



Research Paper

Machine Learning-Based Prediction of Tragacanth Gum Viscosity using Optical Features

Abdollah Imanmehr^{*1}, Ehsan Nasrnia¹, Mohsen Heidarisoltanabadi¹, Fatemeh Salek²

¹ Agricultural Engineering Research Department, Isfahan Agricultural and Natural Resources Research and Education Center, AREEO, Isfahan, Iran.

² Department of Biosystems Engineering, Faculty of Agriculture, Isfahan University of Technology, Isfahan, Iran.

Article History

Submitted: 2025/12/27

Revised: 2026/05/09

Accepted: 2026/05/20

Published
online: 2026/06/30

Keywords:

Cross-validation,
Support Vector
Machine, Python,
Regression, Modeling,
Artificial Intelligence

*Corresponding
author email:

a.imanmehr@areeo.ac.ir

ORCID: 
0000-0002-4556-0904



Abstract

Tragacanth gum is a valuable export product, and the viscosity index of its gel is recognized as the most important quality parameter, based on which it is valued. Determining a fast, accurate, low-cost, and non-destructive method for measuring the viscosity of tragacanth gum gel is a major challenge in the export, grading, and processing industry of this product. In this study, laboratory-measured data, optical properties, and viscosity values of gels obtained from different tragacanth gum samples were used to develop machine learning models. Experiments were conducted at two levels of gum type (ribbon and flake), two levels of milling method (single-stage and two-stage), and three levels of particle size (2 mm, 0.5 mm, and 0.25 mm). The optical properties and viscosity of each sample were obtained using standard methods. Subsequently, statistical models were developed to determine the viscosity of tragacanth gum samples using their optical properties. For this purpose, machine learning algorithms, including Multiple Linear Regression (MLR), Partial Least Squares Regression (PLSR), Lasso Regression, Support Vector Regression (SVR), and LassoCV Regression, were trained in Python and then validated and evaluated. Finally, the performance of the developed models was compared. The results showed that the Lasso model, with an R^2 of 98.1%, RMSE of 134 cP, and MAE of 115.86 cP, performed best among the algorithms investigated. This high accuracy indicates a strong correlation between the optical properties and viscosity of the samples and confirms the reliability of the developed model. Therefore, using this model, the viscosity values of different tragacanth gum samples can be determined with appropriate accuracy, in the shortest possible time, at the lowest cost, and in a non-destructive manner.

How to cite this paper:

Imanmehr, A., Nasrnia, E., Heidarisoltanabadi, M. and Salek, F. (2026). Machine Learning-Based Prediction of Tragacanth Gum Viscosity using Optical Features. *Journal of Research in Mechanics of Agricultural Machinery*. 38: 119-136. <https://dx.doi.org/10.22034/jrmam.2026.14818.748> (In Persian)



Authors retain the copyright and full publishing rights. Published by [Shahrekord University](https://www.shahrekord.ac.ir). This article is an open access article licensed under the [Creative Commons Attribution 4.0 International \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/)

<https://dx.doi.org/10.22034/jrmam.2026.14818.748>

EXTENDED ABSTRACT

Introduction

Tragacanth gum is one of the most valuable natural gums, widely used for its renewability, availability, cost-effectiveness, hypoallergenicity, non-carcinogenicity, and non-toxicity. Its applications span wastewater treatment, extending the shelf-life of agricultural and food products, and various hygienic and pharmaceutical industries (Boamah et al., 2023; Anon, 2006). Statistics indicate that Iran accounts for approximately 70% of the world's tragacanth gum exports (Qomshi Bozorg et al., 2012). Generally, tragacanth gum is classified into two major types (ribbon and flake), which exhibit distinct physical and rheological properties. Key determinants of tragacanth gum quality and commercial value include aqueous solution viscosity, color indices, and microbial load (Abasi & Rahimi, 2006). A critical technological challenge in the export, grading, and processing of tragacanth gum is the development of a rapid, accurate, cost-effective, and non-destructive method for measuring the viscosity of its gels. In this study, a novel approach is proposed for estimating tragacanth gum viscosity, using the optical properties of the samples as input and machine learning algorithms for modeling. To address the problem, five regression-based modeling techniques, including multiple linear regression (MLR), partial least square regression (PLSR), support vector regression (SVR), standard Lasso regression, and cross-validated Lasso regression, were applied to predict viscosity from optical data. By comparing their performance and prediction accuracy, the best model for estimating tragacanth gum viscosity based on optical features was identified.

Material and Methods

This study employed an experimental design to evaluate the feasibility of predicting the viscosity of tragacanth gum gel using optical properties and machine learning. A total of 36 gum samples from two commercially

available grades (strip and flake) were analyzed. Optical color indices (L^* , a^* , b^*) were measured using a calibrated colorimeter (Lutron RGB-1002). Gum gels were prepared according to standard protocols, and their viscosities were measured with Brookfield DV_II viscometer. All samples were prepared under identical conditions to ensure consistency. A machine learning approach was used to develop predictive models for viscosity determination. MLR, PLSR, SVR, Lasso, and LassoCV models were developed, trained, and tested in Python. Model performance was evaluated using R^2 , RMSE, and MAE with k-fold cross-validation to minimize overfitting and ensure replicability.

Results and Discussion

- Initial Data Pattern Analysis: To examine the initial patterns and possible relationships between the input variables (optical and physical features) and the output variable (viscosity), the variations in viscosity with respect to each of the measured features were analyzed. As observed, there is a clear distinction in viscosity between the two gum types (ribbon and flake); ribbon-type samples generally exhibit higher viscosity, whereas flake-type samples tend to have lower viscosity. Among the optical features, the L^* , a^* , and b^* parameters exhibit distinct patterns of scatter with respect to viscosity.

- Evaluation of Machine Learning Models: The results of evaluating the performance of different models in predicting the viscosity of tragacanth gum showed that the Lasso regression model provided the highest accuracy compared to the other models. This model demonstrated superior predictive capability for viscosity.

-Residual Plot Analysis: Ideally, residuals should be randomly scattered around the zero axis ($y=0$), with no systematic patterns or clustering. In this dataset, due to the nature of the samples, the outputs belong to two distinct types of tragacanth gum with separate numerical ranges. One type has low viscosity

values (200 to 500 cP), while the other shows high viscosity values (2000 to 3000 cP), and there are no data points in the intermediate range.

A closer look at the Lasso residual plot shows that the residuals mostly fluctuate within a narrow range around zero and exhibit a more random pattern than those of the other models. This indicates that the Lasso model has achieved a better balance between variance and bias.

Analysis of Predicted vs. Actual Value

Plots: These plots are essential tools for assessing model fit, as the closer the points lie to the diagonal reference line ($y = x$), the higher the model accuracy and the smaller the difference between actual and predicted values. In the plots of all models, an upward trend near the reference line can be observed, indicating that all five models can predict the output values. However, differences in point density and the degree of dispersion around the reference line distinguish the accuracy and stability of each model.

The Lasso and LassoCV models exhibit the best agreement between actual and predicted values. In these two models, most points align very closely with the reference line, indicating high correlation and low prediction error.

Conclusions

This research showed that using machine learning and exploiting the optical properties of various types of tragacanth gum enables the determination of its viscosity quickly, at low cost, and with high accuracy. In this study, five linear regression models MLR, Lasso, LassoCV, and PLSR and one nonlinear regression model, SVR, were compared.

The Lasso model, due to its superior statistical indices, high consistency of points around the reference line (lower error), and minimal dispersion in the residual plots, was identified as the most stable and accurate model among all the methods examined. This confirms the Lasso model's high efficiency and reliability in predicting complex, multidimensional data. Moreover, in this model, applying the L1

penalty to the coefficients effectively eliminated one of the features, reducing dimensionality and yielding a lighter, more interpretable model. Overall, the results indicated that the Lasso model outperformed the other models in terms of statistical metrics (R^2 , RMSE, MAE), residual distribution, and prediction accuracy and speed, making it an optimal choice for non-destructive viscosity estimation. Given the practical nature of this research and its strong potential for application in the production and trade industry of tragacanth gum, it is recommended that future research develop a model capable of automatically determining viscosity values through direct image processing of tragacanth samples.

Acknowledgements

We sincerely express our gratitude to the *Isfahan Agricultural and Natural Resources Research and Education Center*. The experiments and measurements of this study were conducted in the laboratory of the Technical and Engineering Department. Without the support, cooperation, and provision of specialized equipment and facilities by this center, the accurate and reliable execution of the laboratory stages of this research would not have been possible. We hereby extend our deepest thanks and appreciation to the dedicated staff of this department for their efforts and collaboration.

Author Contributions

E. Nasrnia was responsible for writing, modeling, data processing, and result analysis, A. Imanmehr contributed to conceptualization and performing the experiments, M. Heidarisoltanabadi contributed to writing and manuscript review and F. Salek was involved in modeling and manuscript review. All authors have read and approved the final manuscript.

Data Availability Statement

The datasets generated and/or analyzed during the current study are available from the corresponding author upon reasonable request.

Ethical Considerations

This study was conducted in accordance with the ethical standards of research integrity. All experiments were performed following standard laboratory safety and ethical guidelines. The authors confirm that there was no fabrication, falsification, plagiarism, or any other form of research misconduct in the study.

Conflict of Interest

The authors declare that they have no known competing financial interests or personal relationships that could have influenced the work reported in this paper.

Funding Statement

The authors received no specific funding for this research.



پیش‌بینی گرانروی صمغ کتیرا بر پایه ویژگی‌های نوری با استفاده از یادگیری ماشین

عبداله ایمان‌مهر^{۱*}، احسان نصرنیا^۱، محسن حیدری سلطان‌آبادی^۱ و فاطمه سالک^۲

۱- بخش تحقیقات فنی و مهندسی کشاورزی، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان اصفهان، سازمان تحقیقات، آموزش و ترویج کشاورزی، اصفهان، ایران.

۲- گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه صنعتی اصفهان، اصفهان، ایران.

