



Predicting biomass Gasification outputs with the aid of machine-learning

Pouria Mohammad Javaheri¹ | Shahin Rafiee^{2✉} | Mortaza Aghbashloo³

1. Department of Mechanical Engineering of Agricultural Machinery, Faculty of Agricultural Engineering and Technology, College of Agriculture and Natural Resources, University of Tehran, Iran. E-mail: Pouria.Javaheri@ut.ac.ir

2. Corresponding Author, Department of Mechanical Engineering of Agricultural Machinery, Faculty of Agricultural Engineering and Technology, College of Agriculture and Natural Resources, University of Tehran, Iran. E-mail: ShahinRafiee@ut.ac.ir

3. Department of Information Science, Faculty of Management, University of Tehran, Tehran, Iran. Department of Mechanical Engineering of Agricultural Machinery, Faculty of Agricultural Engineering and Technology, College of Agriculture and Natural Resources, University of Tehran, Iran E-mail: maghashloo@ut.ac.ir

Article Info

Article type: Research Article

Article history:

Received: June. 23, 2024

Revised: Dec. 31, 2024

Accepted: Feb. 2, 2025

Published online: Autumn 2024

Keywords:

**Artificial Intelligence,
Biomass,
Gasification,
Machine-Learning.**

ABSTRACT

Optimizing existing technologies in this field has become inevitable with the increasing demand for renewable energy sources. Among the renewable resources that have attracted much attention in research, biomass resources can be mentioned. In this study, an attempt has been made to examine one of the technologies for extracting energy from biomass resources - gasification - and to optimize and control this technology as much as possible, after forming a database extracted from a comprehensive review of related articles, its outputs have been predicted using several techniques in the field of artificial intelligence and machine learning. The statistical artificial intelligence methods used in this study were selected after reviewing similar articles. They included linear regression, gradient boosting regression, decision tree regression, random forest regression, support vector regression, and kernel ridge regression. Finally, this research resulted in several AI-based forecasting models with different forecast accuracies, which were evaluated with the relevant statistical parameters. Among the aforementioned machine learning techniques and considering the various parameters for evaluating the accuracy of the models, the most important of which is the squared error in the test data, the linear regression, gradient boosting regression, and random forest regression methods, whose squared error rates in each of the models were 0.909, 0.829, and 0.818, respectively, showed better performance than other proposed technologies.

Cite this article: Mohammad Javaheri, P., Rafiee, Sh., Aghbashloo, M., (2024) Predicting biomass Gasification outputs with the aid of machine-learning, *Iranian Journal of Biosystem Engineering*, 55 (3), 73-85. <https://doi.org/10.22059/ijbse.2025.378433.665555>

© The Author(s).

Publisher: The University of Tehran Press.

DOI: <https://doi.org/10.22059/ijbse.2025.378433.665555>





EXTENDED ABSTRACT

Introduction

With the increasing demand for renewable energy sources, the optimization of existing technologies in this field has become inevitable. Among different renewable energy sources, biomass showed great potential possessing features such as being abundant, environmental-friendly (e.g. lower environmental impact, being carbon-neutral, etc.), low-cost, and producing a wide variety of desirable products. The mentioned advantageous characteristics resulted in its importance in the current global energy supply and accountability for above 70 percent of green energy production.

Materials and Methods

In this research, an attempt has been made to examine one of the technologies for extracting energy from biomass sources - gasification - and in order to optimize and control this technology as much as possible, after gathering data and making the database, its outputs by using several techniques in the field of artificial intelligence and learning Machines are predicted. The statistical artificial intelligence methods used in this research were selected after reviewing similar articles and include linear regression (LR), gradient boosting regression (GBR), decision tree regression (DTR), random forest regression (RFR), Support vector regression (SVR) and kernel Ridge Regression (KRR).

Results and Discussion

Machine learning (ML) shows great potential for being a fast, relatively inexpensive, and accurate approach to predicting gasification outputs. Although some efforts have been made to predict the effect of control parameters on the gasification output, this paper offers a comprehensive approach to evaluate the relationship between different biomass precursor characteristics and the energy output of the gasification process with the aid of different data-driven ML techniques. Finally, this research resulted in several prediction models based on artificial intelligence with different prediction accuracies. Among the mentioned machine learning techniques and taking into account various parameters for assessing the accuracy of models, among the most important of which we can mention the square error in the test data, linear regression (LR), gradient boosting regression (GBR) and Random Forest Regression (RFR) with r-squared of 0.909, 0/829 and 0/818 performed better than the rest of the proposed technologies.

Conclusion

This research resulted in several prediction models based on artificial intelligence with different prediction accuracies. Among the mentioned machine learning techniques and taking into account various parameters for assessing the accuracy of models, among the most important of which we can mention the square error in the test data, linear regression (LR), gradient boosting regression (GBR) and Random Forest Regression (RFR) with r-squared of 0.909, 0.829 and 0.818 performed better than the rest of the proposed technologies.

Author Contributions

All authors contributed equally to the conceptualization of the article and writing of the original and subsequent drafts.

Data Availability Statement

Data available on request from the authors.

Ethical considerations

The study was approved by the Ethics Committee of the University of ABCD (Ethical code: IR.UT.RES.2024.500). The authors avoided data fabrication, falsification, plagiarism, and misconduct.

Conflict of interest

The author declares no conflict of interest.

پیش‌بینی خروجی‌های تکنولوژی‌گازی سازی منابع زیست‌توده با بهره‌گیری از یادگیری ماشین

پوریا محمد جواهری^۱ | شاهین رفیعی^۲ | مرتضی آغباشلو^۳^۱ گروه مهندسی ماشین‌های کشاورزی، دانشگدان کشاورزی و منابع طبیعی، دانشگاه تهران، ایران. رایانامه: Pouria.Javaheri@ut.ac.ir^۲ نویسنده مسئول، گروه مهندسی ماشین‌های کشاورزی، دانشگدان کشاورزی و منابع طبیعی، دانشگاه تهران، ایران. رایانامه:ShahinRafiee@ut.ac.ir^۳ گروه مهندسی ماشین‌های کشاورزی، دانشگدان کشاورزی و منابع طبیعی، دانشگاه تهران، ایران. رایانامه: maghashloo@ut.ac.ir

اطلاعات مقاله

چکیده

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۳/۴/۳

تاریخ بازنگری: ۱۴۰۳/۱۰/۱۱

تاریخ پذیرش: ۱۴۰۳/۱۱/۱۴

تاریخ انتشار: پاییز ۱۴۰۳

واژه‌های کلیدی:

زیست‌توده،

گازی‌سازی،

هوش مصنوعی،

یادگیری ماشین.

با افزایش روزافزون تقاضا برای منابع انرژی تجدیدپذیر، بهینه‌سازی فناوری‌های موجود در این حوزه بدل به امری اجتناب‌ناپذیر شده است. از جمله منابع تجدیدپذیر که در تحقیقات توجهات بسیاری را به خود جلب کرده است می‌توان به منابع زیست‌توده اشاره داشت. در این پژوهش تلاش شده است که یکی از فناوری‌های استحصال انرژی از منابع زیست‌توده - گازی‌سازی - مورد بررسی قرار گیرد و به‌منظور بهینه‌سازی و کنترل هر چه بیشتر این فناوری، پس از تشکیل پایگاه داده مستخرج از بررسی جامع مقالات مرتبط، خروجی‌های آن با بهره‌گیری از چندین تکنیک در حوزه هوش مصنوعی و یادگیری ماشین پیش‌بینی شده‌اند. روش‌های هوش مصنوعی آماری استفاده شده در این پژوهش پس از بررسی مقالات مشابه انتخاب شدند و عبارت‌بودند از رگرسیون خطی، رگرسیون تقویت‌کننده گرادیان، رگرسیون درخت تصمیم‌گیری، رگرسیون جنگل رندوم، رگرسیون بردار ساپورت و رگرسیون کرنل ریج. در نهایت این پژوهش منتج به چندین مدل پیش‌بینی بر پایه هوش مصنوعی بادقت‌های پیش‌بینی مختلف شد که با پارامترهای آماری مربوطه، دقت پیش‌بینی مدل‌های مختلف مورد ارزیابی قرار گرفت. در میان تکنیک‌های یادگیری ماشین مذکور و با در نظر گرفتن پارامترهای مختلف ارزیابی دقت مدل‌ها که از جمله مهم‌ترین آن‌ها می‌توان به مربع خطا در داده‌های تست اشاره کرد، روش‌های رگرسیون خطی، رگرسیون تقویت‌کننده گرادیان و رگرسیون جنگل تصادفی، که میزان مربع خطا در هر یک از مدل‌ها به ترتیب برابر ۰/۹۰۹، ۰/۸۲۹ و ۰/۸۱۸ بود، عملکرد بهتری از خود نسبت به سایر فناوری‌های پیشنهاد شده نشان دادند.

