است که سهم چشم‌گیری را از میانگین انرژی مصرفی داشته‌اند. این مقادیر نشان می‌دهد که کود شیمیایی به‌عنوان یک نهاده مهم مصرفی مورد استفاده قرار می‌گیرد. مطالعه [Gu and Yang \(2022\)](#) نیز نشان داده است که کود نیترات، به‌عنوان یکی از ارکان مدیریت مدرن کشاورزی، نقش مهمی در افزایش عملکرد محصول ایفا می‌کند و در زراعت برنج به‌عنوان راهکاری کلیدی برای تأمین نیازهای جمعیت در حال رشد محسوب می‌شود.

در ارقام محلی میانگین مصرف سموم شیمیایی برابر با ۲/۷۰ درصد مشاهده شد. این میزان در ارقام پرمحصول برابر با ۲/۵۴ درصد بود که نشان از مصرف بیشتر ۶/۲۹ درصدی در ارقام محلی نسبت به ارقام پرمحصول دارد. میانگین مصرف انرژی سوخت و برق در رقم محلی ۸/۸۱ درصد و در رقم پرمحصول ۸/۳۱ درصد بود. میانگین انرژی مصرفی ماشین‌های کشاورزی ۲/۰۷ درصد در رقم محلی و ۱/۹۱ درصد در رقم پرمحصول بوده است. نتایج حاکی از آن بود که در مزارع تحت کشت ارقام محلی، میانگین انرژی مصرفی پمپ آب در رقم محلی ۸/۶۷ درصد و در رقم پرمحصول ۷/۱۸ مترمکعب بر هکتار بوده است.

در بررسی مجموع انرژی مصرفی و انرژی حاصل از تولید شلتوک در مزارع ارقام محلی و پرمحصول، نتایج نشان‌دهنده تفاوت قابل‌توجهی بین دو نوع رقم مورد مطالعه بود. در مزارع کشت ارقام محلی، میانگین انرژی مصرفی برابر با ۴۱۰۸۱/۴ مگاژول بوده است، در حالی که میانگین انرژی حاصل از تولید شلتوک در این مزارع به ۲۳۷۷۱/۹ مگاژول می‌رسد. در مقابل، میانگین انرژی مصرفی در مزارع ارقام پرمحصول ۴۱۱۱۸/۸ مگاژول برآورد شده است، در حالی که میانگین انرژی حاصل از شلتوک تولیدی در این مزارع برابر با ۴۲۲۲۰/۰۴ مگاژول بوده است.

جدول ۵ شاخص‌های انرژی مربوط به دو نوع رقم محلی و پرمحصول را نشان می‌دهد. نوع رقم پرمحصول در همه شاخص‌های انرژی عملکرد بهتری نسبت به نوع رقم محلی داشت. شاخص نسبت انرژی در رقم پرمحصول ۷۷/۵ درصد نسبت به رقم محلی از خود بهبود نشان داد. شاخص‌های بهره‌وری انرژی و انرژی ویژه در ارقام پرمحصول نسبت ارقام محلی به‌ترتیب ۰/۰۳ به‌ازای هر مگاژول و ۱۱/۱۲ به‌ازای هر کیلوگرم بهتر بود. علاوه بر این، افزوده خالص انرژی در رقم پرمحصول نسبت به رقم محلی بیش از ۱۵ برابر بهبود نشان داد. شاخص‌های نسبت انرژی و بهره‌وری انرژی بالاتر، و انرژی ویژه و افزوده خالص انرژی کمتر در نوع رقم پرمحصول نشان می‌دهد که ارقام پرمحصول فجر و شیرودی به لحاظ مصرف انرژی بهینه است. در تحقیق مشابه نسبت انرژی، بهره‌وری انرژی، انرژی ویژه و افزوده خالص انرژی برای محصول نیشکر به‌ترتیب ۱/۵۲،

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{A_i - P_i}{A_i} \right|}{n} \quad (11)$$

$$EF = 1 - \frac{\sum_{i=1}^n (A_i - P_i)^2}{\sum_{i=1}^n (A_i - \bar{P}_i)^2} \quad (12)$$