چکیده	تاریخچه مقاله
<p>صمغ کتیرا یکی از محصولات ارزشمند صادراتی است و گرانروی ژل آن مهم‌ترین شاخص کیفی این صمغ محسوب می‌شود. تعیین روشی سریع، دقیق، کم‌هزینه و غیرمخرب برای تعیین گرانروی ژل حاصل از صمغ کتیرا یک چالش مهم در صنعت صادرات، درجه‌بندی و فرآوری این محصول است. در این مطالعه، داده‌های اندازه‌گیری شده آزمایشگاهی، ویژگی‌های نوری و مقادیر گرانروی ژل حاصل از نمونه‌های مختلف صمغ کتیرا برای توسعه مدل‌های یادگیری ماشین استفاده شدند. آزمایش‌ها در ۲ سطح نوع کتیرا (ناری و ورقه‌ای)، ۲ سطح روش خرد کردن (یک مرحله‌ای و دو مرحله‌ای) و ۳ سطح اندازه ذرات (۲، ۵/۰ و ۲۵/۰ میلی‌متر) انجام شده و خواص نوری و گرانروی هر نمونه با استفاده از روش استاندارد به دست آمد. در ادامه، مدل‌های آماری برای تعیین گرانروی نمونه‌های صمغ کتیرا با استفاده از ویژگی‌های نوری توسعه داده شد. بدین منظور الگوریتم‌های یادگیری ماشین شامل رگرسیون خطی (MLR)، رگرسیون حداقل مربعات جزئی (PLSR)، رگرسیون Lasso، رگرسیون بردار پشتیبان (SVR) و رگرسیون LassoCV با استفاده از زبان برنامه‌نویسی پایتون آموزش یافته و سپس اعتبارسنجی و ارزیابی شدند. در پایان، عملکرد مدل‌های توسعه داده شده با یکدیگر مقایسه شد. نتایج نشان داد که مدل ایجاد شده با استفاده از الگوریتم Lasso با داشتن R^2، RMSE و MAE به ترتیب ۹۸/۱ درصد و ۱۳۴ و ۱۱۵/۸۶ سانتی‌پواز در مقایسه با سایر الگوریتم‌های بررسی شده بهترین عملکرد را دارد. این دقت بالا نشان‌دهنده همبستگی قوی بین ویژگی‌های نوری و گرانروی نمونه‌هاست و قابلیت اطمینان مدل توسعه‌یافته را تأیید می‌کند. بنابراین با استفاده از این مدل می‌توان مقادیر گرانروی نمونه‌های مختلف صمغ کتیرا را با دقت مناسب، در کم‌ترین زمان و با کم‌ترین هزینه، به صورت غیر مخرب تعیین کرد.</p>	<p>دریافت: ۱۴۰۴/۱۰/۰۶</p> <p>بازنگری: ۱۴۰۵/۰۲/۱۹</p> <p>پذیرش: ۱۴۰۵/۰۲/۳۰</p> <p>انتشار: ۱۴۰۵/۰۶/۰۹</p> <p>واژه‌های کلیدی: اعتبارسنجی متقاطع ماشین بردار پشتیبان پایتون، رگرسیون مدل‌سازی، هوش مصنوعی</p> <p>* پست الکترونیکی نویسنده مسئول: a.imanmehr@areeo.ac.ir</p> <p>ORCID:  ۰۰۰۰-۰۰۰۲-۴۵۵۶-۰۹۰۴</p> 

نحوه استناد به این مقاله:

ایمان‌مهر، ع.، نصرنیا، ا.، حیدری سلطان‌آبادی، م.، و سالک، ف. (۱۴۰۵). پیش‌بینی گرانروی صمغ کتیرا بر پایه ویژگی‌های نوری با استفاده از یادگیری ماشین. *نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی*، ۳۸: ۱۱۹-۱۳۶. شناسه دیجیتال:

<https://dx.doi.org/10.22034/jrmam.2026.14818.748>

تحقیقات متعددی با هدف بررسی کیفیت صمغ کتیرا و روش‌های بهبود آن انجام شده است. نتایج این تحقیقات نشان می‌دهد که عوامل کلیدی تعیین‌کننده کیفیت صمغ کتیرا شامل گرانروی یا گرانروی محلول آبی، شاخص‌های رنگ و بار میکروبی است (Abbasi & Rahimi, 2006). پژوهش‌گران تأثیر اندازه ذرات پودر شده صمغ کتیرا بر روی گرانروی و اثر آن بر سرعت حلالیت را بررسی کردند و نشان دادند که اندازه ذرات بر سرعت حلالیت و گرانروی تأثیر دارد. همچنین آنها مشخص نمودند که کاهش اندازه ذرات تا اندازه خاصی باعث افزایش گرانروی می‌شود و از آن به بعد می‌تواند تأثیر نامناسب بر آن داشته باشد (Zahedi & Vedadi, 1979). در تحقیقات کاربردی از صمغ کتیرا در تولید دارو نیز استفاده می‌شود. در این خصوص بالا بودن گرانروی و شفافیت رنگ از مهم‌ترین فاکتورها در انتخاب نوع کتیرا به شمار می‌روند (Tavakol & Mohammadifar, 2017).



شکل ۱- انواع مختلف صمغ کتیرا، الف) کتیرای نوع نواری (مفتولی) و ب) کتیرای نوع ورقه‌ای (خرمنی)

به طور کلی، خواص رنگی صمغ کتیرا (در پودر، محلول و فیلم) برای کاربردهای بسته‌بندی زیستی، پوشش‌های خوراکی و محصولات دارویی اهمیت بالایی دارد؛ زیرا عامل‌های رنگی مانند L^* ، a^* ، b^* ، روشنایی و تغییرات رنگ (ΔE) مستقیماً بر پذیرش حسی، شاخص‌های پایداری نوری و ارزش اقتصادی تأثیر می‌گذارند. اندازه‌گیری رنگ معمولاً با اسپکتروفتومتری انعکاسی یا دستگاه‌های رنگ‌سنج (مثلاً Data color یا Konica Minolta) و گزارش CIELab انجام می‌شود که امکان کمی‌سازی تغییرات رنگی در طول فرآوری و نگهداری را فراهم می‌کند (Petkovska et al., 2024). ارتباط بین رنگ و گرانروی در صمغ‌ها چندوجهی است: تغییرات ساختاری (مانند هیدرولیز، اکسید شدن یا شکست زنجیره‌ها) می‌تواند هم گرانروی و هم خواص نوری را تغییر دهد. برای مثال کاهش طول زنجیره یا کاهش وزن مولکولی معمولاً گرانروی را کاهش و در برخی موارد باعث تغییر رنگ (تیره‌شدن یا زردی)

جدول اختصارات

MLR	Multiple Linear Regression	رگرسیون خطی چندگانه
SVR	Support Vector Regression	رگرسیون بردار پشتیبان
PLSR	Partial Last Square Regression	رگرسیون حداقل مربعات جزئی
CV	Croos Validation	اعتبارسنجی متقابل
Sat	Saturation	درجه اشباع
RMSE	Root Mean Square Error	مجدور میانگین مربعات خطا
MAE	Mean Absolute Error	میانگین خطای مطلق

مقدمه

صمغ کتیرا (*Tragacanth gum*) یکی از صمغ‌های طبیعی ارزشمندی است که از گونه‌های گیاهی جنس گون (*Astragalus*) به‌ویژه در مناطق کوهستانی ایران، ترکیه و خاورمیانه استخراج می‌شود. این صمغ از مهم‌ترین منابع صمغ تجاری در سطح جهان به شمار می‌رود که به دلیل ویژگی‌هایی نظیر تجدیدپذیر بودن، دسترسی مناسب، مقرون به‌صرفه بودن، غیر حساسیت‌زا بودن، غیر سرطان‌زا و غیر سمی بودن، کاربردهای گسترده‌ای در صنایع مختلف پیدا کرده است. از جمله این کاربردها می‌توان به استفاده در تصفیه فاضلاب، افزایش پایداری و ماندگاری محصولات کشاورزی و غذایی و همچنین صنایع دارویی و بهداشتی اشاره کرد (Boamah et al., 2023; Anon, 2006). در حال حاضر حدود ۱۷ میلیون هکتار از زیست‌بوم‌های مرتعی ایران در منطقه مرکزی زاگرس زیر پوشش گونه‌های مختلف گون قرار دارد که حدود ۱۹ درصد از اراضی مرتعی کشور را شامل می‌شود. رویشگاه‌های گون در استان اصفهان در حدود ۵۱/۳ درصد از سطح مراتع این استان را تشکیل می‌دهد. آمارها نشان می‌دهند که حدود ۷۰ درصد تولید کتیرای جهان در ایران بوده و بنا بر گزارش‌های موجود، ایران سالیانه توان تولید ۴۰۰ تن کتیرا را دارد (Qomshi bozorg et al., 2012). صمغ کتیرا در دو شکل اصلی نواری (مفتولی) و ورقه‌ای (خرمنی) یافت می‌شود که دارای خواص فیزیکی متفاوتی هستند (شکل ۱). پودر صمغ نواری، معمولاً زرد کم‌رنگ است، در حالی که پودر نوع خرمنی به رنگ کرم تا برنزه دیده می‌شود. از نظر عملکردی، صمغ نوع ورقه‌ای دارای فعالیت سطحی بهتری نسبت به انواع نواری است. با این حال، صمغ نوع نواری گرانروی بیشتری نسبت به نوع ورقه‌ای داشته و حجم تجارت جهانی آن نیز به مراتب بیشتر است (Barak et al., 2020).

که ضریب تبیین این مدل برابر با $0.99/69$ به دست آمد (Lee *et al.*, 2026).

با این حال، تاکنون مطالعه‌ای که امکان تخمین گرانروی صمغ کتیرا را به صورت غیرمخرب و با استفاده از ویژگی‌های نوری و الگوریتم‌های یادگیری ماشین مورد بررسی قرار داده باشد، گزارش نشده است. شکاف تحقیقاتی مذکور، به‌ویژه با توجه به اهمیت صمغ کتیرا به عنوان یک محصول راهبردی صادراتی ایران، ضرورت انجام پژوهشی هدفمند در این زمینه را آشکار می‌سازد. بنابراین، هدف اصلی این تحقیق، امکان‌سنجی توسعه و ارزیابی مدل‌های یادگیری ماشین برای تخمین گرانروی ژل حاصل از صمغ کتیرا بر اساس ویژگی‌های نوری آن است.

نوآوری این پژوهش در به‌کارگیری هم‌زمان طیف وسیعی از الگوریتم‌های رگرسیونی (شامل SVR, PLSR, MLR, LassoCV و Lasso) و مقایسه عملکرد آنها به منظور دستیابی به مدلی با بالاترین دقت و قابلیت اطمینان برای کاربردهای صنعتی است. بدین منظور، با استفاده از داده‌های آزمایشگاهی شامل ویژگی‌های نوری و مقادیر گرانروی نمونه‌های مختلف کتیرا (در دو نوع نواری و ورقه‌ای، دو سطح خرد کردن و سه اندازه ذرات)، مدل‌های مذکور آموزش، اعتبارسنجی و ارزیابی شدند. در نهایت، بهترین مدل برای پیش‌بینی غیرمخرب، سریع و کم‌هزینه گرانروی صمغ کتیرا معرفی شد.

مواد و روش‌ها

این پژوهش در چند بخش انجام شد که در ادامه مراحل مختلف انجام مطالعه شرح داده خواهد شد. همچنین در شکل ۲ نمودار گردش کار مراحل انجام پژوهش نشان داده شده است.