استناد: محمدجواهری؛ پوریا، رفیعی؛ شاهین، آغباشلو؛ مرتضی، (۱۴۰۳) پیش‌بینی خروجی‌های تکنولوژی‌گازی‌سازی منابع زیست‌توده با بهره‌گیری از یادگیری ماشین،

مجله مهندسی بیوسیستم ایران/ ایران، ۵۵ (۳)، ۷۳-۸۵. <https://doi.org/10.22059/ijbse.2025.378433.665555>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijbse.2025.378433.665555>

مقدمه

مصرف انرژی جهانی به خاطر عوامل متعدد تاثیر گذار همچون رشد جمعیت جهان، بهبود استانداردهای زندگی، سرعت صنعتی شدن جوامع، توسعه اقتصادی و غیره، بسرعت در حال افزایش است. در حال حاضر سوخت‌های فسیلی همچنان منبع اولیه انرژی محسوب شده و ۸۷ درصد مصرف کل انرژی را در سراسر جهان تشکیل می‌دهند (Zhou et al., 2019). در عین حال اما توجه روز افزون به تاثیرات مخرب سوخت‌های فسیلی بر محیط زیست مثل اثر گلخانه‌ای و گرم شدن زمین، تغییرات اقلیمی و آلودگی منابع طبیعی منجر به کاهش مصرف سوخت‌های فسیلی و گرایش به سمت انرژی و منابع تجدید پذیر شده است (Akbarian et al., 2022b). زیست‌توده در میان منابع انرژی تجدیدپذیر ویژگی‌های فرایندی بالقوه زیادی از جمله فراوانی، سازگاری بیشتر با محیط زیست (به معنی تاثیرات کمتر بر محیط زیست، کربن خنثی بودن آن و ...) و ایجاد تنوع زیاد از محصولات مطلوب از خود نشان داده که باعث اهمیت و جایگاه آن در تامین کنونی منابع انرژی جهان و احتساب ۷۰٪ از تولید انرژی سبز شده است (Villora et al., 1998). زیست‌توده عبارت است از مجموعه ای از منابع همچون گیاهان، محصولات کشاورزی و زراعی و محصولات جنگلی و نیز پسماند آنها، زیست‌توده‌های دریایی (بخصوص جلبک‌ها)، بخش ارگانیک پسماندهای خشک شهری و غیره. روش‌های متعددی برای دسته‌بندی منابع زیست‌توده وجود دارد. بعنوان مثال دسته‌بندی بر اساس ترکیب شیمیایی (زیست‌توده لیگنوسلولزی، غنی از قند، غنی از چربی، غنی از نشاسته و غنی از پروتئین)، بر اساس منشأ (زیست‌توده های با منشأ کشاورزی، جنگل، پسماند، و یا آبی) و بر اساس کاربری نهایی (اعم از حمل و نقل، تولید گرما و برق، زیست پالایشگاه و حمل کننده انرژی) (Sánchez et al., 2019). معمولاً ۴ نسل از زیست‌توده در تمام مقالات و کتب آورده می‌شود که عبارتند از (Aziz et al., 2020):

زیست‌توده نسل اول: این زیست‌توده شامل منابع خوراکی و خوردنی است مثل ذرت و نیشکر که مقدار قند و نشاسته آنها بالاست
زیست‌توده نسل دوم: شامل منابع غیرخوراکی مثل بخش ارگانیک پسماندهای جامد شهری، پسماندهای کشاورزی و محصولات
حاوی انرژی

زیست‌توده نسل سوم: این نسل از زیست‌توده معمولاً از جلبک و جلبک‌های دریایی به‌عنوان خوراک استفاده می‌کند

زیست‌توده نسل چهارم: از منابع اصلاح ژنتیکی شده به‌عنوان خوراک استفاده می‌کند

در حال حاضر روش‌های متعددی برای تبدیل زیست‌توده به انرژی وجود دارد. مثلاً تبدیل ترموشیمیایی مثل گازدار کردن، پیرولیز، ترفکشن، تبدیل به مایع کردن و غیره و نیز تبدیل‌های بیولوژیکی مانند تخمیر، هضم بی‌هوازی و غیره. روش‌های تبدیل ترموشیمیایی مزایایی دارند مثل بازدهی بالاتر تبدیل و حساسیت به کیفیت خوراک در آنها کمتر است، زمان واکنش کمتری دارند و انعطاف‌پذیری آنها در ماتریس محصول در مقایسه با روش‌های تبدیل بیولوژیکی بیشتر است. گازی‌سازی یکی از پرکاربردترین فرایندهای تبدیل ترموشیمیایی است. فرایند تبدیل زیست‌توده جامد اولیه به مخلوط گازی بانرژی بالا با کمک عوامل مختلف گازدار شدن در دماهای بالا، در حضور یا بدون حضور کاتالیزور، را گازی‌سازی می‌نامند. این مخلوط گازی بانرژی بالا عموماً به‌عنوان گاز سنتز یا تولیدکننده گاز شناخته می‌شود. برخلاف سایر روش‌های تبدیل ترموشیمیایی مثل پیرولیز و ترفکشن که به ترتیب بر تولید محصولات مایع و جامد تاکید دارند اصلی‌ترین محصول گازی‌سازی گاز سنتز است. گاز سنتز معمولاً از گازهای مختلف مثل هیدروژن، مونوکسید کربن و دی‌اکسید کربن و متان و مقدار ناچیزی ناخالصی‌های دیگر تشکیل شده است درصدهای مختلفی از هر کدام از مواد تشکیل‌دهنده وجود دارد که مستقیماً متأثر از نوع خوراک زیست‌توده و پارامترها و عوامل مختلف گازی‌سازی است (مثل دما و فشار). علاوه بر گاز سنتز، گازی‌سازی منجر به تولید تعدادی محصول جانبی جامد (دوده) و مایع (تار) می‌شود در نتیجه استفاده از گاز مناسب که زیرفرایندها را تمیز و پاک‌سازی کند امری ضروری است. استفاده از تکنیک‌ها و پارامترهای مختلف کنترلی می‌تواند باعث تولید انواع مختلف گازی‌سازی شود. برخی از این روش‌ها عبارتند از: گازی‌سازی بستر ثابت، گازدار کردن بستر سیال، گازی‌سازی با بستر متحرک، گازی‌سازی سیال حبابدار و گازدار کردن پلاسما (Midilli et al., 2021). گازی‌سازی سیال حبابدار و پلاسما معمولاً در دمای بین ۱۲۰۰ تا ۱۷۰۰ درجه سلسیوس انجام می‌گردد و سایر روش‌ها عموماً بین ۹۰۰ تا ۱۲۰۰ درجه سلسیوس انجام می‌شود (Long et al., 2020). همان‌طور که گفته شد پارامترهای کنترلی گازی‌سازی از جمله دما، فشار، غلظت مواد واکنش دهنده و زمان آن بشدت بر محصول آن فرایند و ترکیب بندی آن تاثیر می‌گذارد. گازدار کردن