در رابطه‌های (۹) تا (۱۲)، A_i ، P_i ، $\bar{A}_i$ و $\bar{P}_i$ به‌ترتیب مقادیر پیش‌بینی، محاسباتی، میانگین مقدار محاسباتی و میانگین مقدار پیش‌بینی (در این تحقیق مدل MGP) برای i -مزرعه می‌باشد. بهترین عملکرد مدل‌ها برای تخمین مجموعه داده‌ها، زمانی به‌دست می‌آید که معیار خطا MAPE حداقل و نزدیک به صفر و معیارهای عملکردی شامل EF و R^2 حداکثر و نزدیک به یک باشد. ایجاد حداقل اختلاف بین مقادیر محاسبه‌شده و مقادیر پیش‌بینی‌شده دقت مدل برنامه‌نویسی ژنتیک را نشان می‌دهد. به‌طور معمول در روش‌های محاسبات نرم در مرحله آموزش و آزمون به‌ترتیب از ۸۰ و ۲۰ درصد از مجموعه داده‌ها به‌صورت تصادفی استفاده می‌شود. در انتخاب تصادفی داده‌ها، احتمال بررسی نشدن برخی داده‌ها وجود دارد و ممکن است که نتایج مرحله‌های آموزش و آزمون در هر بار انتخاب مجموعه داده‌ها، متفاوت باشد. بنابراین در این مطالعه، از روش اعتبارسنجی متقاطع چندلایه‌ای^۱ استفاده شد. در این روش ابتدا مجموع داده‌ها به‌طور تصادفی مرتب شده و سپس به k (در این مطالعه ۵) زیرمجموعه دسته‌بندی شدند. یک زیرمجموعه برای آزمون و $k-1$ زیر مجموعه برای آموزش مدل استفاده شد. این رویه ۲۰ بار تکرار شد و در پایان میانگین و انحراف معیار شاخص‌های عملکردی مدل در دو مرحله محاسبه شد. از بین ۱۰۰ ($5 \times 20 = 100$) مجموعه، یک مجموعه به‌عنوان بهترین مجموعه داده تولیدشده انتخاب شد. این مجموعه داده‌ها دارای دامنه تغییرات برابر با دامنه تغییرات کل مجموعه داده‌ها بوده و نیز عملکردی قابل‌قبول در مرحله‌های آموزش و آزمون می‌باشد.


نتایج و بحث

نتایج بررسی انرژی

در مزارع مورد بررسی، ارقام محلی هاشمی و علی کاظمی و ارقام پرمحصول فجر و شیرودی (شکل ۴) سهم قابل‌توجهی از کل انرژی مصرفی نهاده‌ها را به مواد آلی، به‌عنوان منبعی غنی از ترکیبات ازت (نیترات)، فسفات و پتاس، اختصاص داده‌اند. یافته‌ها نشان می‌دهد که این سهم در میان نهاده‌های مصرفی، در مزارع تحت کشت ارقام محلی به ۴۰/۵۲ درصد رسیده و بالاترین میانگین را به خود اختصاص داده است. در مزارع کشت ارقام پرمحصول نیز مواد آلی همچنان نقش مهمی در مصرف نهاده‌ها دارند، به‌گونه‌ای که سهم انرژی

نهاده‌ها، به‌ویژه کود ازت و برق، عامل کاهش افزوده خالص انرژی بیان شد.

Haroni, Sheikhdavoodi, & (۴۸۲۲۳/۹ و ۱/۶۵، ۰/۶ Kiani Deh Kiani, 2018)؛ در پژوهش ایشان، مصرف بالای



شکل ۴- میانگین انرژی ورودی در (الف) مزارع شلتوک محلی و (ب) مزارع شلتوک پرمحصول (MJ ha^{-1})
Fig.4. Average input energy in (a) local paddy farms, and (b) high-yielding paddy farms (MJ ha^{-1})

جدول ۵- مقایسه مقدار میانگین شاخص‌های انرژی در دو رقم


Table 5- Comparison of average value of energy indices in two cultivars

شاخص‌های انرژی Energy indices	واحد Unit	محلی Local	پرمحصول High yielding
نسبت انرژی Energy ratio	-	0.578	1.026
بهره‌وری انرژی Energy productivity	kg MJ^{-1}	0.039	0.069
انرژی ویژه Specific energy	MJ kg^{-1}	25.43	14.31
افزوده خالص انرژی Net energy gain	MJ ha^{-1}	-17309.5	1101.24


مقاطع بر اساس مقادیر مختلف مجموعه آموزش (۵۰ تا ۸۰ درصد از مجموع داده‌ها) در جدول ۶ برای رقم محلی و در جدول ۷ برای رقم پرمحصول ارائه شده است. بهترین شرایط مدل زمانی حاصل می‌شود که با استفاده از داده‌های کمتر، تخمین‌های دقیق‌تری ارائه دهد و به عبارت دیگر، از تعمیم‌پذیری بالایی برخوردار باشد. بر اساس جدول ۶ و ۷ مدل برنامه‌نویسی ژنتیک با داشتن ۶۵ درصد از مجموع داده‌ها توانست نتایج تقریباً مشابه با ۸۰ درصد از مجموع داده‌ها ایجاد نماید. با کاهش اندازه مجموعه آموزش، نتایج مرحله آموزش بهبود یافت. ولی نتایج مرحله آزمون ضعیف‌تر شد، زیرا قابلیت تعمیم‌پذیری شبکه کاهش یافت. نتایج این تحقیق، در مقایسه با مطالعه مشابه با وجود استفاده از مجموعه داده‌های کوچک‌تر، عملکرد بهتری از نظر دقت و