۱-۲- آماده‌سازی نمونه‌ها

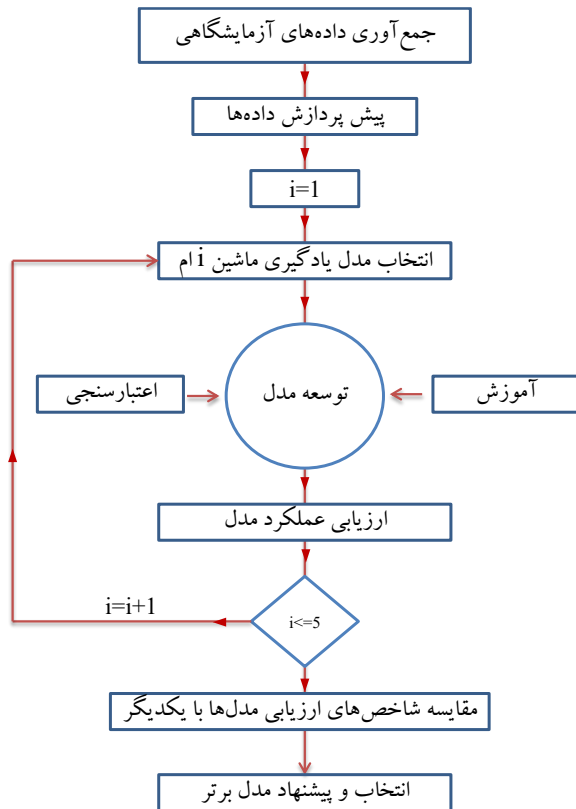
در این تحقیق ابتدا مقادیر شاخص‌های نوری و گرانروی ژل حاصل از محلول‌سازی نمونه‌های مختلف صمغ کتیرا در آزمایشگاه با استفاده از روش‌های مرجع اندازه‌گیری و ثبت شد (Imanmehr & Heidarisoltanabadi, 2024). برای انجام آزمایش‌ها، دو بسته ۵ کیلوگرمی از دو نوع کتیرا، شامل کتیراهای نواری (مفتولی) و ورقه‌ای (خرمنی) صادراتی، که از مناطق کوهستانی استان اصفهان برداشت شده بودند، تهیه و به آزمایشگاه مرکز تحقیقات کشاورزی استان اصفهان منتقل شد. هر دو نوع کتیرا با استفاده از دستگاه آسیاب (مدل SK-

می‌شود. بنابراین اندازه‌گیری هم‌زمان عامل‌های رئولوژیکی و نوری می‌تواند نشانگرهای حساسی برای پایش کیفیت، فرآوری و پایداری محصول فراهم کند. مطالعات متعددی بر همبستگی میان اندازه ذرات، تغییرات مولکولی و عامل‌های رئولوژیک/رنگی تاکید کرده‌اند (Balaghi *et al.*, 2010; Ninchan *et al.*, 2024).

Xuan و همکاران (۲۰۲۵) در مطالعه‌ای با هدف رفع محدودیت‌های روش‌های تجربی و نیمه‌تجربی در پیش‌بینی گرانروی سرباره‌های گازی‌کننده زغال‌سنگ از رویکرد یادگیری ماشین داده‌محور استفاده کردند. آن‌ها چهار مدل یادگیری ماشین شامل جنگل تصادفی (RF)، درخت تصمیم با تقویت گرادیان (GBDT)، رگرسیون بردار پشتیبان (SVR) و شبکه عصبی پس‌انتشار (BP) را توسعه دادند. ورودی‌های مدل شامل ترکیبات اصلی سرباره، نسبت Si/Al و دما بود. نتایج آن‌ها نشان داد که مدل BP بهترین عملکرد را داشت. در نهایت، نویسندگان نتیجه گرفتند که رویکرد پیشنهادی قادر به پیش‌بینی منحنی گرانروی-دما تنها بر اساس ترکیب سرباره است و ابزاری کارآمد برای پایش پایدار گازی‌سازها فراهم می‌کند (Xuan *et al.*, 2025).

مطالعات انجام شده نشان می‌دهند، استفاده از روش‌های طیف‌سنجی (مانند طیف‌سنجی مرئی/فروسرخ) و تصویربرداری ابرطیفی به‌عنوان ابزارهای غیرمخرب و سریع برای اندازه‌گیری غیرتماسی رنگ و ترکیب شیمیایی نمونه‌ها کارآمد هستند. طیف‌سنجی NIR/Vis می‌تواند اطلاعات جامعی در مورد ترکیب شیمیایی نمونه‌ها و همچنین خصوصیات فیزیکی آنها ارائه دهد. این داده‌ها با استفاده از روش‌های کمی پیشرفته مانند SVR, PLSR و شبکه‌های عصبی مصنوعی (ANN) مدل‌سازی می‌شوند تا مقادیر کمی ویژگی‌های مورد نظر تخمین زده شود. مطالعات متعددی توانایی این روش‌ها را در پیش‌بینی گرانروی محصولات متنوعی نظیر شامپو و مواد غذایی نشان داده‌اند (Haroon *et al.*, 2019; Qiu *et al.*, 2022; Zhang *et al.*, 2022; Qi *et al.*, 2024).

در پژوهشی از تصویربرداری ابرطیفی همراه با هوش مصنوعی برای شناسایی هشت هیدروکلوئید که نشان‌دهنده منشأ و ساختارهای متنوع مرتبط با کاربردهای غذایی هستند، جهت پیش‌بینی گرانروی آنها در شرایط مختلف فرآوری استفاده شد. نتایج این مطالعه حاکی از دقت بسیار بالا در پیش‌بینی گرانروی با استفاده از مدل XGBoost بود، به طوری



شکل ۲- نمودار گردش کار مراحل پژوهش برای مدل بررسی شده در این پژوهش (i : شماره مدل).

(1) به پودر تبدیل شدند. برای بررسی اثر پودرشدگی کتیرا و اندازه ذرات بر گرانروی ژل حاصل، صفحه مشبک آسیاب در سه قطر سوراخ تنظیم شد. همچنین برای بررسی اثر تغییرات دما حین خرد کردن بر گرانروی نمونه‌ها، عملیات خرد کردن به دو روش یک مرحله‌ای و دو مرحله‌ای انجام گرفت (جدول ۱).

از پودر به دست آمده تحت روش‌های مختلف خرد کردن، برای تهیه ژل کتیرا طبق روش استاندارد استفاده شد (Anonymous, 2001). آزمایش‌ها در ۳ تکرار انجام شدند و در مجموع، ۳۶ اجرای آزمایشی شامل اندازه‌گیری خواص نوری صمغ خشک شده و اندازه‌گیری گرانروی ژل کتیرا انجام شد.

جدول ۱- سطوح مختلف ویژگی‌های بررسی شده در آزمایشگاه حین آماده‌سازی نمونه‌های کتیرا

ویژگی	سطوح	شرح
نوع کتیرا	۱	نوری (مفتولی)
	۲	ورقه‌ای (خرمنی)
	۳	۲ میلی‌متر
اندازه ذرات (قطر)	۱	۰/۲۵ میلی‌متر
	۲	۰/۵ میلی‌متر
	۳	۲ میلی‌متر
روش خرد کردن	۱	یک مرحله‌ای
	۲	دو مرحله‌ای

شاخص‌های رنگ (RGB) نمونه‌های صمغ کتیرا خشک شده با استفاده از دستگاه رنگ‌سنج رقومی مدل Lutron RGB-1002 ساخت کشور تایوان (شکل ۲- الف) اندازه‌گیری شدند. سپس با استفاده از مقادیر R، G و B به دست آمده، مقادیر استاندارد L^* ، a^* و b^* نمونه‌های صمغ تعیین شدند (Imanmehr & Heidarisoltanabadi, 2024). پس از محلول‌سازی نمونه‌ها و تهیه ژل کتیرا، گرانروی ژل حاصل از هر نمونه آزمایشی با استفاده از دستگاه گرانروی سنج بروکفیلد مدل Brookfield DV-II، ساخت کشور آمریکا (شکل ۳- ب) اندازه‌گیری شد. تمامی مقادیر اندازه‌گیری شده خواص نوری و گرانروی در یک مجموعه داده ثبت و ذخیره شدند و در مراحل بعدی به عنوان ورودی مدل‌سازی یادگیری ماشین به کار گرفته شدند.



شکل ۳- دستگاه‌های آزمایشگاهی استفاده شده به منظور اندازه‌گیری: الف) خواص نوری نمونه کتیرا (Lutron RGB-1002) و ب) گرانروی نمونه ژل شده کتیرا (Brookfield DV-II) (Imanmehr & Heidarisoltanabadi, 2024).

۲-۲- توسعه مدل

این پژوهش با هدف پیش‌بینی سریع، مقرون‌به‌صرفه و غیرمخرب گرانروی ژل حاصل از صمغ کتیرا، بر روی داده‌های مربوط به ویژگی‌های نوری (L^* ، a^* ، b^* ، Hue، Sat، Lightness) نمونه‌های جامد این صمغ متمرکز شده است.

هدف، عملیات مقیاس‌بندی استاندارد داده‌ها اجرا شد. این فرآیند با استفاده از ابزار StandardScaler از کتابخانه SciKit-Learn کدنویسی و بر کل مجموعه داده‌های ورودی (ویژگی‌ها) اعمال گردید. در نتیجه، مطابق با رابطه ۱، میانگین (μ) هر ویژگی برابر صفر و انحراف معیار (σ) آن برابر ۱ تنظیم شد. این مقیاس‌بندی باعث بهبود همگرایی الگوریتم‌ها، افزایش دقت پیش‌بینی‌ها و جلوگیری از غلبه ویژگی‌هایی با مقیاس‌های متفاوت بر سایر متغیرها گردید.

$$x' = \frac{x - \mu}{\sigma} \quad (1)$$

۲-۲-۲- توسعه مدل و اعتبارسنجی آن

به منظور توسعه مدل یادگیری ماشین، داده‌های پژوهش به دو بخش داده‌های آزمون و آموزش تقسیم‌بندی شدند. بدین منظور ۸۰٪ کل داده‌ها برای آموزش مدل و ۲۰٪ باقی‌مانده برای آزمون و ارزیابی عملکرد مدل اختصاص داده شد. همچنین با توجه به محدودیت تعداد داده‌های موجود در این پژوهش و به منظور کاهش خطای تعمیم، از روش اعتبارسنجی متقاطع استفاده گردید. برای مدل‌سازی، الگوریتم‌های مختلف یادگیری ماشین با تمرکز بر رگرسیون مورد بررسی قرار گرفتند:

۱- رگرسیون حداقل مربعات جزئی (PLSR): این مدل به دلیل توانایی بالا در مدیریت داده‌های با هم‌خطی شدید و نیز در شرایطی که تعداد متغیرهای ورودی زیاد و تعداد نمونه‌ها کم است، انتخاب شد. در PLSR، متغیرهای ورودی به مجموعه‌ای از مؤلفه‌های نهفته تبدیل می‌شوند که ضمن کاهش بُعد داده‌ها، بیش‌ترین همبستگی را با متغیر خروجی (در این مطالعه، گرانروی ژل حاصل از صمغ کتیرا) حفظ می‌کنند. این ویژگی مدل PLSR را قادر می‌سازد تا الگوی پنهان بین ویژگی‌های نوری و خواص رئولوژیکی صمغ کتیرا را آشکار کرده و امکان پیش‌بینی گرانروی را با دقت مناسب فراهم آورد.

۲- مدل رگرسیون خطی چندگانه (Multiple Linear Regression - MLR): این مدل پایه‌ای برای تحلیل ارتباط خطی میان ویژگی‌های نوری و گرانروی است و فرض می‌کند که رابطه میان متغیرهای ورودی و خروجی کاملاً خطی است.

۳- رگرسیون بردار پشتیبان (SVR): یک مدل غیرخطی قدرتمند است که با استفاده از توابع هسته‌ای (Kernel Functions) مانند RBF، قادر است روابط پیچیده میان ویژگی‌ها و خروجی را به طور موثر مدل‌سازی کند. این

بدین منظور، از الگوریتم‌های مختلف رگرسیون خطی و غیرخطی در حوزه یادگیری ماشین برای مدل‌سازی و تحلیل داده‌ها بهره گرفته شد. این رویکرد امکان بررسی دقیق و مدل‌سازی روابط میان متغیرهای ورودی (ویژگی‌های نوری نمونه‌های صمغ کتیرا) و متغیر خروجی یا هدف (گرانروی ژل تولید شده پس از محلول‌سازی صمغ) را فراهم می‌آورد.