زیست‌توده‌ای را می‌توان به سه مرحله تقسیم کرد (Rodionova et al., 2022): خشک‌کردن؛ تبخیر مرطوب و تولید بخار در این فاز انجام می‌شود زدودن مواد فرار؛ بخش فرار حذف شده و زغال در این فاز تشکیل می‌شود. گازی‌سازی زغال: اکسیژن (از یک ماده گازدار کننده) با زغال واکنش می‌دهد و گاز کربن دی‌اکسید یا کربن مونوکسید و گرما تولید می‌کند. بعلاوه، زغال با بخار (آمده از فاز اول) و کربن دی‌اکسید ترکیب شده و تولید هیدروژن و کربن مونوکسید می‌کند. ویژگی‌های اولیه زیست‌توده مثل آنالیز تقریبی (درصد رطوبت، کربن ثابت، مواد فرار، و خاکستر)، آنالیز نهایی (درصد کربن، هیدروژن، اکسیژن؛ نیتروژن، و گوگرد) مقدار ارزش حرارتی بالاتر و مقدار ارزش حرارتی پایین‌تر از اهمیت زیادی در تعیین میزان انرژی حاصله از فرایند گازی‌سازی و عملکرد و بازدهی نهایی آن برخوردار است. پیش‌بینی اینکه ویژگی‌های زیست‌توده ورودی چگونه بر انرژی خروجی فرایند گازی‌سازی تأثیر می‌گذارد (بر میزان گرمای گاز سنتز) می‌تواند به کنترل بهتر و راحت‌تر فرایند کمک کند همچنین به شناخت منابع جدیدتر زیست‌توده و ارزیابی منابع بالقوه زیست‌توده‌ای نیز کمک خواهد کرد. اگر چه برخی از روش‌های مدل‌سازی سنتی مثل روش محاسباتی دینامیک سیالات، مدل‌سازی ترمودینامیک و سینتیک می‌تواند روابط ورودی-خروجی را در فرایند گازی‌سازی تا حدی پیش‌بینی کند؛ اما هر کدام از اینها نقاط ضعف خود را دارند. مثلاً روش محاسباتی دینامیک سیالات نیاز به مصرف برق زیادی دارد و بنابراین بسیار گران و زمان‌بر است (Elmaz et al., 2020). همچنین برخی مدل‌های ترمودینامیکی و سینتیکی بر اساس فرضیات بی‌شمار و یا ساده سازی بیش از حد کار میکنند که ممکن است باعث بروز چالش‌هایی شود. هوش مصنوعی (فراگیری ماشینی) پتانسیل بالایی برای پیش‌بینی دقیق، ارزان‌تر و سریع‌تر محصول خروجی گاز دار کردن از خود نشان داده است.

پیشینه پژوهش

تحقیقات زیادی در بحث مدل‌سازی و پیش‌بینی فرایند گازی‌سازی انجام شده است. الماز و همکاران در سال ۲۰۲۰ طی یک تحقیق گازی‌سازی از زباله جامد شهری را مدل‌سازی کردند. آنها با به کارگیری سه مدل یادگیری ماشین، میزان گاز زیستی و زغال زیستی را برای این فرایند تخمین زدند. الگوریتم رگرسیون تقویت کننده گرادیان بهترین پیش‌بینی را نشان داد (Elmaz et al., 2020). یانگ و همکاران در سال ۲۰۲۳ مدل‌سازی یادگیری ماشین را برای گازسازی از زیست‌توده و زباله به کار بردند که مدل شبکه‌های عصبی مصنوعی، بالاترین دقت را در مدل‌سازی داشت (Yang et al., 2023). همچنین آلفارا و همکاران در سال ۲۰۲۴ در مقاله ای مروری، به بررسی روش‌های یادگیری ماشین مورد استفاده برای گازی‌سازی زیست‌توده و مقایسه این روش‌ها پرداختند (Alfarra et al., 2024). بونگومین و همکاران در سال ۲۰۲۴ نیز، مدلی جهت بهینه‌سازی فرایند گازی‌سازی برای استحصال انرژی از زیست‌توده بر مبنای یادگیری ماشین ارائه دادند (Bongomin et al., 2024). فیاضی و همکاران نیز در سال ۲۰۲۴، پژوهشی با هدف بهبود تولید زیست‌گاز از زیست‌توده و بهینه‌سازی خروجی‌های این حوزه انجام دادند (Fiazi et al., 2024).

هرچند که تلاش‌هایی برای پیش‌بینی تأثیر پارامترهای کنترلی بر محصول خروجی گازی‌سازی انجام شده است؛ اما در این مقاله روشی جامع برای بررسی رابطه بین ویژگی‌های مواد اولیه زیست‌توده‌ها و محصول خروجی انرژی در فرایند گازی‌سازی با استفاده از تکنیک‌های هوش مصنوعی ارائه می‌گردد.

روش‌شناسی پژوهش

برای روشن شدن رابطه بین ویژگی‌های زیست‌توده (ورودی سیستم) و خروجی انرژی سیستم گازی‌سازی، از روش‌های مختلف داده محور هوش مصنوعی آماری استفاده شده است. این روش‌ها بر اساس نتایج بدست آمده از دقت برآورد و شبیه‌سازی تحقیقات پیشین انتخاب شده است (Shafizadeh et al., 2023). روش‌های هوش مصنوعی آماری استفاده شده عبارتند از رگرسیون خطی، روش رگرسیون تقویت کننده گرادیان، رگرسیون درخت تصمیم‌گیری، روش رگرسیون جنگل رندوم، رگرسیون بردار ساپورت و رگرسیون کرنل ریج. پس از معرفی کوتاه هر کدام از روش‌های هوش مصنوعی آماری بکار رفته فرایند جمع‌آوری داده و ایجاد پایگاه داده توضیح داده خواهد شد.

روش‌های هوش مصنوعی آماری

در این بخش به طور اختصار روش‌های هوش مصنوعی آماری مورد استفاده بیان خواهد شد.

باتوجه به سادگی روش رگرسیون خطی در مقالات و تحقیق‌ها این روش به‌عنوان خط مبنا در نظر گرفته می‌شود. به‌عنوان مثال چو و همکارانش اثر بعضی از پارامترهای مستقل را روی فرایند گازی‌سازی پلازما در پسماندهای شهری جامد و تاثیر آن بر ترکیب گاز سنتز تولید شده مدل‌سازی کردند (Chu et al., 2022).

روش رگرسیون تقویت‌کننده گرادیان را می‌توان برای طبقه‌بندی و پیش‌بینی استفاده کرد و از نوع الگوریتم‌های تقویت‌کننده می‌باشد این الگوریتم بصورت مستمر وزن هوش مورد استفاده را آموزش داده و تنظیم می‌کند و باعث ایجاد مدل بسیار قویتری می‌شود. ون و همکارانش از روش GBR برای پیش‌بینی ترکیب گاز سنتز ناشی از سبوس غلات (برنج) استفاده کردند (Ascher, Wang, et al., 2022). در روش درخت تصمیم‌گیری با رشد درخت تصمیم‌گیری فضای ویژگی به چند ناحیه تقسیم می‌شود. درخت تصمیم‌گیری شامل گره‌های برگ (تقاطع برگ با ساقه) و تقاطع تصمیم‌گیری است. تقاطع تصمیم‌گیری باعث ایجاد دو یا چند شاخه می‌شود بعبارت دیگر تقاطع برگ نشان دهنده نشان دهنده یک طبقه یا تصمیم است (Ozbas et al., 2019a). آشر و همکارانش از الگوریتم بر مبنای درخت تصمیم‌گیری برای مدل‌سازی گازی‌سازی و پیرولیز در تحقیق خود استفاده کردند (Ascher, Watson, et al., 2022).

مدل رگرسیون جنگل تصادفی چندین درخت تصمیم را برای ایجاد یک مدل ترکیب می‌کند. هر درخت در جنگل از زیر مجموعه متفاوتی از داده‌ها می‌سازد و پیش‌بینی مستقل خود را انجام می‌دهد. پیش‌بینی نهایی برای ورودی مبتنی بر میانگین یا میانگین وزنی پیش‌بینی‌های تک تک درختان است. موتلو و یوسل از روش رگرسیون جنگل تصادفی برای پیش‌بینی ترکیبات گاز سنتز به جهت گازدار کردن زیست‌توده ای پایین‌سوا (گازی‌سازی) که بیشتر برای تولید برق استفاده می‌شود و در آن راکتوری وجود دارد که خوراک یا سوخت از طریق هوا به آن داده می‌شود) استفاده نمودند (Mutlu & Yucel, 2018).

در رگرسیون کرنل رنج روش کرنل تریک با رگرسیون لبه ترکیب می‌شود. رگرسیون لبه روش خطای حداقل مربع با رگولاریزاسیون است که با حداقل‌سازی خطای رگرسیون لبه، مانع بیش آموزش یا انحراف کناره‌های شیب رگرسیون می‌شود (Onsree & Tippayawong, 2021). پاندی و همکارانش از روش رگرسیون کرنل رنج برای پیش‌بینی گازی‌سازی با بسترسیال حبابدار با توضیح روش‌های یادگیری ماشین استفاده کردند.