نتایج مدل‌سازی

اجرای مدل برنامه‌نویسی ژنتیک نشان داد که پس از ۱۰۰ تکرار (نسل)، همگرایی حاصل شده و مدل به راه‌حل بهینه دست یافته است. شکل ۵ بهترین و میانگین تناسب را برحسب خطای مدل (RMSE و Log RMSE) در رقم محلی و در رقم پرمحصول نشان می‌دهد. همان‌طور که مشاهده می‌شود، با افزایش تعداد تکرارها، میزان خطا به تدریج کاهش یافته و در نهایت به مقدار ثابتی رسیده است. این کاهش تدریجی خطا نشان‌دهنده بهبود مستمر مدل در طول فرآیند آموزش و تنظیم پارامترها است. نتایج حاصل از دو مرحله آموزش و آزمایش در ارزیابی تعمیم‌پذیری مدل برنامه‌نویسی ژنتیک با استفاده از روش اعتبارسنجی



الف a



ب b

شکل ۵- مقدار خطای مدل در (الف) رقم محلی و (ب) رقم پرمحصول

Fig.5. Model error in (a) the local cultivar, and (b) the high-yielding cultivar

جدول ۶- بررسی قابلیت تعمیم‌پذیری مدل با استفاده از روش اعتبارسنجی متقاطع برای رقم محلی

Table 6- Evaluating the generalization capability of the model using the cross-validation method in the local cultivar

درصد داده‌های آموزش یافته TS (%)	مرحله آموزش Train Phase				مرحله آزمون Test Phase			
	R ² ($\bar{x} \pm sd$)	EF ($\bar{x} \pm sd$)	RMSE ($\bar{x} \pm sd$)	MAPE ($\bar{x} \pm sd$)	R ² ($\bar{x} \pm sd$)	EF ($\bar{x} \pm sd$)	RMSE ($\bar{x} \pm sd$)	MAPE ($\bar{x} \pm sd$)
80	0.88±0.1	0.90±0.4	32.31±5.3	10.02±0.6	0.91±0.0	0.92±0.0	28.1±7.8	10.55±0.8
75	0.88±0.0	0.90±0.1	32.31±5.1	10.02±0.7	0.91±0.2	0.92±0.1	28.2±7.9	10.56±0.4
70	0.89±0.1	0.90±0.2	31.98±5.2	10.02±0.2	0.91±0.1	0.92±0.2	25.0±6.0	10.51±0.2
65	0.89±0.1	0.90±0.5	31.91±6.4	10.02±0.2	0.91±0.4	0.93±0.5	22.5±5.0	10.50±0.7
60	0.89±0.1	0.90±0.1	31.92±5.2	10.03±0.3	0.89±0.5	0.91±0.2	32.0±7.3	12.55±0.8
55	0.89±0.1	0.90±0.0	31.91±5.0	10.02±0.5	0.85±0.9	0.90±0.0	35.0±7.1	13.54±0.6
50	0.89±0.1	0.90±0.1	31.91±4.4	10.02±0.2	0.86±0.4	0.90±0.1	36.0±7.0	13.51±0.9


جدول ۷- بررسی قابلیت تعمیم‌پذیری مدل با استفاده از روش اعتبارسنجی متقاطع برای ارقام پر محصول

Table 7- Evaluating the generalization capability of the model using the cross-validation method in the high-yielding cultivar

درصد داده‌های آموزش یافته	مرحله آموزش Train Phase				مرحله آزمون Test Phase			
	R ² ($\bar{x} \pm sd$)	EF ($\bar{x} \pm sd$)	RMSE ($\bar{x} \pm sd$)	MAPE ($\bar{x} \pm sd$)	R ² ($\bar{x} \pm sd$)	EF ($\bar{x} \pm sd$)	RMSE ($\bar{x} \pm sd$)	MAPE ($\bar{x} \pm sd$)
80	0.84±0.1	0.86±0.0	15.01±2.5	8.52±1.1	0.95±0.0	0.86±0.0	18.1±5.1	9.50±0.9
75	0.84±0.0	0.86±0.3	15.01±2.5	8.52±1.0	0.95±0.1	0.86±0.0	18.3±5.2	9.53±0.5
70	0.84±0.1	0.86±0.3	15.05±1.9	8.52±1.1	0.95±0.2	0.86±0.1	18.5±5.1	9.48±0.1
65	0.84±0.1	0.86±0.0	15.00±1.9	8.52±1.0	0.96±0.4	0.86±0.0	18.0±5.2	9.41±0.6
60	0.84±0.1	0.86±0.1	15.00±2.0	8.51±1.1	0.94±0.2	0.82±0.2	19.0±5.1	9.57±0.7
55	0.84±0.0	0.86±0.1	15.01±1.8	8.51±1.1	0.93±0.3	0.81±0.1	19.1±5.0	9.59±0.9
50	0.84±0.2	0.86±0.1	15.00±2.0	8.51±1.0	0.91±0.8	0.80±0.2	19.1±5.3	9.60±0.7

رگرسیون در داده‌های مرحله آموزش بالاتر از مقدار آن در مرحله آزمون می‌باشد. همچنین داده‌ای خارج از دو خط $+10\%$ و -10% مشاهده نشد. این مورد نشان می‌دهد که مجموع داده‌ها در محدوده قابل قبول قرار دارند.