از طرفی مطالعات کاربردی تاکید دارند که عواملی چون انتخاب ویژگی‌ها، پیش‌پردازش داده‌ها، کاهش بُعد، تنظیم ابرپارامترها برای مدل‌های مختلف مبتنی بر یادگیری ماشین و استفاده از اعتبارسنجی متقابل نقش تعیین‌کننده‌ای در دقت نهایی مدل ایفا می‌کنند. (Chew et al., 2024; Malashin et al., 2025). لذا در این مطالعه فرایند پژوهش در چند مرحله اصلی انجام شد که عبارتند از: الف) پیش‌پردازش داده‌ها برای حذف نویز و آماده‌سازی داده‌های خام، ب) تفکیک مجموعه داده‌ها به بخش‌های آموزشی و آزمون به منظور ارزیابی عملکرد مدل، پ) آموزش الگوریتم‌های منتخب با استفاده از داده‌های آموزشی، ت) اعتبارسنجی مدل‌ها برای جلوگیری از بیش‌برازش، و ث) ارزیابی و مقایسه نهایی عملکرد مدل‌های توسعه یافته بر اساس شاخص‌های آماری استاندارد.

تمامی مراحل توسعه و پیاده‌سازی مدل‌ها در محیط کدنویسی Jupyter و با استفاده از زبان کدنویسی پایتون انجام شد. این محیط به دلیل انعطاف‌پذیری بالا، امکان مصورسازی نتایج و ادغام کد، متن و نمودارها، بستر مناسبی برای تحلیل داده‌ها و ارزیابی عملکرد الگوریتم‌های یادگیری ماشین فراهم آورد. از این‌رو در نظر است با استفاده از این رویکرد، علاوه بر کاهش هزینه‌ها و زمان آزمایش‌های عملی، یک راهکار کارآمد برای ارزیابی سریع کیفیت و رفتار رئولوژیکی ژل‌های حاصل از صمغ کتیرا ارائه شود. در ادامه هر یک از مراحل توسعه مدل به ترتیب شرح داده می‌شود.

۱-۲-۲- پیش‌پردازش و آماده‌سازی داده‌ها

در این مرحله مجموعه داده‌ها از ابعاد مختلف مورد تحلیل قرار گرفتند. این تحلیل‌ها شامل بررسی فراسنجه‌های آماری (مانند میانگین، واریانس، انحراف معیار) و نیز الگوهای توزیع و پراکندگی داده‌ها بود.

همچنین به منظور افزایش دقت مدل و به حداقل رساندن تاثیرات نامطلوب احتمالی، شناسایی و بررسی مقادیر پرت با دقت انجام شد. برای دستیابی به عملکرد بهتر مدل‌ها و اطمینان از مقایسه منصفانه‌ی اثر ویژگی‌های ورودی بر متغیر

به منظور اطمینان از تعمیم‌پذیری مدل‌ها و جلوگیری از بیش‌برازش، نتایج به دست آمده مورد بررسی قرار گرفتند. برای اینکار از مقایسه شاخص‌های آماری به دست آمده در بخش اعتبارسنجی (با استفاده از داده‌های آموزش) و مقادیر متناظر به دست آمده در ارزیابی نهایی مدل (با استفاده از داده‌های آزمون) و تحلیل نمودارهای باقیمانده، نمودارهای پیش‌بینی/واقعی و منحنی آموزش استفاده شد. علاوه بر این، برای کسب اطمینان از یادگیری موفق مدل توسعه داده شده، برخی داده‌های آزمون و آموزش به صورت تصادفی انتخاب و مورد بررسی دقیق قرار گرفتند.

$$R^2 = \frac{\sum_{i=1}^n (y_i - \bar{y}_i)^2}{\sum_{i=1}^n (y' - \bar{y}_i)^2} \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_i (y' - y_i)^2} \quad (3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y' - y_i| \quad (4)$$

نتایج و بحث

۱-۳- تحلیل الگوهای اولیه داده‌ها

به منظور بررسی الگوهای اولیه و روابط احتمالی بین متغیرهای ورودی (ویژگی‌های نوری و فیزیکی) و متغیر خروجی (گرانروی)، تغییرات گرانروی نسبت به هر یک از ویژگی‌های اندازه‌گیری شده مورد بررسی قرار گرفت.

شکل ۴، نمودارهای پراکندگی تغییرات گرانروی نسبت به ویژگی‌های فیزیکی (اندازه ذرات خردشده) و نوری صمغ کتیرا را نشان می‌دهند. در نمودارهای مرتب با نوع، روش خرد کردن و اندازه ذرات، کدهای متناظر با سطوح مختلف هر ویژگی در جدول ۱ آورده شده است. همان‌طور که مشاهده می‌شود، مقادیر گرانروی دو نوع صمغ کتیرا (نوری و خرمی) تفاوت آشکاری با یکدیگر دارند؛ به‌طوری‌که نمونه‌های نوری معمولاً دارای گرانروی بالاتر و نمونه‌های خرمی دارای گرانروی پایین‌تر هستند.

در میان ویژگی‌های نوری، عامل‌های L^* ، a^* و b^* الگوهای پراکندگی مشخصی با گرانروی نشان می‌دهند. این الگوها بیان‌گر حساسیت رنگ و روشنایی صمغ نسبت به تغییرات ساختاری درون آن است. هم‌چنین شاخص‌های مشتق‌شده مانند Hue، Sat و Lightness نیز رفتارهای غیرخطی با گرانروی دارند. این رفتار غیرخطی می‌تواند ناشی از تفاوت در میزان ناخالصی یا ساختار فیزیکی مختلف نمونه‌ها باشد. این

الگوریتم به‌ویژه برای داده‌های با ابعاد کم و روابط غیرخطی کارآمد است.

۴- رگرسیون Lasso: این مدل یک روش رگرسیون خطی منظم‌سازی شده است که با افزودن قابلیت جریمه کردن بر پایه مجموع قدر مطلق ضرایب (L_1 -norm) به تابع هزینه، سعی می‌کند مدل‌هایی با ضرایب کوچک‌تر و تعداد ویژگی‌های کم‌تر بسازد. ویژگی متمایز Lasso این است که برخی از ضرایب را دقیقاً به صفر می‌رساند و در نتیجه به عنوان یک روش انتخاب ویژگی نیز بسیار موثر عمل می‌کند.

۵- رگرسیون Lasso با اعتبارسنجی متقاطع (LassoCV): این روش، نسخه‌ای بهینه شده از Lasso است که برای انتخاب ویژگی و جلوگیری از بیش‌برازش به کار می‌رود. LassoCV به‌طور خودکار مقدار بهینه عامل تنظیمی (α) را با استفاده از اعتبارسنجی متقاطع انتخاب می‌کند. در این رویکرد، مدل برای مقادیر مختلف α آموزش داده می‌شود و بهترین مقدار α که تعادل مناسبی بین سادگی مدل و دقت پیش‌بینی ایجاد می‌کند، انتخاب می‌شود. استفاده از LassoCV فرآیند انتخاب ویژگی را داده‌محور کرده و به مدلی ساده‌تر و قابل تفسیرتر منجر می‌شود. تنظیمات اختصاصی مدل‌های توسعه داده شده در جدول ۲ نشان داده شده است.

جدول ۲- تنظیمات مدل‌های یادگیری ماشین بررسی شده

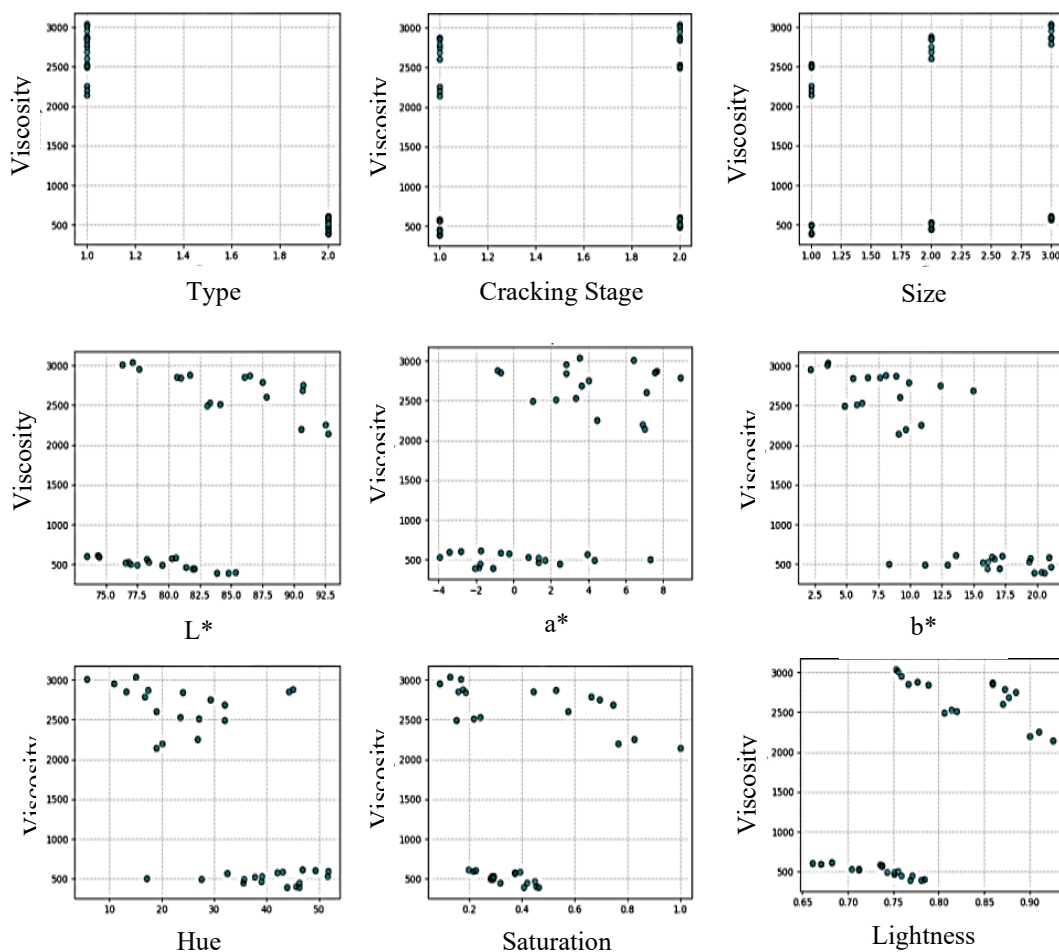
تنظیمات مدل	مدل
n-component= 5	PLSR
C= 300, ϵ = 0.5	SVR
α = 1	Lasso
α = 9.9	LassoCV

۲-۲-۳- آزمون مدل‌های توسعه یافته

برای ارزیابی و مقایسه عملکرد نهایی مدل‌ها، ابتدا هر مدل با استفاده از داده‌های آموزش برازش و اعتبارسنجی شد. سپس با استفاده از مدل نهایی برازش شده، مقادیر گرانروی نمونه‌های موجود در داده‌های آزمون، پیش‌بینی و ثبت شد. در نهایت، مقادیر پیش‌بینی شده برای داده‌های آزمون با مقادیر واقعی آن‌ها مقایسه شدند تا شاخص‌های آماری لازم جهت ارزیابی نهایی مدل به دست آیند. برای مقایسه عملکرد نهایی هر مدل از شاخص‌های آماری ضریب تبیین (R^2)، مجذور میانگین مربعات خطا (RMSE) و میانگین قدر مطلق خطا (MAE) مطابق با روابط ۲ تا ۴ استفاده شد.