روش رگرسیون بردار ساپورت در هنگام دسته‌بندی الگوریتم آموزش داده‌ها به نحوی به دو دسته تقسیم می‌شود که فاصله بین نزدیک‌ترین داده‌ها از دسته‌ها و خط بالایی پیشنهادی به حداکثر شود. این الگوریتم می‌خواهد فاصله بین دو دسته را کم کند تا بهترین خط رگرسیون را ارائه کند (Umenweke et al., 2022; Pandey et al., 2023). آیودل و همکاران در سال ۲۰۲۲ فرایند گازدار کردن کاتالیزوری شده پسماند روغن پالم را با کمک رگرسیون بردار ساپورت مدل‌سازی کردند (Ayodele et al., 2022).

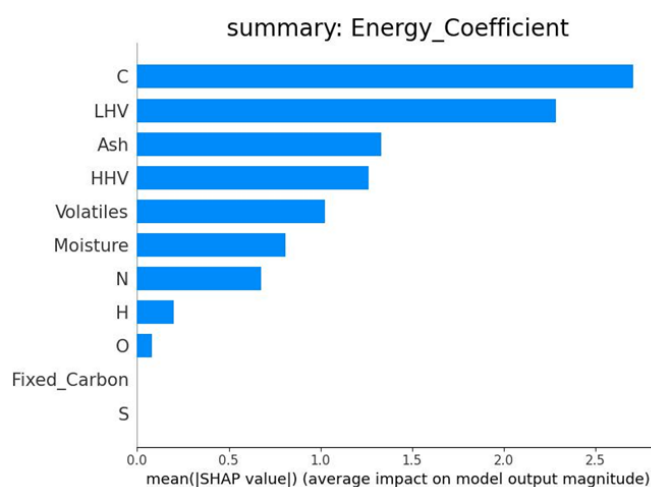
ایجاد بانک داده‌ها

پس از انتخاب روش‌های مناسب داده‌محور هوش مصنوعی آماری، جمع‌آوری داده‌ها و ایجاد یک دیتابیس از اهمیت زیادی برخوردار است. برای این کار تحقیقات جامعی انجام شد. تحقیقات مربوطه بررسی و از طریق وبسایت‌هایی مثل "Google Scholar" و "Web of Science" و استفاده از لغات کلیدی مثل "گازدار کردن"، "زیست‌توده"، "پسماندهای جامد شهری"، "آنالیز تکنو اکونومیک"، "امکان‌سنجی"، "تحقیق موردی"، "بررسی چرخه زندگی" و "انرژی، اکسرژی، و محیط‌زیست، آنالیز 3E" یافت شد. در ابتدا تعداد ۲۳۰ تحقیق جمع‌آوری شد و در اکسل مرتب‌سازی شد. در این مرحله پاک‌سازی و فرمت کردن داده‌ها ضروری بود. لازم بود داده‌های ورودی و خروجی که متعلق به ردیف‌های مشابه هستند دارای یک واحد یکسان باشند. بنابراین تغییر واحد مناسب مورد استفاده قرار گرفت. پس از بازرسی داده‌های پاک شده، پارامترهای تاثیرگذار ورودی بدین نحو انتخاب شد: درصد کربن، هیدروژن، نیتروژن، گوگرد، و اکسیژن همراه با درصد کربن ثابت، مواد فرار، رطوبت و خاکستر و بعد پارامترهای ارزش حرارتی بالاتر و ارزش حرارتی پایین‌تر آن خوراک زیست‌توده. در مجموع تعداد ۱۱ ویژگی بعنوان ورودی مدل بر اساس مجموعه داده‌ها انتخاب شد بطوریکه پیش‌بینی دقیقی از پارامترهای خروجی انتخاب شده که همان مقدار ارزش حرارتی پایین‌تر گاز سنتز است بدست آید.

پس از آن آنالیز دقیق‌تر و بیشتر روی تحقیقات جمع‌آوری شده انجام شد تا مقالات مربوطه صحیح و کاملاً مرتبط انتخاب گردد و تعداد کمتر شود. در این مرحله تعداد تحقیقات معتبر که شامل داده‌های ورودی و خروجی مورد نیاز می‌شدند، فیلتر شدند. پس از این مرحله تعداد مجموع ۱۰۵ تحقیق انتخاب شد که در نهایت ۳۱۶ ردیف داده ایجاد شد. یک فیلتر کردن دیگر نیز روی مجموعه داده‌های جمع

آوری شده انجام شد و ردیف‌های داده‌ای با مقدار قابل توجه از داده‌های گم شده در بخش ورودی داده خارج شد. این کار منجر به تعداد کل ۲۱۸ ردیف داده شد. از آنجاییکه بعضی از بخش ورودی داده‌های جمع‌آوری شده داده‌های گم شده بود الگوریتم مجاورهای نزدیک ترین K برای جایگزینی داده‌های گم شده مورد استفاده قرار گرفت. این روش مجاورها را با محاسبه فاصله بین مقدار گم شده و نسبت دادن مقادیر گم شده با استفاده از مقادیر مجاورهای شناسایی شده، مشخص می‌کند. پس از جایگزینی مقادیر گم شده آنالیز همبستگی پیرسون روی مجموعه داده‌ها انجام شد. نتایج این آزمون در شکل ۱ خلاصه شده است. این تصویر نمودار میله‌ای از ارزش‌های SHAP^۲ را نشان می‌دهد که اهمیت ویژگی‌های مختلف در پیش‌بینی "ضریب انرژی" را نمایش می‌دهد. محور X نمودار نشان‌دهنده میانگین مقدار مطلق SHAP برای هر ویژگی است که تأثیر میانگین ویژگی‌ها بر خروجی مدل را نشان می‌دهد. محور Y ویژگی‌هایی را که تحلیل شده‌اند فهرست می‌کند. بر اساس اطلاعات ارائه شده، ویژگی‌های اولیه زیست‌توده مانند آنالیز تقریبی (درصد رطوبت، کربن ثابت، مواد فرار، و خاکستر)، آنالیز نهایی (درصد کربن، هیدروژن، اکسیژن، نیتروژن، و گوگرد)، مقدار ارزش حرارتی بالاتر و ارزش حرارتی پایین‌تر از اهمیت زیادی در تعیین میزان انرژی حاصله از فرایند گازی‌سازی و عملکرد و بازدهی نهایی آن برخوردارند. این نمودار نشان می‌دهد که محتوای کربن، ارزش حرارتی بالاتر و خاکستر از مهم‌ترین ویژگی‌ها در پیش‌بینی "ضریب انرژی" هستند. ویژگی‌های دیگر مانند ارزش حرارتی بالاتر، مواد فرار و رطوبت نیز اهمیت متوسطی دارند، در حالی که نیتروژن، هیدروژن، اکسیژن، کربن ثابت و گوگرد به عنوان ویژگی‌های کم‌اهمیت‌تر بر اساس مقادیر متوسط کم SHAP ذکر شده‌اند. پیش‌بینی اینکه ویژگی‌های زیست‌توده ورودی چگونه بر انرژی خروجی فرایند گازی‌سازی تأثیر می‌گذارد (یعنی بر میزان گاز سنتز) می‌تواند به کنترل بهتر و راحت‌تر فرایند کمک کند و همچنین به شناخت منابع جدیدتر زیست‌توده و ارزیابی منابع بالقوه زیست‌توده‌ای نیز کمک خواهد کرد.

در انتها پس از جمع‌آوری مجموعه داده‌ها، جایگزینی مقادیر گم شده و انجام آنالیز همبستگی پیرسون، پایگاه داده برای آنالیز با روش‌های هوش مصنوعی در بخش ۲ و ۱ آماده شد.