به ترتیب در شکل‌های ۶ پراکندگی مقادیر عملکرد پیش‌بینی شده و محاسباتی برای رقم محلی و پرمحصول آمده است. نتایج موید آن است که توافق بین مقادیر پیش‌بینی شده و محاسباتی در مرحله آموزش از مرحله آزمون بیشتر شده است؛ زیرا ضریب تبیین خط



شکل ۶- پراکندگی مقادیر محاسباتی در برابر مقادیر پیش‌بینی شده عملکرد در (الف) رقم محلی و (ب) رقم پرمحصول
Fig.6. Cross-correlation of the observed and predicted yield values in (a) the local cultivar and (b) the high-yielding cultivar

(2016) همخوانی داشت.

برای بررسی اثرات هریک از شش متغیر مستقل ماشین‌های کشاورزی، کودهای شیمیایی، سوخت‌ها و برق، مواد آلی، سموم شیمیایی و پمپ آب بر متغیر وابسته برآورد میزان عملکرد شلتوک از روش تحلیل حساسیت استفاده شد. نتایج این روش در جدول ۹ آورده شده است. در این روش حذف هریک از این متغیرهای ورودی، اثر منفی بر کارایی پیش‌بینی مدل برنامه نویسی ژنتیک داشت. براساس نتایج جدول ۹ می‌توان گفت که متغیر مواد آلی مانند کمپوست، بذر و کاه و کلش برنج مهم‌ترین عامل موثر در برآورد عملکرد شلتوک در

معادلات برنامه‌نویسی ژنتیک به‌دست‌آمده برای پیش‌بینی عملکرد ارقام محلی و پرمحصول در جدول ۸ آورده شده است. عمق درخت معادله برنامه‌نویسی ژنتیک از ۴ به ۱۲ افزایش یافت. همان‌طور که مشاهده می‌شود، معادله به‌دست‌آمده در عمق ۱۲ در هر دو رقم با وجود دقت بالا نسبت به سایر عمق‌ها پیچیده و دارای کمترین ضریب تبیین بود. در رقم محلی بیشترین ضریب تبیین در عمق درخت ۴ به میزان 0.98 و این میزان در رقم پرمحصول 0.96 بود. ساختار ساده‌تر در عمق ۴ منجر به رابطه ریاضی ساده‌تری شد که از این نظر با نتایج تحقیق هوشیار و اشرف طالاش (Hushyar & Ashraf Talesh,)

سوخت و برق در برآورد میزان عملکرد شلتوک حائز اهمیت شد. این متغیر یکی از مهم‌ترین نهاده‌های تعیین‌کننده در برآورد عملکرد محصولات کشاورزی به‌شمار می‌رود. نتایج تحقیق مشابه نشان داد که به‌ازای مصرف یک مگاژول سوخت و برق به‌ترتیب ۱/۸۸ و ۰/۵۸ کیلوگرم عملکرد مرکبات افزایش می‌یابد (Aghkhani, Ahmadipour, Soltanali, & Rohani, 2018). متغیرهای کودها و سموم شیمیایی در اولویت بعدی قرار گرفتند و در نهایت، ماشین‌های کشاورزی و پمپ آب در رتبه‌های بعدی جای گرفتند.

هر دو رقم می‌باشد. در پژوهش شهیدی کومله و همکاران (Shahdi Kumleh, Seyedi, Haghighi Hasanalideh & Karamniya, 2021) استفاده از کودهای حیوانی عامل بسیار تأثیرگذار در افزایش عملکرد ارقام محلی و پرمحصول تلقی شده است. نتایج تحقیق صادقی (Sadeghi, 2023)، نشان داد که استفاده از کود حیوانی و کمپوست تأثیر به‌سزایی در کاهش مشکلات ناشی از مصرف بیش از حد کودهای شیمیایی دارد. این مواد با جلوگیری از آلودگی منابع تجدیدپذیر، بهبود حاصل‌خیزی خاک، افزایش دسترسی و جذب عناصر غذایی، و تولید محصولی باکیفیت و سالم از نظر ویژگی‌های ارگانیک، نقش مهمی ایفا می‌کنند. پس از متغیر مواد آلی، متغیر

جدول ۸- معادلات برنامه‌نویسی ژنتیک برای ارقام محلی و پرمحصول

Table 8- Genetic programming equations for local and high-yielding cultivar

رقم محلی Local cultivar		
عمق درخت Tree depth	معادله Equation	ضریب تبیین R ²
4	$P = \log AM + 0.66Fe \times 2.03FE \times \sin 0.28B + \sqrt{0.2WP}$	0.95
8	$P = \sin 0.01AM \times \tanh 1.69Fe \times 5.01OM + \cos 10WP + 0.93$	0.91
10	$P = \log AM \times 0.33Fe + 3.66OM \times 5.62B + 0.24WP$	0.90
12	$P = \tanh 12AM + \log 0.3Fe + 0.2FE \times \sqrt{5.3B} + \sin 0.2WP$	0.86
رقم پرمحصول High-yielding cultivar		
عمق درخت Tree depth	معادله Equation	ضریب تبیین R ²
4	$P = \sqrt{2.32AM} \times 0.52FE - \log 0.14OM \times 2.43B \times 15.59WP - 0.23$	0.94
8	$P = \log 2.55AM \times \sqrt{35.4FE} + \cos 61.5OM + 8.82B + \sin 0.47WP + 0.33$	0.90
10	$P = \sqrt{\log 0.32AM \times 1.22FE} \times 8.85OM + \sin 15.36B + \cos 3.2WP$	0.90
12	$P = 55.32AM \times 10.66Fe \times 67.22FE + \cos 20.5OM \times 0.2B$	0.89