در پژوهش انجام شده اثرات عوامل مختلف شامل نوع کتیرا، روش خرد کردن و اندازه ذرات بر مقدار گرانروی و خصوصیات رنگ نمونه‌های کتیرا بررسی شد. نتایج به دست آمده نشان دادند که اثرات هر سه عامل نوع کتیرا، روش خرد کردن و اندازه ذرات بر مقادیر گرانروی ژل کتیرا و خصوصیت‌های رنگ در سطح احتمال ۱٪ معنی‌دار است (Imanmehr & Heidarisoltanabadi, 2024).

نتایج نشان می‌دهد که ویژگی‌های نوری می‌توانند به‌طور بالقوه به‌عنوان شاخص‌های مؤثر در پیش‌بینی گرانروی صمغ کتیرا مورد استفاده قرار گیرند. این یافته‌های اولیه هم‌چنین بیان‌گر آن است که مدل‌های یادگیری ماشین قادر خواهند بود با ترکیب هم‌زمان این ویژگی‌ها، روابط غیرخطی پیچیده موجود در پیش‌بینی گرانروی را به‌طور مؤثرتری شناسایی و مدل‌سازی کنند.



شکل ۴- نمودارهای پراکنندگی مقادیر اندازه‌گیری شده گرانروی صمغ کتیرا نسبت به ویژگی‌های مختلف مورد مطالعه

همبستگی (از نوع معکوس) و با روش خرد کردن، اندازه ذرات و Sat کم‌ترین همبستگی را دارد. هم‌چنین بررسی همبستگی بین ویژگی‌های مختلف نشان داد که ارتباط قوی و زیادی به ترتیب بین نوع کتیرا با b^* ، L^* با Sat، L^* با Lightness و b^* با Hue است. بیش‌ترین همبستگی داخلی بین مقادیر L^* و Lightness مشاهده شد ($r = 0.95$).

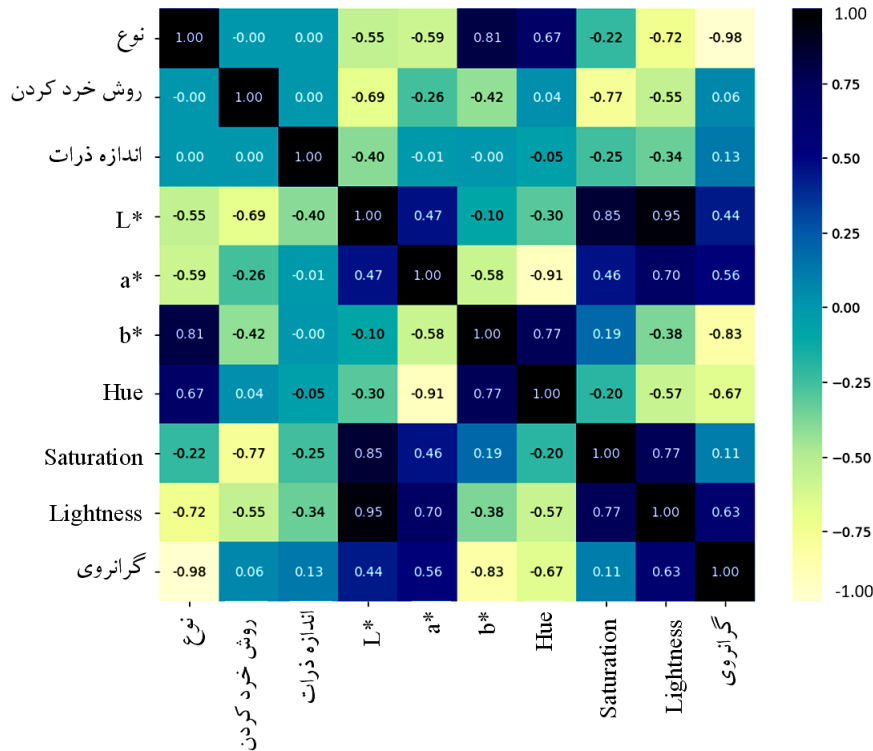
۲-۳- پیش‌پردازش داده‌ها و تحلیل همبستگی متغیرها
قبل از توسعه‌ی مدل‌های مختلف، پیش‌پردازش داده‌ها انجام شد. داده‌ها از نظر مقادیر پرت و از دست رفته بررسی شدند که بررسی‌ها نشان داد هیچ داده پرت یا از دست رفته مؤثری وجود نداشت.

همان‌طور که در شکل ۵ مشخص است، نقشه حرارتی همبستگی بین ویژگی‌ها نشان داد که مقدار گرانروی به‌عنوان متغیر هدف با ویژگی‌های نوع کتیرا، b^* و Hue بیش‌ترین

۳-۲- ارزیابی مدل‌های یادگیری ماشین

عملکرد پنج مدل یادگیری ماشین شامل مدل‌های رگرسیون حداقل مربعات جزئی (PLSR)، خطی چندگانه (MLR)، ماشین بردار پشتیبان (SVR)، Lasso و Lasso با اعتبارسنجی متقابل (LassoCV) برای پیش‌بینی گرانروی ژل حاصل از

صمغ کتیرا در مراحل آموزش و آزمون جهت مقایسه و بررسی، در جدول ۳ نشان داده شده است. معیارهای ارزیابی شامل ضریب تبیین (R^2)، میانگین خطای مطلق (MAE)، ریشه میانگین مربعات خطا (RMSE) و تعداد ویژگی‌های غیرصفر بوده است.



شکل ۵- نقشه حرارتی همبستگی بین ویژگی‌های ورودی (نوری و فیزیکی) و متغیر هدف (گرانروی ژل کتیرا).

جدول ۳- شاخص‌های آماری ارزیابی در مرحله آموزش و آزمون عملکرد مدل‌های بررسی شده

ویژگی‌های غیرصفر	ارزیابی مرحله آزمون			ارزیابی مرحله آموزش			مدل
	RMSE (cP)	MAE (cP)	R^2 (%)	RMSE (cP)	MAE (cP)	R^2 (%)	
۹	۱۵۹/۲۵	۱۲۱/۳۱	۹۸/۱	۱۶۳/۵۷	۱۳۷/۵۵	۹۷/۲	PLSR
۹	۱۷۱/۸۱	۱۲۱/۵۸	۹۷/۸	۱۳۴/۹۰	۱۱۸/۸۹	۹۸/۱	MLR
-	۲۲۰/۷۶	۱۶۴/۰۳	۹۶/۳	۱۴۰/۴۲	۱۱۱/۱۵	۹۷/۹	SVR
۸	۱۴۲/۵۱	۱۰۳/۰۱	۹۸/۵	۱۳۴	۱۱۵/۸۶	۹۸/۱	Lasso
۴	۱۲۰/۰۵	۹۸/۹۲	۹۸/۹	۱۲۱/۲۳	۹۸/۸۸	۹۸/۵	LassoCV

مقادیر R^2 ، RMSE و MAE در مرحله اعتبارسنجی مدل به ترتیب ۹۸/۵ درصد و ۱۲۱/۲۳ و ۹۸/۸۸ سانتی‌پواز و در مرحله آزمون مدل به ترتیب ۹۸/۹ درصد و ۱۲۰/۰۵ و ۹۸/۹۲ سانتی‌پواز به دست آمد. پس از آن، مدل رگرسیون Lasso

نتایج ارزیابی عملکرد مدل‌های مختلف در پیش‌بینی گرانروی صمغ کتیرا نشان داد که مدل LassoCV بیش‌ترین دقت و کم‌ترین خطا را در پیش‌بینی گرانروی دارد، به طوری که با استفاده از روش اعتبارسنجی متقاطع ($CV=3$)، میانگین

جمع‌بندی نتایج نشان می‌دهد که برای این مجموعه داده خاص، مدل‌های خطی تنظیم‌شده گزینه‌های بهتری هستند. مدل‌های رگرسیون Lasso و LassoCV با کسب بالاترین ضریب تبیین در مرحله آموزش مدل (به ترتیب برابر با ۹۸/۱ و ۹۸/۵) و کم‌ترین مقادیر خطا MAE و RMSE نسبت به سایر مدل‌ها، به عنوان بهترین مدل‌ها شناخته می‌شوند.

عملکرد برتر Lasso احتمالاً ناشی از مکانیسم تنظیم L_1 است که هم‌زمان با حفظ دقت پیش‌بینی و عملکرد بهتر در انتخاب متغیر، از بیش‌برازش جلوگیری می‌کند و در نهایت مدلی پایدارتر و دقیق‌تر ارائه می‌دهد. در مدل Lasso با استفاده از هشت ویژگی غیرصفر، تعادلی مناسب بین دقت و سادگی مدل ایجاد شده است، در حالی که مدل LassoCV با چهار ویژگی غیر صفر، دقت بیش‌تری نسبت به Lasso داشت و در کاهش ابعاد داده بسیار موفق‌تر عمل کرد، اگرچه باعث حذف اثر برخی از ویژگی‌های نوری اصلی و نیز اثر روش خرد کردن به عنوان یکی از متغیرهای اصلی مورد بررسی شد. با توجه به اینکه در این مطالعه حفظ متغیرهای اصلی و قابلیت تفسیر مدل در الویت قرار دارد و نیز اختلاف ضریب تبیین دو مدل بسیار جزئی (حدود ۰/۴) است، مدل Lasso به عنوان مدل نهایی انتخاب شد. در مقایسه با پژوهش Lee et al., 2026 که با استفاده از داده‌های ابرطیفی و مدل XGBoost گرانروی را با دقت بالا ($R^2 = 99.69\%$) پیش‌بینی کردند، روش به کار گرفته شده در پژوهش حاضر با استفاده از داده‌های نوری ساده‌تر (و در نتیجه کم‌هزینه‌تر) به دقت قابل قبولی ($R^2 = 98.1\%$) دست یافته است. ضرایب و مقدار عرض از مبدا همه مدل‌های رگرسیون خطی توسعه داده شده در جدول ۴ ارائه شده است.

بالاترین دقت را نسبت به سایر مدل‌ها ارائه می‌دهد. بدین ترتیب، میانگین مقادیر R^2 ، RMSE و MAE در مرحله آموزش و اعتبارسنجی مدل به ترتیب ۹۸/۱ درصد و ۱۳۴ و ۱۱۵/۸۶ سانتی‌پواز به دست آمد. هم‌چنین مقادیر ارزیابی این شاخص‌ها در مرحله آزمون مدل، به ترتیب ۹۸/۵ درصد، ۱۴۲/۵۱ و ۱۰۳/۰۱ سانتی‌پواز به دست آمد.

مدل MLR نیز با دقت خوبی توانست مقدار گرانروی را پیش‌بینی کند. با استفاده از اعتبارسنجی متقاطع ($CV=3$)، میانگین مقادیر R^2 ، RMSE و MAE در مرحله آموزش مدل به ترتیب، ۹۸/۱ درصد و ۱۳۴/۹۰ و ۱۱۸/۸۹ سانتی‌پواز و در مرحله آزمون به ترتیب ۹۷/۸ درصد و ۱۷۱/۸۱ و ۱۲۱/۵۸ سانتی‌پواز به دست آمد. هم‌چنین برای مدل PLSR میانگین مقادیر R^2 ، RMSE و MAE در مرحله آموزش مدل به ترتیب، ۹۷/۲ درصد و ۱۶۳/۵۷ و ۱۳۷/۵۵ سانتی‌پواز و در مرحله آزمون به ترتیب ۹۸/۱ درصد و ۱۵۹/۲۵ و ۱۲۱/۳۱ سانتی‌پواز به دست آمد. این نتایج حاکی از آن است که احتمالاً رابطه خطی قوی بین متغیرهای مستقل و گرانروی وجود دارد که مدل‌های خطی را برای این مسئله مناسب می‌سازد.