شکل ۱. آنالیز همبستگی پیرسون (PCA)

مقایسه روش‌های یادگیری ماشین مورد استفاده

برای آنالیز و تجزیه و تحلیل مجموع داده‌ها روش‌های مختلف هوش مصنوعی و برای روشن‌شدن رابطه پنهان ورودی - خروجی، داده‌ها به دو دسته دریافتی و ارزیابی به نسبت X:Y تقسیم شد. این نسبت بر اساس کارهای مشابه در مقالات و تحقیقات از کارهای مشابه قبلی انتخاب شد. برای محاسبه عملکرد مدل و مقایسه عملکرد مدل‌های مختلف با هم چهار پارامتر به نام‌های ضریب تعیین (R^2 / R square)، خطای مربع میانگین ریشه (RMSE)، خطای مربع میانگین ریشه نسبی (RRMSE) و خطای قطعی میانگین (MAE) برای هر مدل و به ترتیب بر اساس معادله ۱ تا ۴ محاسبه شد:

$$R^2 = 1 - \frac{\text{Sum Squared Regression}}{\text{Total Sum of Squares}} = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y}_i)^2} \quad \text{معادله ۱}$$

$$\text{RMSE} = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{n}} \quad \text{معادله ۲}$$


$$\text{RRMSE} = \frac{\text{RMSE}}{\sum \hat{y}_i^2} \quad \text{معادله ۳}$$

$$\text{MAE} = \frac{\sum |y_i - \hat{y}_i|}{n} \quad \text{معادله ۴}$$

پارامتر y_i عبارتست از مقدار واقعی، \hat{y}_i عبارتست از مقدار پیش بینی شده، \bar{y}_i عبارتست از مقدار متوسط و n تعداد ردیف‌های داده‌ای است.

یافته‌های پژوهش

شکل ۲ نشان‌دهنده نتایج بدست آمده از دو روش GBR و DTR است. در نمودار پراکندگی با عنوان "GBR"، رابطه بین داده‌های تجربی (بر روی محور x) و داده‌های پیش‌بینی شده (بر روی محور y) نشان داده شده است. این نمودار نشان می‌دهد که پیش‌بینی‌های مدل با داده‌های تجربی هماهنگ نیستند و دقت پیش‌بینی‌های مدل کم است به عبارتی تفاوت بین داده‌های تجربی نتایج پیش‌بینی زیاد است. نتایج نشان می‌دهد که مدل رگرسیون تقویت‌کننده گرادیان دارای خطاهایی در پیش‌بینی‌های خود است و ممکن است نیاز به تنظیمات بیشتری یا اطلاعات اضافی برای بهبود دقت خود داشته باشد. نتایج مشابهی برای مدل‌سازی براساس روش رگرسیون درخت تصمیم‌گیری بدست آمد که رابطه مشابهی بین داده‌های تجربی و پیش‌بینی شده را نشان می‌دهد. در این نمودار نیز نقاط پراکنده هستند و نشان می‌دهند که مدل رگرسیون درخت تصمیم‌گیری نیز دارای خطاهایی در پیش‌بینی‌های خود است و نیاز به بهبود دارد.



شکل ۲. نتایج پیش‌بینی روش‌های مختلف هوش مصنوعی (ML) مورداستفاده: الف - GBR، ب - DTR

روش رگرسیون خطی نیز، مطابق انتظار، عملکرد صد درصدی در پیش‌بینی خروجی‌ها نداشت. مقادیر ضریب تعیین، خطای مربع میانگین ریشه، خطای مربع میانگین ریشه نسبی و خطای قطعی میانگین در مدل رگرسیون خطی به ترتیب برابر با ۰/۴۹۲، ۳/۰۰۱، ۰/۱۱۸ و ۴/۲۴۰ برای دسته دریافتی^۱ و برابر با ۲/۴۴۵، ۰/۹۰۹، ۲/۱۶۶ و ۰/۲۷۸ برای دسته ارزیابی^۲ بدست آمد. روش رگرسیون تقویت‌کننده گرادیان عملکرد بهتری داشت و اعداد بدست آمده برای ضریب تعیین، خطای مربع میانگین ریشه، خطای مربع میانگین ریشه نسبی و خطای قطعی میانگین برای دسته دریافتی به ترتیب برابر با ۰/۰۹۶، ۰/۰۵۷، ۱/۰۱۱ و ۱/۰۱۱ و برای دسته ارزیابی برابر با ۲/۵۳۸، ۰/۰۴۳ و ۳/۱۴۱ و ۰/۰۸۳ بدست آمد. بهترین عملکرد برای روش رگرسیون تقویت‌کننده گرادیان، با تنظیم پارامترهای فرایند بدین شرح بدست آمد: سرعت گیرندگی برابر با ۰/۰۱، ماکزیمم عمق برابر ۴، تعداد کل محاسبه‌گرها برابر ۵۰۰ و تعداد کل نمونه برابر ۰/۵. روش رگرسیون درخت تصمیم‌گیری عملکرد متوسطی را با مقادیری برابر با ۰/۵۹۲، ۰/۰۱۴، ۱/۱۷۶، ۰/۹۴۰ به ترتیب برای ضریب تعیین، خطای

مربع میانگین ریشه، خطای مربع میانگین ریشه نسبی و خطای قطعی میانگین در دسته دریافتی و ۱/۵۵۲، ۰/۲۲۳، ۲/۱۴۷ و ۰/۷۴۶ برای دسته ارزیابی از خود نشان داد. عملکرد روش رگرسیون جنگل تصادفی تقریباً مشابه رگرسیون درخت تصمیم‌گیری بود. که دلیل این امر می‌تواند این واقعیت باشد که هر دو روش از اصول یکسان استفاده می‌کنند. پارامترهای عملکرد رگرسیون جنگل تصادفی نیز بدین شرح می‌باشند: مقادیر ضریب تعیین، خطای مربع میانگین ریشه، خطای مربع میانگین ریشه نسبی و خطای قطعی میانگین برای دسته دریافتی به ترتیب برابر با ۰/۲۵۲، ۲/۱۰۹، ۰/۸۵۸ و ۱/۲۶۷ و برای دسته ارزیابی برابر با ۱/۶۸۶، ۰/۲۲۲، ۱/۹۶۸ و ۰/۸۱۸ بدست آمد. بهترین عملکرد روش رگرسیون جنگل تصادفی با روش گره بند کفشی رخ داد که ماکزیمم عمق در آن برابر با ۸۰ و ماکزیمم ویژگی‌ها برابر ۴ و مینیمم برگ نمونه برابر ۲ و مینیمم تقسیم نمونه برابر ۲، و تعداد کل ۱۰۰ محاسبه گر بود. روش رگرسیون کرنل ریج نیز به درستی عمل نکرد و مقادیر بدست آمده برای تست‌های ضریب تعیین، خطای مربع میانگین ریشه، خطای مربع میانگین ریشه نسبی و خطای قطعی میانگین به ترتیب برابر با ۲/۱۹۹، ۰/۴۰۷، ۳/۳۳۰ و ۰/۴۲۴ برای دسته دریافتی و ۵/۷۵۷، ۰/۷۳۳، ۷/۵۷۴ و ۰/۲۷۲ برای دسته ارزیابی بدست آمد. روش رگرسیون بردار ساپورت نیز عملکرد قابل قبولی نشان نداد و مقادیر ضریب تعیین، خطای مربع میانگین ریشه، خطای مربع میانگین ریشه نسبی و خطای قطعی میانگین برای دسته دریافتی به ترتیب برابر با ۲/۵۲۴، ۰/۴۷۴، ۳/۸۷۴ و ۰/۲۹۶ و برای دسته ارزیابی برابر با ۵/۲۶۴، ۰/۷۱۵، ۷/۳۹۲ و ۰/۲۷۴ بدست آمد.