جدول ۹- تحلیل حساسیت مدل MGP در تخمین عملکرد شلتوک

Table 9- Sensitivity analysis of the MGP model in estimating paddy yield


متغیرهای ورودی variables Input	مرحله آموزش Train Phase				مرحله آزمون Test Phase			
	RMSE		R ²		RMSE		R ²	
	پرمحصول high-yielding	محلی local	پرمحصول high-yielding	محلی Local	پرمحصول high-yielding	محلی local	پرمحصول high-yielding	محلی Local
All	15.01	14.33	0.85	0.82	18.22	13.28	0.91	0.88
All-AM	32.10	32.63	0.83	0.84	32.14	32.87	0.85	0.89
All-Fe	36.33	36.10	0.80	0.81	33.80	32.55	0.80	0.81
All-FE	37.02	36.22	0.79	0.80	36.56	32.20	0.79	0.80
All-OM	40.27	39.91	0.77	0.78	40.30	32.37	0.78	0.78
All-B	33.28	33.33	0.82	0.82	33.12	33.13	0.81	0.82
All-WP	30.99	30.63	0.88	0.86	32.90	31.22	0.89	0.90

است. بر این اساس عملکرد بیشینه، با مقدار متوسط تا بالای هر دو متغیر ورودی به‌دست آمد. در هر دو نوع رقم شلتوک، عملکرد بیشینه در سطوح بالاتری از مواد آلی مشاهده شد. در مجموع، این تحلیل

نتایج روش سطح پاسخ برای ارقام پرمحصول و محلی در شکل ۷ نشان داده شده است که به بررسی تأثیر متقابل مواد آلی و مصرف سوخت و برق بر عملکرد محصول برحسب مگاژول بر هکتار پرداخته

بیانگر آن است که برای دستیابی به بیشترین عملکرد، بهینه‌سازی

هم‌زمان مواد آلی و سوخت و برق مصرفی ضروری است.



الف

ب

شکل ۷- نمودار سطح پاسخ برای (الف) رقم پرمحصول و (ب) رقم محلی
Fig.7. Response surface methodology for (a) high-yield cultivar and (b) local cultivar

نتیجه‌گیری

با توجه به توجه جهانی به مسئله انرژی در کشاورزی و اهمیت انرژی‌محور بودن این حوزه، همراه با روند رو به رشد مکانیزاسیون و ضرورت ایجاد تعادل در مصرف نهاده‌های کشاورزی، برقراری توازن در تولید محصولات کشاورزی امری حیاتی است. از این رو، هدف از این پژوهش بررسی و مقایسه انرژی و مدل‌سازی عملکرد ارقام محلی هاشمی و علی کاظمی و پرمحصول فجر و شیرودی در شهرستان رشت بود. میانگین انرژی حاصل از تولید ارقام محلی شلتوک برابر با ۲۳۷۷۱/۹ مگاژول بود در حالی که میانگین انرژی مصرفی در این ارقام به ۴۱۰۸۱/۴ مگاژول رسید. در مقابل، میانگین انرژی مصرفی در مزارع ارقام پرمحصول ۴۱۱۱۸/۸ مگاژول بود در حالی که میانگین انرژی حاصل از شلتوک تولیدی در این مزارع برابر با ۴۲۲۲۰/۰۴ مگاژول بوده است. نسبت انرژی، بهره‌وری انرژی و انرژی ویژه در ارقام پرمحصول نسبت به ارقام محلی به ترتیب ۷۶/۴۷، ۷۶/۹۲، ۷۷/۷۰ درصد و شاخص افزوده خالص انرژی بیش از ۱۵ برابر از خود بهبود نشان دادند. مدل برنامه‌نویسی ژنتیک پس از ۱۰۰ تکرار به همگرایی رسید و راه‌حل بهینه را ارائه داد. تغییرات بهترین و میانگین تناسب نتایج حاکی از آن بود که با افزایش تکرارها، میزان خطا به تدریج کاهش یافته و در نهایت به مقدار ثابتی رسید، که بیانگر بهبود مستمر مدل در فرآیند آموزش و تنظیم پارامترها بود. با استفاده از روش اعتبارسنجی متقاطع بر اساس مقادیر مختلف مجموعه آموزش نتایج نشان داد مدل برنامه‌نویسی ژنتیک با داشتن ۶۵ درصد از مجموع داده‌ها می‌تواند نتایج تقریباً مشابه با ۸۰ درصد از مجموع داده‌ها ایجاد نماید که ۶۵ درصد از مجموعه داده‌ها به عنوان مجموعه برتر انتخاب شد. ضریب تبیین خط رگرسیونی در داده‌های مرحله آموزش بالاتر از مقدار آن در مرحله آزمون در هر دو نوع رقم مورد بررسی بود. در بررسی معادلات برنامه‌نویسی ژنتیک برای بررسی