ضعیف‌ترین عملکرد در بین تمام مدل‌ها برای مدل SVR به دست آمد. اگرچه برای این مدل مقادیر R^2 ، RMSE و MAE در مرحله اعتبارسنجی به ترتیب ۹۷/۹ درصد و ۱۴۰/۴۲ و ۱۱۱/۱۵ سانتی‌پواز به دست آمد؛ در مرحله آزمون، مقادیر R^2 ، RMSE و MAE به ترتیب ۹۶/۳ درصد و ۲۲۰/۷۶ و ۱۶۴/۰۳ سانتی‌پواز به دست آمد. این نتیجه ممکن است ناشی از ماهیت پیچیده‌تر این مدل و نیاز به تنظیم دقیق هابیرعامل‌ها باشد. هم‌چنین احتمالاً روابط بین متغیرها در این مسئله به اندازه‌ای پیچیده نیست که مزیت‌های مدل‌های غیرخطی مانند SVR آشکار شود.

جدول ۴- ضرایب معادله رگرسیون به دست آمده برای مدل‌های مختلف توسعه داده شده جهت پیش‌بینی گرانروی نمونه‌های کتیرا

مدل	نوع	روش خرد کردن	اندازه	L*	a*	b*	Hue	Sat	Lightness	عرض از مبدا
PLSR	-۸۹۹/۱	۲۰۰/۰۳	۲۲۷/۳۶	۲۶۰/۰۴	۹/۹۵	۱۹۰/۲۷	-۱۵۳/۶۲	-۲۷۷/۴۶	۱۷۱/۷۲	۱۶۴۲/۵
MLR	-۹۲۴/۱۸	۱۹۶/۵۹	۲۱۶/۶۹	۳۶/۹	-۷۱/۰۲	۲۵۴/۶۷	-۲۰۱/۱	-۲۴۸/۷۹	۳۸۸/۸۳	۱۵۸۱/۱۴
Lasso	-۹۸۷/۶۲	۱۱۲/۳۸	۱۷۶/۷۲	۲۱۴/۴۰	۱۴/۲۳	۱۲۴/۳۶	-۱۳۶/۲۳	-۱۹۴/۰۲	۰/۰	۱۵۸۴/۹۳
LassoCV	-۱۰۴۳/۹۸	۰/۰	۱۲۲/۴۸	۰/۰	۰/۰	۰/۰	-۴۵/۷۶	-۷۴/۷۱	۰/۰	۱۵۸۹/۸۲

۳-۳- تحلیل نمودار باقیمانده‌ها

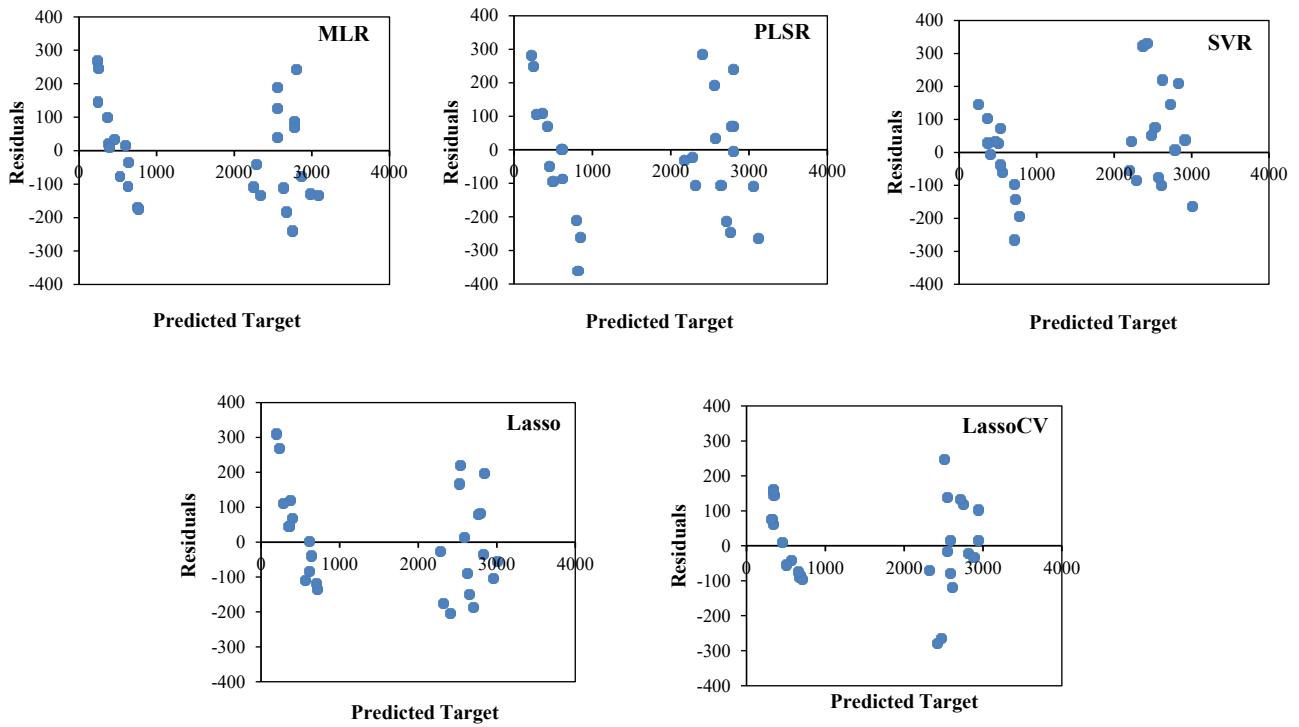
شکل ۶ نمودارهای باقیمانده در مقابل مقادیر پیش‌بینی شده را برای هر پنج مدل SVR، Lasso، MLR، PLSR و LassoCV نشان می‌دهد. نمودارهای باقیمانده ابزار قدرتمندی برای ارزیابی عملکرد مدل‌های رگرسیون ارائه می‌دهند. در این مطالعه، تحلیل دقیق این نمودارها برای پنج مدل مختلف اطلاعات ارزشمندی درباره کیفیت پیش‌بینی‌ها آشکار کرد. به‌طور ایده‌آل، باقیمانده‌ها باید به‌صورت تصادفی در اطراف محور صفر ($y=0$) پراکنده باشند و فاقد هرگونه الگوی نظام‌مند یا تجمع نقاط باشند. در داده‌های این پژوهش، به دلیل ماهیت نمونه‌ها، خروجی‌ها متعلق به دو نوع متفاوت صمغ کتیرا با دامنه‌های عددی مجزا هستند. رقم خرمی دارای مقادیر گرانی کمی (محدوده ۲۰۰ الی ۵۰۰ سانتی‌پواز) و رقم نواری دارای مقادیر گرانی زیاد (محدوده ۲۰۰۰ تا ۳۰۰۰ سانتی‌پواز) است و به‌طور کلی داده‌ای در محدوده میانی وجود ندارد. این توزیع خاص باعث شکل‌گیری دو خوشه مجزا در نمودارهای باقیمانده و شکاف در بخش میانی شده است که بیان‌گر خطای مدل ناست و مربوط به ماهیت داده‌ها و ارقام کتیرا است.

در مدل PLSR، الگوی باقیمانده‌ها پراکنده و تا حدی متقارن حول محور صفر است، که بیان‌گر برازش نسبتاً مناسب مدل است. با این حال، وجود تعدادی نقاط دورافتاده در مقادیر پایین و بالا نشان می‌دهد که مدل در پیش‌بینی برخی نمونه‌ها دچار خطاهای نسبتاً بزرگ شده است. علاوه بر این، وجود الگوی مایل در خوشه نشان دهنده‌ی عدم برازش کامل است. مدل MLR رفتار مشابهی دارد، اما باقیمانده‌ها در بازه‌های پایین مقادیر پیش‌بینی، تمایل به تمرکز دارند، در حالی که در مقادیر بالا، پراکندگی و انحراف از محور صفر افزایش می‌یابد. علاوه بر این، در هر خوشه الگویی نظام‌مند دیده می‌شود که حاکی از برازش نامناسب است. این امر احتمال وجود روابط غیرخطی میان متغیرهای ورودی و پاسخ را مطرح می‌کند که این مدل به‌دلیل ماهیت خطی خود از درک آن‌ها ناتوان است. در مقابل، مدل SVR اگرچه از نظر تئوری قابلیت مدل‌سازی روابط غیرخطی را دارد، اما در این مطالعه پراکندگی باقیمانده‌ها نشان می‌دهد که همچنان برخی مقادیر پیش‌بینی دچار خطاهای زیاد هستند. به طوری که با وجود پخشیدگی تصادفی‌تر باقیمانده‌ها نسبت به دو مدل قبل، نقاط پرت همچنان مشاهده می‌شوند. این موضوع ممکن است ناشی

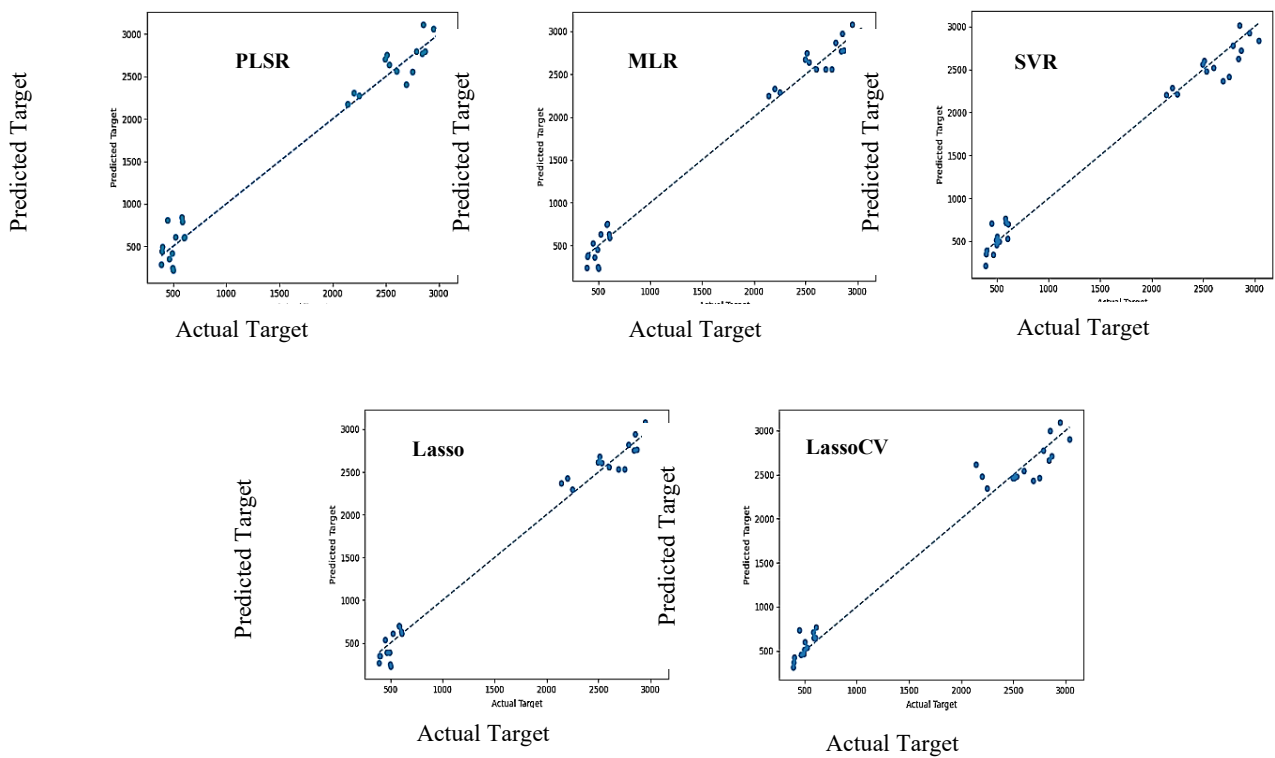
از انتخاب نادرست عامل‌های مدل یا عدم تناسب ذاتی این روش با ماهیت داده‌ها باشد.