جدول ۱. پارامترهای ارزیابی دقت مدل‌های متفاوت

| آموزش | | | | آزمون | | | | |
|-------|-----------|-------|-------|-------|-----------|-------|-------|-------|
| روش | R-squared | RMSE | RRMSE | MAE | R-squared | RMSE | RRMSE | MAE |
| LR | ۰/۲۴ | ۴/۱۱۸ | ۰/۴۹۲ | ۳/۰۰۱ | ۰/۹۰۹ | ۲/۴۴۵ | ۰/۲۷۸ | ۲/۱۶۶ |
| GBR | ۰/۹۶۱ | ۱/۰۱۱ | ۱/۰۱۱ | ۰/۵۷۳ | ۰/۸۲۹ | ۳/۱۴۱ | ۰/۴۳۱ | ۲/۵۳۸ |
| DTR | ۰/۹۴ | ۱/۱۷۶ | ۰/۱۴۲ | ۰/۵۹۲ | ۰/۷۴۶ | ۲/۱۴۷ | ۰/۲۲۳ | ۱/۵۵۲ |
| RFR | ۰/۸۵۸ | ۲/۱۰۹ | ۰/۲۵۲ | ۱/۲۶۷ | ۰/۸۱۸ | ۱/۹۶۸ | ۰/۲۲۲ | ۱/۶۸۶ |
| KRR | ۰/۴۲۴ | ۳/۳۳ | ۰/۴۰۷ | ۲/۱۹۹ | ۰/۲۷۲ | ۷/۵۷۴ | ۰/۷۳۳ | ۵/۷۵۷ |
| SVR | ۰/۲۹۶ | ۳/۸۴۷ | ۰/۴۷۴ | ۲/۵۲۴ | ۰/۲۷۴ | ۷/۳۸۲ | ۰/۷۱۵ | ۵/۲۶۴ |

بحث

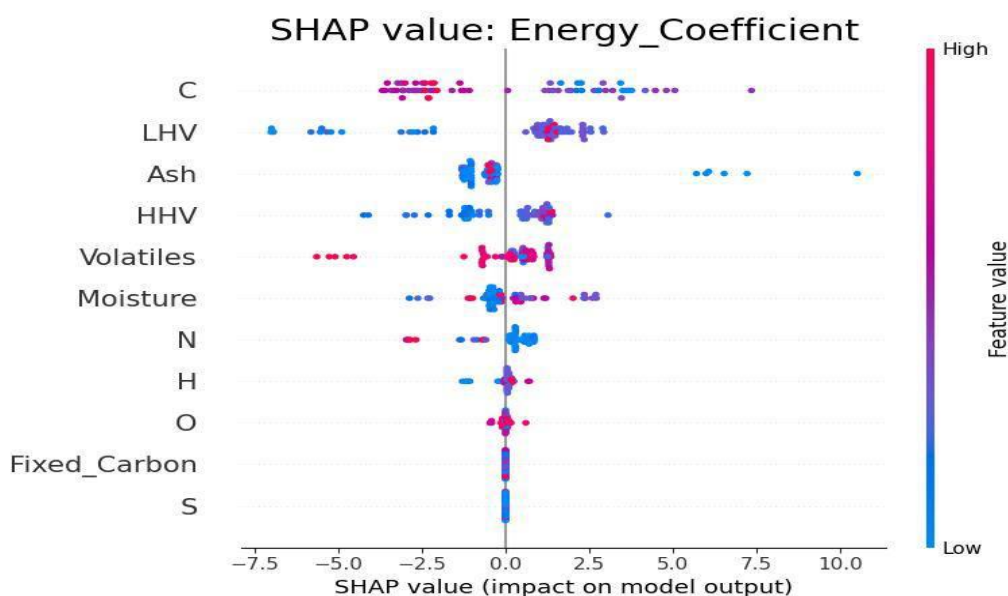
مقایسه عملکرد مدل

عملکرد الگوریتم‌های مختلف هوش مصنوعی مورد استفاده با کمک ۴ پارامتر مقیاسی مورد مقایسه قرار گرفت. ضریب تعیین بعنوان اولین پارامتر مقیاس انتخاب شد. بر اساس این پارامتر، روش رگرسیون تقویت‌کننده گرادیان بهترین عملکرد را در دسته دریافتی داشت و پس از آن بترتیب روش‌های رگرسیون درخت تصمیم‌گیری و رگرسیون جنگل تصادفی قرار داشتند. پس از اینکه یک فاصله معنادار در عملکرد مشاهده شد، رگرسیون کرنل ریج عملکرد متوسطی از خود نشان داد و از طرف دیگر روش رگرسیون بردار ساپورت و رگرسیون خطی ابداً عملکرد خوبی از خود نشان ندادند. سایر پارامترهای مقایسه‌ای رتبه نسبتاً یکسانی در مقایسه با ضریب تعیین داشت و همان رویه را دنبال کرد. در جمع بندی، مدلی انتخاب می‌شود که نتایج بخش آموزش و ارزیابی نزدیک به هم و نسبت به بقیه بهتر باشند لذا اگر چه ضریب تعیین رگرسیون خطی در بخش ارزیابی نتایج خوبی (برابر با ۰/۹۰۹) بدست داد ولیکن با توجه به مقدار نامناسب در بخش آموزش (برابر با ۰/۲۴) قابل اعتماد نبود و انتخاب نمی‌شود. بهترین عملکرد به ترتیب عبارت از رگرسیون تقویت‌کننده گرادیان، رگرسیون جنگل تصادفی و رگرسیون درخت تصمیم‌گیری قرار گرفتند که همگی شان عملکرد مطلوبی از خود نشان دادند. رگرسیون کرنل ریج و رگرسیون بردار ساپورت در پارامتر ضریب تعیین ضعیف عمل کرده و عدد ۰/۲۷ حاصل شد. سایر پارامترهای ارزیابی عملکرد نیز همان رویه رتبه بندی ضریب تعیین را دنبال کردند. در مجموع، روش‌های بر پایه درخت تصمیم‌گیری به نام‌های رگرسیون تقویت‌کننده گرادیان، رگرسیون جنگل تصادفی و

رگرسیون درخت تصمیم‌گیری در هنگام مدلسازی عملکرد بهتری نشان دادند که دلیل این امر را می‌توان در بهره‌گیری این روش‌ها از الگوریتم درخت تصمیم‌گیری جویا شد. همچنین عملکرد سایر روش‌ها به دلیل ماهیت غیرخطی ارتباط ورودی‌ها و خروجی‌ها عملکرد مساعدی از خود به جا گذاشتند. با بررسی مقالات مربوطه نیز می‌توان به این مهم پی‌برد که الگوریتم‌های بر پایه درخت تصمیم‌گیری، قدرت پیش‌بینی بالاتری نسبت به سایرین از خود نشان داده‌اند (Ozbas et al., 2019b).

آزمون حساسیت

برای داشتن درک بهتر از روش‌های هوش مصنوعی، عملکرد، کاهش آنها در جعبه سیاه؛ توضیح پذیر بودن آنها، ارزیابی اهمیت هر ورودی بر خروجی و نیز محاسبه و اندازه‌گیری تاثیرات نسبی آن بر خروجی، آنالیز حساسیت اجرا گردید. آنالیز حساسیت بر اساس روش SHAP انجام شد. SHAP یک مدل قابل فهم برای ارزیابی دخالت ویژگی‌ها در هدف مورد انتظار و پیش‌بینی می‌باشد (Li et al., 2021). ایده اصلی پشت SHAP ارزیابی دخالت حاشیه‌ای ویژگی‌های ورودی و خروجی و تفسیر مدل بلک باکس (جعبه سیاه) می‌باشد (Liu et al., 2022). شکل ۳ تاثیر ویژگی‌های مختلف بر خروجی مدل را نشان می‌دهد. ویژگی‌هایی مانند درصد کربن، ارزش حرارتی پایین، ارزش حرارتی بالا و میزان خاکستر تاثیر مهمی بر پیش‌بینی‌های مدل دارند. مواد فرار و رطوبت تاثیر متوسطی دارند، در حالی که نیتروژن، هیدروژن، اکسیژن، کربن ثابت و گوگرد تاثیر کمتری دارند. به طور کلی، ویژگی‌هایی با بیشترین تاثیر مانند کربن، ارزش حرارتی بالاتر، ارزش حرارتی پایین‌تر و خاکستر ارتباط بیشتری با مقادیر SHAP دارند که نشان‌دهنده اهمیت آنها در پیش‌بینی ضریب انرژی است. برعکس، ویژگی‌هایی مانند نیتروژن، هیدروژن، اکسیژن، کربن ثابت و گوگرد دارای مقادیر کمتری از SHAP هستند که نشان‌دهنده کمتر بودن تاثیر آنها بر خروجی مدل است.