دقت مدل پیشنهادی عمق درخت از ۴ به ۱۲ افزایش یافت. در رقم محلی بیشترین ضریب تبیین در عمق درخت ۴ به میزان ۰/۹۵ و این میزان در رقم پرمحصول ۰/۹۴ بود. ساختار ساده‌تر در عمق ۴ منجر به رابطه ریاضی ساده‌تری شد. در پایان به بررسی اثرات هریک از شش متغیر مستقل بر متغیر وابسته عملکرد شلتوک پرداخته شد که متغیر مواد آلی مانند کمپوست، بذر و کاه و کلش برنج مهم‌ترین عامل موثر در برآورد عملکرد شلتوک در هر دو رقم بیان شد. با توجه به اهمیت بالای مواد آلی مانند کمپوست، بذر و کاه و کلش برنج در برآورد عملکرد شلتوک، به کشاورزان پیشنهاد می‌شود از این منابع به صورت هدفمند و منظم در مدیریت مزرعه بهره‌گیرند. استفاده از بذرهای با کیفیت، گواهی شده و سازگار با شرایط منطقه، به‌کارگیری کمپوست و حفظ بقایای گیاهی در خاک می‌تواند به بهبود ساختار خاک، افزایش حاصلخیزی و ارتقای ظرفیت نگهداری آب منجر شود. همچنین، ترکیب مدیریت مواد آلی با کودهای شیمیایی و بهره‌گیری از دانش فنی به‌روز از طریق مشاوره با کارشناسان و شرکت در دوره‌های آموزشی، نقش مؤثری در افزایش پایداری و عملکرد محصول خواهد داشت.

سپاسگزاری

از دانشگاه شهید چمران اهواز و حمایت مالی معاونت پژوهش و فناوری دانشگاه شهید چمران اهواز به خاطر حمایت مالی در قالب پژوهانه (SCU.AA98.29747) تشکر و قدردانی می‌شود.

مشارکت نویسندگان

سینا شریفی: جمع‌آوری داده‌ها، مفهوم‌سازی، روش‌شناسی، خدمات نرم‌افزاری، پردازش داده‌ها، استخراج و تهیه متن اولیه، ویرایش متن، اعتبارسنجی و تصویرسازی نتایج

عباس عساکره: نظارت و مدیریت، مفهوم‌سازی، مشاوره فنی،
تصویرسازی نتایج، ویرایش متن
سمیه جنت رستمی: مفهوم‌سازی، مشاوره فنی، تصویرسازی
نتایج، ویرایش متن
مصطفی کیانی ده کیانی: مفهوم‌سازی، مشاوره فنی، اعتبارسنجی،