مدل‌های Lasso و LassoCV به دلیل استفاده از جریمه L_1 و قابلیت انتخاب خودکار ویژگی‌ها، رفتار متفاوتی از خود نشان دادند. هر دو مدل توانستند خطای کلی را کاهش دهند و توزیع باقیمانده‌ها را نسبتاً فشرده‌تر نگه دارند. بررسی دقیق نمودار Lasso نشان می‌دهد که باقیمانده‌ها عمدتاً در محدوده‌ای باریک حول محور صفر نوسان دارند و الگوی تصادفی‌تری نسبت به سایر مدل‌ها شکل گرفته است. این شرایط نشان می‌دهد که مدل Lasso توانسته است تعادل بهتری میان واریانس و خطا برقرار کند. به عبارت دیگر، از بیش‌برازش جلوگیری کرده و در عین حال خطای پیش‌بینی را در سطح پایین حفظ کرده است. نتایج آماری مدل نیز این تحلیل بصری را تأیید می‌کند. مدل Lasso از نظر شاخص‌های آماری نیز پس از مدل LassoCV در وضعیت مناسب‌تری نسبت به سایر مدل‌ها قرار داشت. این موضوع نشان‌دهنده توانایی Lasso در یادگیری بهینه روابط میان متغیرها و تعمیم مناسب به داده‌های جدید است. ماهیت کاهش بعدی این مدل باعث حذف ضرایب کم‌اهمیت و تمرکز بر متغیرهای کلیدی شده است، که به بهبود دقت و کاهش نویز کمک شایانی می‌کند.

مدل Lasso ضمن حفظ سادگی ساختار، دقت بالاتری در پیش‌بینی‌ها ارائه داده است و به واسطه‌ی انتخاب ویژگی‌های مؤثر، پیچیدگی داده را به‌صورت بهینه پایش کرده است. توزیع خطاها در این مدل به صورت تقریباً متقارن حول محور صفر قرار گرفته است. این الگو نشان می‌دهد مدل توانسته است رابطه خطی بین متغیرها را به خوبی شناسایی کند. تمرکز نقاط حول صفر و عدم وجود الگوی نظام‌مند در باقیمانده‌ها، فرضیات اصلی رگرسیون خطی را تأیید می‌کند. در مقابل، نمودار باقیمانده‌های مدل LassoCV الگوی متفاوتی را نشان می‌دهد. دامنه باقیمانده بزرگ‌تر (بین ۳۰۰- تا ۳۰۰+) حاکی از آن است که این مدل در برخی نقاط خطاهای خیلی بزرگ می‌دهد و بنابراین در نقاط خاصی غیرقابل اعتماد است. این موضوع ممکن است ناشی حذف تعداد زیادی از عامل‌های اصلی مورد بررسی باشد. بنابراین، با استناد به هر دو تحلیل بصری و کمی، مدل Lasso به عنوان کارآمدترین مدل در این مطالعه شناخته می‌شود و قابلیت تعمیم بالایی در مسائل مشابه دارد.



شکل ۶- نمودارهای باقیمانده به دست آمده برای مدل‌های یادگیری ماشین توسعه داده شده



شکل ۷- نمودار مقایسه مقادیر پیش‌بینی شده در برابر مقادیر واقعی برای مدل‌های مختلف مورد بررسی

مقادیر گرانروی بالا (حدود ۲۰۰۰ تا ۳۰۰۰ سانتی‌پواز)، پراکندگی بیش‌تری نسبت به مدل Lasso دارد و تمایل دارد مقادیر را کمی کم‌تر از مقدار واقعی پیش‌بینی کند. بنابراین، این دو مدل نه‌تنها برازش مناسبی بین داده‌های واقعی و پیش‌بینی‌ها دارند بلکه تعمیم‌پذیری آن‌ها نیز در مقایسه با سایر مدل‌ها بهتر است.

به طور خلاصه، مدل‌های مبتنی بر تنظیم (مانند Lasso) برای این مسئله خاص از کارایی بالاتری برخوردارند. روش‌های خطی ساده مانند MLR اگرچه تفسیرپذیر هستند اما در مواجهه با روابط پیچیده‌تر عملکرد ضعیف‌تری دارند. مدل‌های Lasso در این مطالعه به دلیل ترکیب مناسب دقت بالا و پایداری قوی در برابر بیش‌برازش، گزینه‌های مناسبی برای پیاده‌سازی عملی پیش‌بینی گرانروی شناسایی شده‌اند.

نتیجه‌گیری

نتایج این پژوهش نشان داد که می‌توان با استفاده از یادگیری ماشین و بهره‌گیری از ویژگی‌های نوری انواع صمغ کتیرا، مقدار گرانروی آن را به صورت سریع، کم‌هزینه و با دقت بالایی تعیین کرد. در این مطالعه پنج مدل رگرسیون خطی MLR، Lasso، LassoCV، PLSR و یک مدل رگرسیون غیرخطی SVR مورد مقایسه قرار گرفتند. مدل Lasso با توجه به شاخص‌های آماری برتر همراه با حفظ ویژگی‌های اصلی، نظم بالای نقاط در اطراف خط مرجع (خطای کم‌تر) و پراکندگی حداقلی در نمودار باقیمانده‌ها، به عنوان پایدارترین و دقیق‌ترین مدل در میان تمامی روش‌های بررسی‌شده شناخته شد. این موضوع تأییدکننده کارایی بالا و قابلیت اعتماد مدل Lasso در پیش‌بینی داده‌های پیچیده و چند بعدی است. همچنین، در این مدل، با اعمال جریمه L_1 بر روی ضرایب، یکی از ویژگی‌ها به‌طور مؤثر حذف شد که ضمن کاهش بعد، به ارائه یک مدل سبک‌تر و قابل‌تفسیرتر منجر گردید. به‌طورکلی نتایج نشان داد که مدل Lasso از نظر شاخص‌های آماری R^2 ، RMSE، MAE، توزیع مقادیر باقیمانده‌ها و دقت و سرعت پیش‌بینی، عملکرد بهتری نسبت به سایر مدل‌ها داشته و انتخابی بهینه برای پیش‌بینی غیرمخرب گرانروی محسوب می‌شود.

از جمله محدودیت‌های پژوهش حاضر آن است که این مطالعه عمدتاً با هدف امکان‌سنجی انجام و به همین دلیل، حجم نمونه‌ها به گونه‌ای محدود در نظر گرفته شده است. چنین محدودیتی برای مدل‌سازی مبتنی بر یادگیری ماشین،

۳-۴- تحلیل نمودار مقادیر پیش‌بینی‌شده نسبت به مقادیر واقعی

شکل ۷ رابطه بین مقادیر واقعی و مقادیر پیش‌بینی‌شده را برای پنج مدل رگرسیونی Lasso، SVR، MLR، PLSR و LassoCV نمایش می‌دهد. این نمودارها ابزار مهمی برای بررسی میزان برازش مدل‌ها محسوب می‌شوند، چرا که هرچه نقاط به خط قطری (خط مرجع $y=x$) نزدیک‌تر باشند، دقت مدل بالاتر و اختلاف بین مقادیر واقعی و پیش‌بینی شده کم‌تر است. در نمودار همه مدل‌ها، روند کلی صعودی و نزدیک به خط مرجع مشاهده می‌شود که نشان‌دهنده توانایی هر پنج مدل در پیش‌بینی مقادیر خروجی است.

با این حال تفاوت‌هایی در تراکم نقاط و میزان پراکندگی نسبت به خط مرجع وجود دارد که دقت و پایایی هر مدل را متمایز می‌سازد. مدل PLSR، اگرچه به دلیل ماهیت کاهش بعدی در داده‌های دارای هم‌بستگی عملکرد قابل قبولی دارد، اما پراکندگی خفیف پیرامون خط مرجع (به ویژه در مقادیر میانی و بالایی) نشان می‌دهد که در برخی نقاط دچار خطای متوسط می‌شود. در مدل MLR نیز الگوی مشابهی دیده می‌شود، اما میزان انحراف نقاط از خط معیار بیش‌تر است. این پراکندگی در مدل‌های خطی ساده، احتمال وجود روابط غیرخطی در داده‌ها را نشان می‌دهد که MLR قادر به مدل‌سازی آن‌ها نیست و در نتیجه دقت پیش‌بینی آن کاهش می‌یابد.

مدل SVR توزیع نسبتاً متراکمی نزدیک به خط قطری دارد، که بیان‌گر دقت مناسب این مدل در پیش‌بینی است. با این وجود، در مقادیر پایین و بالا اندکی پراکندگی مشاهده می‌شود، که ممکن است به علت تنظیم نامناسب عامل‌های مدل باشد.

مدل‌های Lasso و LassoCV بهترین تطابق را میان مقادیر واقعی و پیش‌بینی‌شده ارائه داده‌اند. در این دو مدل، اکثر نقاط بسیار نزدیک بر مسیر خط مرجع قرار دارند که نشان‌دهنده هم‌بستگی بالا و خطای پیش‌بینی پایین است. مدل Lasso به ویژه توانسته است دقت پیش‌بینی را هم در دامنه پایین و هم در دامنه بالا حفظ کند. این پایداری به دلیل استفاده Lasso از جریمه‌گذاری L_1 است که ضمن حذف ویژگی‌های کم‌اهمیت، عامل‌های کلیدی را حفظ کرده و از بیش‌برازش جلوگیری می‌کند. اعتبارسنجی متقاطع در LassoCV نیز به انتخاب بهینه عامل تنظیمات و بهبود پایداری مدل کمک کرده است. اگرچه LassoCV در دامنه

می‌تواند استانداردسازی کیفی در زنجیره تأمین کتیرا را تسهیل کرده و بستری برای پایش بلادرنگ کیفیت در خطوط تولید و مراکز تجاری فراهم آورد.

سپاسگزاری

بدین‌وسیله از مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی اصفهان قدردانی می‌کنیم. تمامی مراحل آزمایشگاهی و اندازه‌گیری‌های این پژوهش در آزمایشگاه بخش تحقیقات فنی و مهندسی این مرکز و با استفاده از امکانات تخصصی آن انجام شده است. بی‌تردید، حمایت‌ها و همکاری‌های این مرکز نقشی اساسی در دقت و قابلیت اعتماد نتایج آزمایشگاهی این تحقیق داشت. از همین رو، از تلاش‌ها و مساعدت‌های کارکنان این بخش صمیمانه سپاسگزاریم.