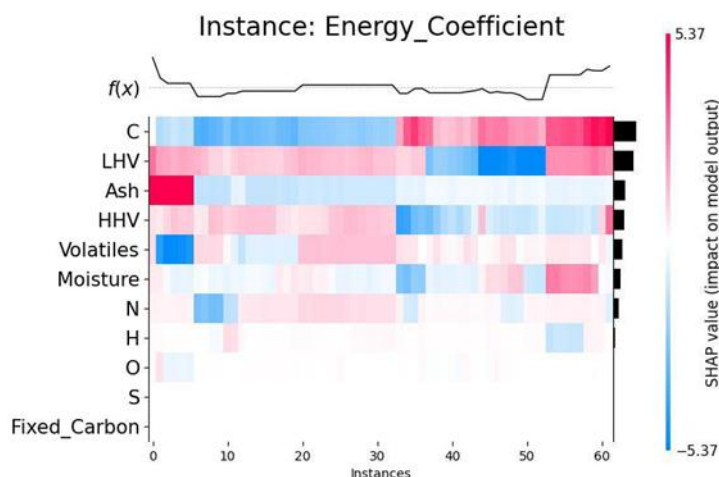


شکل ۳. مقادیر SHAP برای ویژگی‌های ورودی‌های منتخب

مقادیر SHAP حاکی از آن است که درصد کربن بیشترین تاثیر را بر محتوای گرمایی گاز سنتز داشته است. شاید به این دلیل که علاوه بر درصد کربن، به ترتیب مقادیر ارزش حرارتی پایین‌تر، خاکستر و ارزش حرارتی بالاتر از مهم‌ترین ویژگی‌هایی هستند که بر مقدار گرمای گاز سنتز تاثیر می‌گذارند.

شکل ۴ نیز نشان‌دهنده نتایج آنالیز حساسیت است. نمودار SHAP نشان‌دهنده تاثیر ویژگی‌های مختلف بر خروجی مدل است. محور عمودی ویژگی‌های مختلف را نشان می‌دهد، در حالی که محور افقی نمونه‌های مختلف را نشان می‌دهد. رنگ‌ها نشان‌دهنده اثر هر ویژگی بر خروجی مدل هستند، با قرمز نمایانگر تاثیر مثبت و آبی نشان‌دهنده تاثیر منفی. ویژگی‌هایی مانند درصد کربن، ارزش حرارتی پایین‌تر، ارزش حرارتی بالاتر و خاکستر تاثیر قابل توجهی بر خروجی مدل دارند، با بسیاری از نقاط قرمز و آبی که نشان‌دهنده تاثیر مثبت و منفی

آن‌ها است. به‌عنوان مثال، مقادیر بالای کربن و ارزش حرارتی بالاتر معمولاً تأثیر مثبتی بر ضریب انرژی دارند، درحالی‌که مقادیر بالای خاکستر ممکن است تأثیر منفی داشته باشد. مواد فرار و رطوبت تأثیر متوسطی دارند، با نقاط بیشتر در محدوده رنگ‌های روشن‌تر که نشان می‌دهد تأثیر کمتری نسبت به ویژگی‌های اصلی دارند. ویژگی‌های مانند نیتروژن، هیدروژن، اکسیژن، کربن ثابت و گوگرد تأثیر کمتری بر خروجی مدل دارند، بیشتر در محدوده رنگ‌های آبی روشن و قرمز روشن که نشان‌دهنده تأثیر کم آن‌ها است. به‌طور کلی، ویژگی‌های درصد کربن، ارزش حرارتی پایین‌تر، ارزش حرارتی بالاتر و خاکستر بیشتر تأثیر را بر ضریب انرژی دارند، درحالی‌که ویژگی‌های نیتروژن، هیدروژن، اکسیژن، کربن ثابت و گوگرد تأثیر کمتری دارند.



شکل ۴. نتایج آنالیز حساسیت

نتیجه‌گیری و پیشنهادها

در طی بررسی و تحلیل رابطه بین ویژگی‌های زیست‌توده به‌عنوان ورودی سیستم و خروجی انرژی در فرایند گازی‌سازی، از روش‌های مختلف هوش مصنوعی آماری استفاده شد که شامل رگرسیون خطی، رگرسیون تقویت‌کننده گرادیان، رگرسیون درخت تصمیم‌گیری، رگرسیون جنگل رندوم، رگرسیون بردار ساپورت و رگرسیون کرنل ریج بودند. تحلیل داده‌ها نشان داد که روش رگرسیون تقویت‌کننده گرادیان بهترین عملکرد را داشته و ویژگی‌های ورودی مانند درصد کربن، ارزش حرارتی پایین‌تر، میزان خاکستر و ارزش حرارتی بالاتر اهمیت بالایی در پیش‌بینی مقدار گرمای گاز سنتز داشتند. آزمون حساسیت نیز تأیید کرد که درصد کربن و مواد فرار به‌عنوان ویژگی‌های ورودی با تأثیر بیشتری بر مقدار گرمای گاز سنتز همراه بوده و می‌توانند به‌طور معناداری بر روی پیش‌بینی‌ها تأثیر بگذارند. به‌طور کلی، روش‌های پایه درخت تصمیم‌گیری مانند رگرسیون درخت تصمیم‌گیری، رگرسیون جنگل تصادفی و رگرسیون تقویت‌کننده گرادیان از توانمندی بالایی برای کاهش ارتباط ورودی-خروجی و پیش‌بینی دقیق مقادیر گرمای گاز سنتز برخوردارند.

چالش‌ها و کارهای آتی

در مسیر استفاده از روش‌های هوش مصنوعی آماری برای پیش‌بینی و بهینه‌سازی ویژگی‌های گازی‌سازی زیست‌توده، چالش‌هایی مانند دقت و صحت داده‌ها، پیچیدگی مدل‌های هوش مصنوعی، عدم توضیح‌پذیری مدل‌ها، فقدان استانداردهای مشخص، و تطابق با شرایط واقعی وجود دارد. ناهماهنگی داده‌ها و نیاز به تمیزسازی، منابع محاسباتی بالا، و مشکلات در توضیح‌پذیری نتایج، از جمله موانع مهم هستند. همچنین، انتقال مدل‌های آزمایشگاهی به شرایط واقعی صنعتی با چالش‌های زیادی همراه است. این چالش‌ها می‌توانند فرایند تحلیل را پیچیده‌تر کرده و هزینه‌ها را افزایش دهند.

برای مقابله با این چالش‌ها، توسعه پایگاه‌های داده جامع و استاندارد، بهبود مدل‌های توضیح‌پذیر، ارزیابی جامع مدل‌ها، افزایش کارایی محاسباتی، و استفاده از مدل‌سازی ترکیبی می‌تواند به بهبود دقت و صحت مدل‌ها کمک کند. تحقیق و توسعه برای انتقال مدل‌ها به شرایط واقعی صنعتی و بررسی عملکرد آن‌ها در محیط‌های عملیاتی نیز از اهمیت بالایی برخوردار است. با پیشرفت‌های سریع در حوزه هوش مصنوعی، انتظار می‌رود که استفاده از این تکنیک‌ها در بهبود فرایندهای گازی‌سازی زیست‌توده افزایش یافته و به بهبود بهره‌وری