Resources

1. Aghkhani, M. H., Ahmadipour, S., Soltanali, H., & Rohani, A. (2018). Greenhouse gas emissions, energy use, and cost analysis of citrus production: A case study of Mazandaran Province. *Quarterly Journal of Energy Policy and Planning Research*, 4(3), 181-229. (in Persian with English abstract).
2. Ali, M., & Deo, R. C. (2020). Modeling wheat yield with data-intelligent algorithms: Artificial neural network versus genetic programming and minimax probability machine regression. In *Handbook of Probabilistic Models*. <https://doi.org/10.1016/B978-0-12-816514-0.00002-3>
3. Ali, M., Deo, R. C., Downs, N. J., & Maraseni, T. (2018). Cotton yield prediction with Markov Chain Monte Carlo-based simulation model integrated with genetic programming algorithm: A new hybrid copula-driven approach. *Agricultural and Forest Meteorology*, 263, 428-448. <https://doi.org/10.1016/j.agrformet.2018.09.002>
4. Almassi, M., Kiani, S., & Loveimi, N. (2014). *Principles of Agricultural Mechanization* (5th ed.). Gofteman Andisheh Moaser.
5. Ayoubikia, R., Janatrostami, S., Ashrafzadeh, A., Shafiei-Sabet, B. (2019). Optimization of regional water resources allocation in Sefidroud river basin by social equity approach. *Iran-Water Resources Research*, 14(5), 205-218. (in Persian with English abstract).
6. Babaee, M., Maroufpoor, S., Jalali, M., Zarei, M., & Elbeltagi, A. (2021). Artificial intelligence approach to estimating rice yield. *Irrigation and Drainage*, 70(4), 732-742. <https://doi.org/10.1002/ird.2566>
7. Bagheri, S. M., Gheysari, S., Ayoubi, N., & Lavaee. (2013). Silage maize yield prediction using artificial neural networks. *Journal of Plant Production Research*, 19(14), 77-96. (in Persian with English abstract).
8. Barikloo, A., Alamdari, P., Moravej, K., & Servati, M. (2017). Prediction of irrigated wheat yield by using hybrid algorithm methods of artificial neural networks and genetic algorithm. *Journal of Water and Soil*, 31(3), 715-726. (in Persian with English abstract). <https://doi.org/10.22067/jsw.v31i3.56158>
9. Chauhan, N. S., Mohapatra, P. K. J., & Pandey, K. P. (2006). Improving energy productivity in paddy production through benchmarking: An application of data envelopment analysis. *Energy Conversion and Management*, 47, 1063-1085. <https://doi.org/10.1016/j.enconman.2005.07.004>
10. Cochran, W. G. (1977). *Sampling Techniques*. New York: John Wiley and Sons Publishing.
11. Gu, J., & Yang, J. (2022). Nitrogen (N) transformation in paddy rice field: Its effect on N uptake and relation to improved N management. *Crop and Environment*, 1(1), 7-14. <https://doi.org/10.1016/j.crope.2022.03.003>
12. Gummert, M., Cabardo, C., Quilloy, R., Aung, Y. L., Thant, A. M., Kyaw, M. A., Labios, R., Htwe, N. M., & Singleton, G. R. (2020). Assessment of post-harvest losses and carbon footprint in intensive lowland rice production in Myanmar. *Scientific Reports*, 10(1), 1-13. <https://doi.org/10.1038/s41598-020-76639-5>
13. Guo, Y. (2024). Integrating genetic algorithm with ARIMA and reinforced random forest models to improve agriculture economy and yield forecasting. *Soft Computing*, 28, 1685-1706. <https://doi.org/10.1007/s00500-023-09516-8>
14. Hafezi, N., Bahrami, H., Sheikh Davoodi, M. J., & Alavi, S. E. (2020). Hybrid artificial neural network with metaheuristic algorithms for predicting sugarcane yield. *Iranian Journal of Biosystems Engineering*, 51 (3), 515-526. (in Persian with English abstract). <https://doi.org/10.22059/ijbse.2020.290905.665234>
15. Haroni, S., Sheikhdavoodi, M. J., Kiani Deh Kiani, M. (2018). Application of artificial neural networks for predicting the yield and GHG emissions of sugarcane production. *Journal of Agricultural Machinery*, 8(2), 389-401. (in Persian with English abstract). <https://doi.org/10.22067/jam.v8i2.52870>
16. Hushyar, N., & Ashraf Talesh, S. S. (2016). Optimum prediction of the T-shape mixing chamber behavior based on multi-objective genetic programming. *Modares Mechanical Engineering*, 16(12), 612-616. (in Persian with English abstract).
17. Janatrostami S, & Mahmoudpour H. (2020). Environmental assessment of groundwater pumping by using water and energy nexus. *Journal of Water and Soil Science*, 23 (4), 227-240. (in Persian with English abstract). <https://doi.org/10.47176/jwss.23.4.40841>
18. Janatrostami, S., Kholghi, M., & Bozorg Haddad, O. (2010). Management of reservoir operation system using improved harmony search algorithm. *Water and Soil Science*, 20(3), 61-71. (in Persian with English abstract).
19. Kavosi Kalashami, M., Zanipoor, M., Yavari, G., & Adibi, S. (2017). Evaluation of the effect of national plan implementation of increasing rice production on technical efficiency of paddy farms (A case study: Pirbazar region of Rasht city). *Cereal Research*, 7(2), 235-246. (in Persian with English abstract). <https://doi.org/10.22124/c.2017.2549>
20. Kima, A. S., Traore, S., Wang, Y. M., & Chung, W. G. (2014). Multi-genes programing and local scale regression