مشارکت نویسندگان

نحوه و میزان مشارکت نویسندگان در انجام این پژوهش به صورت زیر است:

- ا. نصرنیا مسئولیت نگارش متن، مدل‌سازی، پردازش داده‌ها و تحلیل نتایج را بر عهده داشت.
- ع. ایمان‌مهر در مفهوم‌پردازی تحقیق و انجام آزمایش‌ها مشارکت داشت.
- م. حیدری‌سلطان‌آبادی در نگارش و بازبینی نسخه خطی همکاری نمود.
- ف. سالک در مدل‌سازی و بازبینی مقاله نقش ایفا کرد. همگی نویسندگان نسخه نهایی مقاله را مطالعه و تایید نموده‌اند.

دسترسی به داده‌ها

مجموعه داده‌های تولیدشده و/یا تحلیل‌شده در طول مطالعه حاضر، توسط نویسنده مسئول و در پاسخ به درخواست‌های معقول در دسترس خواهند بود.

اصول اخلاقی

پژوهش حاضر منطبق بر استانداردهای اخلاقی و اصالت علمی انجام پذیرفته و تمامی مراحل آزمایشگاهی آن در چارچوب ضوابط ایمنی و دستورالعمل‌های اخلاقی مصوب صورت گرفته است. نویسندگان بر این باورند که هیچ‌گونه داده‌سازی، تحریف نتایج، سرقت ادبی یا سایر مصادیق تخلف پژوهشی در انجام این مطالعه روی نداده است.

به ویژه برای الگوریتم‌های پیچیده‌ای همچون ماشین بردار پشتیبان (SVR)، از نظر آماری با کفایت لازم همراه نیست و قابلیت تعمیم نتایج را به چالش می‌کشد. افزون بر این، شکاف معناداری در دامنه گرانروی داده‌ها وجود داشته که نشان می‌دهد اضافه کردن اطلاعات مربوط به سایر ارقام کتیرا می‌تواند مدل جامع‌تری ایجاد کند. این شکاف داده‌ای مدل را در پیش‌بینی مقادیر میانی (در صورت مشاهده در سایر ارقام) عملاً ناتوان می‌سازد. محدودیت دیگر به ماهیت ویژگی‌های ورودی باز می‌گردد، زیرا استفاده از روش‌های پیشرفته‌تر نظیر تصویربرداری ابرطیفی یا طیف‌سنجی مرئی-فروسرخ می‌توانست اطلاعات شیمیایی و مولکولی دقیق‌تری را در اختیار مدل قرار دهد و احتمالاً دقت پیش‌بینی را افزایش دهد که نیاز به هزینه‌های بسیار بیش‌تری دارد.

در راستای رفع محدودیت‌های ذکرشده و توسعه پژوهش حاضر، پیشنهاد‌های زیر مطرح می‌گردد: نخست، با توجه به ماهیت امکان‌سنجی این مطالعه، ضروری است در گام‌های بعدی، پژوهش بر روی ارقام متنوع‌تر و با تعداد نمونه‌های بیش‌تر گسترش یابد تا پایه آماری مناسبی برای مدل‌های یادگیری ماشین فراهم آید. دوم، توصیه می‌شود در مجموعه داده‌های آتی، به ویژه در دامنه گرانروی ۵۰۰ تا ۲۰۰۰ سانتی‌پواز، نمونه‌برداری هدفمند انجام شود تا پیوستگی دامنه ورودی مدل تأمین گردد.

سوم، به کارگیری روش‌های طیف‌سنجی پیشرفته و روش‌های تصویربرداری مولکولی به عنوان ویژگی‌های ورودی جایگزین یا مکمل، می‌تواند گامی مؤثر در جهت افزایش دقت و قابلیت تعمیم‌پذیری مدل‌های پیش‌بینی در مطالعات آتی باشد. همچنین، با توجه به ماهیت کاربردی این پژوهش و نیز قابلیت بالای آن برای به کارگیری در صنایع مرتبط با هیدروکلوئیدهای طبیعی، به ویژه حوزه تولید و تجارت صمغ کتیرا، پیشنهاد می‌شود مسیر تحقیقاتی حاضر با هدف توسعه یک مدل جامع و یکپارچه ادامه یابد. در این مدل پیشنهادی، با بهره‌گیری از رویکردهای یادگیری ماشین و بینایی ماشین، پردازش مستقیم تصاویر دیجیتال گرفته‌شده از نمونه‌های مختلف ارقام کتیرا امکان‌پذیر گردد. مدل مذکور می‌تواند با استخراج ویژگی‌های ریخت‌شناختی، بافتی و رنگی از تصاویر نمونه‌ها و سپس اعمال الگوریتم‌های پیشرفته یادگیری ماشین و یا یادگیری عمیق، مقادیر گرانروی را به‌طور خودکار، سریع، کم‌هزینه و غیرمخرب تخمین بزند. چنین رویکردی ضمن حذف نیاز به روش‌های سنتی پرهزینه و مخرب آزمایشگاهی،

- Lee, S., Jeong, S. & Lee, S. (2026). Hyperspectral imaging-based classification and viscosity prediction of hydrocolloids using convolutional neural network and ensemble models. *Journal of Food Engineering*. Volume 409. <https://doi.org/10.1016/j.jfoodeng.2025.112902>
- Malashin, I., Tynchenko, V., Gantimurov, A., Nelyub, V., & Borodulin, A. (2025). Boosting-Based Machine Learning Applications in Polymer Science: A Review. *Polymers* 2025, 17, 499. DOI: [10.3390/polym17040499](https://doi.org/10.3390/polym17040499)
- Ninchan, B., Chauyongyart, P., Utapong, T., & Thamrongsiripak, N. (2024). Effect of Gamma Irradiation on Depolymerization and Property Changes of Gum Tragacanth. <https://doi.org/10.1155/ijbm/8875341>
- Petkovska, J., Geskovski, N., Marković, D., Dimova, V., Mirakovski, D., Radetić, M. & Jordanov, I. (2024). Chitosan-pectin multilayer coating with anthocyanin grape dye as pH indicating wound dressing: Synthesis and characterization. *Carbohydrate Polymer Technologies and Applications* 7 (2024) 100438. DOI: [10.1016/j.carpta.2024.100438](https://doi.org/10.1016/j.carpta.2024.100438)
- Qi, H., Li, H., Chen, L., Chen, F., Luo, J. & Zhang, C. (2024). Hyperspectral Imaging Using a Convolutional Neural Network with Transformer for the Soluble Solid Content and pH Prediction of Cherry Tomatoes. *Foods* 2024, 13, 251. <https://doi.org/10.3390/foods13020251>
- Qiu, L., Zhang, M., Mujumdar, A. S. Chang, L. (2022). Convenient use of near-infrared spectroscopy to indirectly predict the antioxidant activity of edible rose (*Rose chinensis* Jacq “Crimsin Glory” H.T.) petals during infrared drying. *Food Chemistry* Volume 369, 1 February 2022, 130951. DOI: [10.1016/j.foodchem.2022.130951](https://doi.org/10.1016/j.foodchem.2022.130951)
- Qomshi Bozorg, P., Wahabi, M. & Fazilati, M. (2012). Qualitative investigation of white gossip (*Astragalus gossypinus* Fischer.) in the western region of Isfahan province. *Scientific-research quarterly of medicinal and aromatic plants*. 27(4): 668-680. (in Persian). DOI: [10.22092/ijmapr.2012.4516](https://doi.org/10.22092/ijmapr.2012.4516)
- Tavakol, M. & Mohammadifar, M. A. (2017). A review on gum tragacanth and its biomedical applications. *Nashrieh Shimi va Mohandesi Shimi Iran (NSMSI)*, 36(84): 1-20. (in Persian). https://www.nsmsi.ir/article_29721_en.html
- Xuan, W., Zhao, C., Ma, Z., Liu, Z. & Zhang, J. (2025) Data-driven machine learning methods to predict the viscosity-temperature characteristics for gasification slags. *Fuel*. Volume 398. <https://doi.org/10.1016/j.fuel.2025.135287>
- Zahedi, A. H. & Vedadi, I. (1979). Effect of Gum Tragacanth size reduction on DTA and TG behavior and its relationship to solution viscosity. *Thermochimica Acta*, 34: 281-286. [https://doi.org/10.1016/0040-6031\(79\)87118-X](https://doi.org/10.1016/0040-6031(79)87118-X)
- Zhang, W., Kasun, L. C., Wang, Q. J., Zheng, Y. & Lin, Z. (2022). A Review of Machine Learning for Near-Infrared Spectroscopy. *Sensors* 2022, 22, 9764.

تضاد منافع نویسندگان

نویسندگان اعلام می‌کنند که هیچ گونه منافع مالی رقابتی یا روابط شخصی شناخته‌شده‌ای که ممکن است بر کار گزارش شده در این مقاله تأثیر گذاشته باشد، ندارند.

حمایت مالی

نویسندگان این مقاله هیچ حمایت مالی خاصی برای انجام این پژوهش دریافت نکرده‌اند.

منابع

- Abbasi, S. & Rahimi, S. (2006). Investigating the effect of concentration, temperature, viscosity and rotation speed on the flow behavior of Iranian Tragacanth gum solution. *Iranian Journal of Food Sciences and Industries*, 2(4): (in Persian). <https://fsct.modares.ac.ir>
- Anon. (2001). Tragacanth Gum. Metals and arsenic specifications revised at the 57th JECFA. <https://cybercolloids.net/information/technical-articles/tragacanth-gum-jecfa-specification/>
- Anon. (2006). Food Additive Status List. <https://www.fda.gov/food/food-additives-petitions/food-additive-status-list>
- Balaghi, S., Mohammadifar, M., & Zargaraan, A. (2010). Physicochemical and rheological characterization of gum tragacanth exudates from six species of Iranian Astragalus. *Food Biophysics*, 5(1), 59e71. DOI: [10.1007/s11483-009-9144-5](https://doi.org/10.1007/s11483-009-9144-5)
- Barak, S., Mudgil, D., & Taneja, S. (2020). Exudate gums: Chemistry, properties and food applications—a review. *Journal of the Science of Food and Agriculture*, 100(7), 2828–2835. DOI: [10.1002/jsfa.10302](https://doi.org/10.1002/jsfa.10302)
- Boamah, P. O., Afoakwah, N. A., Onumah, J., Osei, E. D. & Mahunu, G. K. (2023). Physicochemical properties, biological properties and applications of gum tragacanth—a review. *Carbohydrate Polymer Technologies and Applications* 5 (2023) 100288. DOI: [10.1016/j.carpta.2023.100288](https://doi.org/10.1016/j.carpta.2023.100288)
- Chew, A. K., Sender, M., Kaplan, Z., Chandrasekaran, A., Chief Elk, J., Browning, A. R., Shaun Kwak, H., Halls, M. d. & Afzal, M. A. F. (2024). Advancing material property prediction: using physics-informed machine learning models for viscosity. DOI: [10.26434/chemrxiv-2023-1qfw8-v2](https://doi.org/10.26434/chemrxiv-2023-1qfw8-v2)
- Haroon, K., Arafah, A., Martin, P., Rodgers, T., Mendoza, C. & Baker, M. (2019). Use of inline near-infrared spectroscopy to predict the viscosity of shampoo using multivariate analysis. *International Journal of Cosmetic Science*, 2019, 41, 346–356. DOI: [10.1111/ics.12536](https://doi.org/10.1111/ics.12536)
- Imanmehr, A & Heidarisoltanabadi, M. (2024). The effect of mechanical processing methods on the color and viscosity properties of Tragacanth gum (In Persian). *Journal of Research in Mechanics of Agricultural Machinery*. 13(2), 79-86. DOI: [10.22034/JRMAM.2024.14735.702](https://doi.org/10.22034/JRMAM.2024.14735.702)