REFERENCES

- Akbarian, A., Andooz, A., Kowsari, E., Ramakrishna, S., Asgari, S., & Cheshmeh, Z. A. (2022a). Challenges and opportunities of lignocellulosic biomass gasification in the path of circular bioeconomy. *Bioresource Technology*, 362(August), 127774. <https://doi.org/10.1016/j.biortech.2022.127774>
- Akbarian, A., Andooz, A., Kowsari, E., Ramakrishna, S., Asgari, S., & Cheshmeh, Z. A. (2022b). Challenges and opportunities of lignocellulosic biomass gasification in the path of circular bioeconomy. *Bioresource Technology*, 362, 127774. <https://doi.org/https://doi.org/10.1016/j.biortech.2022.127774>
- Alfarra, F., Ozcan, H. K., Cihan, P., Ongen, A., Guvenc, S. Y., & Ciner, M. N. (2024). Artificial intelligence methods for modeling gasification of waste biomass: a review. *Environmental Monitoring and Assessment*, 196(3), 309. <https://doi.org/10.1007/s10661-024-12443-2>
- Ascher, S., Wang, X., Watson, I., Sloan, W., & You, S. (2022). Interpretable machine learning to model biomass and waste gasification. *Bioresource Technology*, 364, 128062. <https://doi.org/https://doi.org/10.1016/j.biortech.2022.128062>
- Ascher, S., Watson, I., & You, S. (2022). Machine learning methods for modelling the gasification and pyrolysis of biomass and waste. *Renewable and Sustainable Energy Reviews*, 155, 111902. <https://doi.org/https://doi.org/10.1016/j.rser.2021.111902>
- Ayodele, B. V., Mustapa, S. I., Kanthasamy, R., Mohammad, N., AlTurki, A., & Babu, T. S. (2022). Performance analysis of support vector machine, Gaussian Process Regression, sequential quadratic programming algorithms in modeling hydrogen-rich syngas production from catalyzed co-gasification of biomass wastes from oil palm. *International Journal of Hydrogen Energy*, 47(98), 41432–41443. <https://doi.org/https://doi.org/10.1016/j.ijhydene.2022.05.066>
- Aziz, M. M. A., Kassim, K. A., Shokravi, Z., Jakarni, F. M., Liu, H. Y., Zaini, N., Tan, L. S., Islam, A. B. M. S., & Shokravi, H. (2020). Two-stage cultivation strategy for simultaneous increases in growth rate and lipid content of microalgae: A review. *Renewable and Sustainable Energy Reviews*, 119, 109621. <https://doi.org/https://doi.org/10.1016/j.rser.2019.109621>
- Bongomin, O., Nzila, C., Mwasiagi, J. I., & Maube, O. (2024). Exploring Insights in Biomass and Waste Gasification via Ensemble Machine Learning Models and Interpretability Techniques. *International Journal of Energy Research*, 2024(1), 6087208. <https://doi.org/https://doi.org/10.1155/2024/6087208>
- Chu, C., Boré, A., Liu, X. W., Cui, J. C., Wang, P., Liu, X., Chen, G. Y., Liu, B., Ma, W. C., Lou, Z. Y., Tao, Y., & Bary, A. (2022). Modeling the impact of some independent parameters on the syngas characteristics during plasma gasification of municipal solid waste using artificial neural network and stepwise linear regression methods. *Renewable and Sustainable Energy Reviews*, 157, 112052. <https://doi.org/https://doi.org/10.1016/j.rser.2021.112052>
- Elmaz, F., Yücel, Ö., & Mutlu, A. Y. (2020). Predictive modeling of biomass gasification with machine learning-based regression methods. *Energy*, 191, 116541. <https://doi.org/https://doi.org/10.1016/j.energy.2019.116541>
- Fiazi, C., Zarei, C., Samimi Akhijahani, H., & Maleki, M. (2024). Improving biogas production from fruit waste: using chemical, mechanical and thermal pretreatments and co-digestion with cow manure. *Agricultural mechanization*, 9(1).
- Kardani, N., Zhou, A., Nazem, M., & Lin, X. (2021). Modelling of municipal solid waste gasification using an optimised ensemble soft computing model. *Fuel*, 289, 119903. <https://doi.org/https://doi.org/10.1016/j.fuel.2020.119903>
- Li, J., Pan, L., Suvarna, M., & Wang, X. (2021). Machine learning aided supercritical water gasification for H₂-rich syngas production with process optimization and catalyst screening. *Chemical Engineering Journal*, 426, 131285. <https://doi.org/https://doi.org/10.1016/j.cej.2021.131285>
- Liu, S., Yang, Y., Yu, L., Zhu, F., Cao, Y., Liu, X., Yao, A., & Cao, Y. (2022). Predicting gas production by supercritical water gasification of coal using machine learning. *Fuel*, 329, 125478. <https://doi.org/https://doi.org/10.1016/j.fuel.2022.125478>
- Long, X., Spiegl, N., Berruoco, C., Paterson, N., & Millan, M. (2020). Fluidised bed oxy-fuel gasification of coal: Interactions between volatiles and char at varying pressures and fuel feed rates. *Chemical Engineering Science: X*, 8, 100068. <https://doi.org/https://doi.org/10.1016/j.cesx.2020.100068>
- Midilli, A., Kucuk, H., Topal, M. E., Akbulut, U., & Dincer, I. (2021). A comprehensive review on hydrogen production from coal gasification: Challenges and Opportunities. *International Journal of Hydrogen Energy*, 46(50), 25385–25412. <https://doi.org/https://doi.org/10.1016/j.ijhydene.2021.05.088>

- Mutlu, A. Y., & Yucel, O. (2018). An artificial intelligence based approach to predicting syngas composition for downdraft biomass gasification. *Energy*, *165*, 895–901. <https://doi.org/https://doi.org/10.1016/j.energy.2018.09.131>
- Onsree, T., & Tippayawong, N. (2021). Machine learning application to predict yields of solid products from biomass torrefaction. *Renewable Energy*, *167*, 425–432. <https://doi.org/https://doi.org/10.1016/j.renene.2020.11.099>
- Ozbas, E. E., Aksu, D., Ongen, A., Aydin, M. A., & Ozcan, H. K. (2019a). Hydrogen production via biomass gasification, and modeling by supervised machine learning algorithms. *International Journal of Hydrogen Energy*, *44*(32), 17260–17268. <https://doi.org/https://doi.org/10.1016/j.ijhydene.2019.02.108>
- Ozbas, E. E., Aksu, D., Ongen, A., Aydin, M. A., & Ozcan, H. K. (2019b). Hydrogen production via biomass gasification, and modeling by supervised machine learning algorithms. *International Journal of Hydrogen Energy*, *44*(32), 17260–17268. <https://doi.org/10.1016/j.ijhydene.2019.02.108>
- Pandey, D. S., Raza, H., & Bhattacharyya, S. (2023). Development of explainable AI-based predictive models for bubbling fluidised bed gasification process. *Fuel*, *351*, 128971. <https://doi.org/10.1016/j.fuel.2023.128971>
- Rodionova, M. V., Bozieva, A. M., Zharmukhamedov, S. K., Leong, Y. K., Chi-Wei Lan, J., Veziroglu, A., Veziroglu, T. N., Tomo, T., Chang, J.-S., & Allakhverdiev, S. I. (2022). A comprehensive review on lignocellulosic biomass biorefinery for sustainable biofuel production. *International Journal of Hydrogen Energy*, *47*(3), 1481–1498. <https://doi.org/https://doi.org/10.1016/j.ijhydene.2021.10.122>
- Sánchez, J., Curt, M. D., Robert, N., & Fernández, J. (2019). *Chapter Two - Biomass Resources* (C. Lago, N. Caldés, & Y. B. T.-T. R. of B. in the B. Lechón (eds.); pp. 25–111). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-12-813056-8.00002-9>
- Shafizadeh, A., Shahbeik, H., Rafiee, S., Moradi, A., Shahbaz, M., Madadi, M., Li, C., Peng, W., Tabatabaei, M., & Aghbashlo, M. (2023). Machine learning-based characterization of hydrochar from biomass: Implications for sustainable energy and material production. *Fuel*, *347*, 128467. <https://doi.org/https://doi.org/10.1016/j.fuel.2023.128467>
- Umenweke, G. C., Afolabi, I. C., Epelle, E. I., & Okolie, J. A. (2022). Machine learning methods for modeling conventional and hydrothermal gasification of waste biomass: A review. *Bioresour. Technol. Reports*, *17*, 100976. <https://doi.org/https://doi.org/10.1016/j.biteb.2022.100976>
- Víllora, G., Pulgar, G., Moreno, D. A., & Romero, L. (1998). Eggplant yield response to increasing rates of N-P-K fertilization. *Phyton-International Journal of Experimental Botany*, *63*, 87–91.
- Wen, H. T., Lu, J. H., & Phuc, M. X. (2021). Applying artificial intelligence to predict the composition of syngas using rice husks: A comparison of artificial neural networks and gradient boosting regression. *Energies*, *14*(10), 1–18. <https://doi.org/10.3390/en14102932>
- Yang, Y., Shahbeik, H., Shafizadeh, A., Rafiee, S., Hafezi, A., Du, X., Pan, J., Tabatabaei, M., & Aghbashlo, M. (2023). Predicting municipal solid waste gasification using machine learning: A step toward sustainable regional planning. *Energy*, *278*, 127881. <https://doi.org/https://doi.org/10.1016/j.energy.2023.127881>
- Yu, J., Guo, Q., Gong, Y., Ding, L., Wang, J., & Yu, G. (2021). A review of the effects of alkali and alkaline earth metal species on biomass gasification. *Fuel Processing Technology*, *214*(December 2020), 106723. <https://doi.org/10.1016/j.fuproc.2021.106723>
- Zhou, S., Dai, F., Chen, Y., Dang, C., Zhang, C., Liu, D., & Qi, H. (2019). Sustainable hydrothermal self-assembly of hafnium–lignosulfonate nanohybrids for highly efficient reductive upgrading of 5-hydroxymethylfurfural. *Green Chem.*, *21*(6), 1421–1431. <https://doi.org/10.1039/C8GC03710H>