- for analyzing rice yield response to climate factors using observed and downscaled data in Sahel. *Agricultural Water Management*, 146, 149-162. <https://doi.org/10.1016/j.agwat.2014.08.007>
21. Kitani, O., Jungbluth, T., Peart, R. M., & Ramdani, A. (1999). CIGR handbook of agricultural engineering. *Energy and Biomass Engineering*, 5, 330.
 22. Lu, M., Bi, Y., Xue, B., Hu, Q., Zhang, M., Wei, Y., Yang, P., & Wu, W. (2022). Genetic programming for high level feature learning in crop classification. *Remote Sensing*, 14, 3982. <https://doi.org/10.3390/rs14163982>
 23. Mahmud, T., Datta, N., Chakma, R., Das, U. K., Aziz, M. T., Islam, M., Salimullah, A. H. M., Hossain, M. S., & Andersson, K. (2024). An approach for crop prediction in agriculture: integrating genetic algorithms and machine learning. *IEEE Access*, 12, 173583-173598. <https://doi.org/10.1109/ACCESS.2024.3478739>
 24. Malashin, I., Tynchenko, V., Gantimurov, A., Nelyub, V., Borodulin, A., & Tynchenko, Y. (2024). Predicting sustainable crop yields: Deep learning and explainable AI tools. *Sustainability*, 16, 9437. <https://doi.org/10.3390/su16219437>
 25. Mirshekari, F. (2011). Optimization of energy use efficiency (energy ratio) and revenue in smallholder agriculture of Naragh City. Faculty of Agriculture University of Tehran, Tehran.
 26. Nassiri, S. M., & Singh, S. (2009). Study on energy use efficiency for paddy crop using data envelopment analysis (DEA) technique. *Applied Energy*, 86(7), 1320-1325. <https://doi.org/10.1016/j.apenergy.2008.10.007>
 27. Ozkan, B., Akcaoz, H., & Fert, C. (2004). Energy input-output analysis in Turkish agriculture. *Renewable Energy*, 29(1), 39-51. [https://doi.org/10.1016/S0960-1481\(03\)00135-6](https://doi.org/10.1016/S0960-1481(03)00135-6)
 28. Panahi, S., Samadianfard, S., & Nazemi, A. H. (2021). Modeling the yield of rain-fed wheat, barley and alfalfa products using support vector regression and genetic programming. *Journal of Water and Soil Science*, 32(2), 97-111. (in Persian with English abstract). <https://doi.org/10.22034/ws.2021.35741.2287>
 29. Peng, X., Guan, X., Zeng, Y., & Zhang, J. (2024). Artificial intelligence-driven multi-energy optimization: promoting green transition of rural energy planning and sustainable energy economy. *Sustainability*, 16, 4111. <https://doi.org/10.3390/su16104111>
 30. Sadeghi, S. M. (2023). Investigating the effect of water stress and different levels of organic and chemical fertilizers on rice yield and its components. *Iranian Journal of Irrigation and Drainage*, 17(5), 843-855. (in Persian with English abstract).
 31. Shahdi Kumleh, A., Seyedi S. R., Haghighi Hasanalideh A. R., & Karamniya, S. (2021). Effect of source and application rate of organic fertilizers on grain yield and quality of local and improved rice (*Oryza sativa* L.) cultivars. *Iranian Journal of Crop Sciences*, 23(3), 278-289. (in Persian with English abstract).
 32. Sharifi, S., Hafezi, N., & Aghkhani, M. H. (2025). Investigation and optimization of energy consumption and yield modeling of two rice cultivars using the genetic-artificial bee colony algorithm. *Journal of Agricultural Machinery*, 15(2), 145-164. <https://doi.org/10.22067/jam.2022.77064.1108>
 33. Taghizadeh Merjerdi, R., Seyed Jalali, S. A., & Sarmadian, F. (2016). Spatial prediction of wheat crop yield using digital soil mapping in Gotvand, Khuzestan Province. *Iranian Journal of Agricultural Sciences*, 47(1), 175-184. (in Persian with English abstract). <https://doi.org/10.22059/ijswr.2016.57989>
 34. Taheri-Rad, A., Khojastehpour, M., Rohani, A., & Khoramdel, S. (2017). Assessing the energy consumption efficiency of different long grain rice varieties in Golestan province. *Cereal Research*, 7(1), 51-66. (in Persian with English abstract). <https://doi.org/10.22124/c.2017.2428>
 35. Taheri-Rad, A., Khojastehpour, M., Rohani, A., Khoramdel, S., & Nikkhah, A. (2017). Energy flow modeling and predicting the yield of Iranian paddy cultivars using artificial neural networks. *Energy*, 135, 192-198. <https://doi.org/10.1016/j.energy.2017.06.089>
 36. Tchonkouang, R. D., Onyeaka, H., & Nkoutchou, H. (2024). Assessing the vulnerability of food supply chains to climate change-induced disruptions. *Science of The Total Environment*, 920, 171047. <https://doi.org/10.1016/j.scitotenv.2024.171047>
 37. Tung, C. P., Lee, T. Y., Yang, Y. C., & Chen, Y. J. (2009). Application of genetic programming to project climate change impacts on the population of Formosan Landlocked Salmon. *Environmental Modelling & Software* 24, 1062-1072. <https://doi.org/10.1016/j.envsoft.2009.02.012>
 38. Van-Hung, N., Sander, B. O., Quilty, J., Balingbing, C., Castalone, A. G., Romasanta, R., Alberto, M. C. R., Sandro, J. M., Jamieson, C., & Gummert, M. (2019). An assessment of irrigated rice production energy efficiency and environmental footprint with in-field and off-field rice straw management practices. *Scientific Reports*, 9(1), 1-12. <https://doi.org/10.1038/s41598-019-53072-x>
 39. Zeinalie, M., Golabi, M. R., Azari, A., & Farzi, S. (2022). The study of the performance of the Modflow conceptual model and the genetic programming simulator meta model in the modeling of the hydrograph of the aquifer (Case Study: Lour-Andimeshk Plain). *Journal of Aquifer and Qanat*, 1(4), 1-15. (in Persian with English abstract). <https://doi.org/10.22077/jaaq.2018.1236.1000>