

پیش‌بینی مصرف انرژی در گلخانه‌ها با استفاده از یادگیری ماشین: مورد مطالعاتی استان تهران

خشایار زارع^۱، احمد حسین‌نژاد^{۲*}

۱- کارشناسی ارشد، گروه مهندسی ماشین‌های کشاورزی، دانشکده کشاورزی، دانشکده‌گان کشاورزی و منابع طبیعی،

دانشگاه تهران، کرج، ایران. رایانامه: zare.khashayar@ut.ac.ir

۲- استادیار، گروه مهندسی محیط زیست، دانشگاه تهران، تهران، ایران. رایانامه: ah.hosseinnejad@ut.ac.ir

خلاصه

افزایش مصرف انرژی در بخش گلخانه‌ای، به‌ویژه در مناطق پرتمرکز کشاورزی، لزوم استفاده از روش‌های هوشمند برای تحلیل و پیش‌بینی مصرف انرژی را بیش از پیش نمایان کرده است. در این پژوهش، با استفاده از داده‌های آمارنامه‌های رسمی وزارت جهاد کشاورزی طی سال‌های ۱۳۹۳ تا ۱۴۰۲، مدلی مبتنی بر یادگیری ماشین برای پیش‌بینی مصرف انرژی گلخانه‌های استان تهران توسعه داده شد. مجموعه داده شامل اطلاعاتی نظیر سال، نوع محصول، سطح زیر کشت و فاصله شهرستان‌ها از سطح دریا بود. مصرف انرژی حرارتی و الکتریکی بر اساس استاندارد ملی ایران شماره ۱۴۳۰۰ محاسبه و به یک شاخص واحد انرژی تبدیل شد. برای مدل‌سازی، از دو الگوریتم جنگل تصادفی و درخت تصمیم‌گیری استفاده شد و بهینه‌سازی فرآپارامترها با روش جستجوی شبکه‌ای انجام گرفت. نتایج نشان داد که هر دو مدل از دقت بسیار بالایی برخوردارند، اما مدل درخت تصمیم‌گیری با مقدار پارامتر دقت ۰/۹۹۸۶ عملکرد بهتری در پیش‌بینی مصرف انرژی ارائه داد. تحلیل تطابق مقادیر واقعی و پیش‌بینی‌شده بیانگر پایداری و توان بالای مدل نهایی است. به‌منظور تفسیرپذیری مدل، از روش SHAP برای تحلیل اهمیت ویژگی‌ها استفاده شد. نتایج نشان داد که سطح زیر کشت گلخانه‌ها مهم‌ترین عامل تأثیرگذار بر مصرف انرژی است، در حالی که سایر متغیرها نقش کمتری دارند. یافته‌های این پژوهش نشان می‌دهد که استفاده از مدل‌های یادگیری ماشین می‌تواند ابزار مؤثری برای مدیریت و بهینه‌سازی مصرف انرژی در گلخانه‌ها و حمایت از تصمیم‌گیری‌های کلان در بخش کشاورزی باشد.

کلمات کلیدی: میزان مصرف انرژی، گلخانه، مصرف انرژی گلخانه‌ها، یادگیری ماشین، هوش مصنوعی، پایداری انرژی

۱. مقدمه

در دهه‌های اخیر، افزایش جمعیت و تغییرات اقلیمی، جهان را با چالش جدی تأمین امنیت غذایی مواجه ساخته است. در این راستا، کشاورزی کنترل‌شده و به‌ویژه گلخانه‌ها به‌عنوان راهکاری اساسی برای تولید پایدار محصولات کشاورزی در شرایط مدیریت‌شده، مورد توجه ویژه قرار گرفته‌اند [1]. امروزه فعالیت‌های کشاورزی ناگزیر به سازگاری با محیط رقابتی‌تر شده و در نتیجه، به استفاده از فناوری‌های هوشمند جدید روی آورده‌اند. در این میان، تولید هیدروپونیک و گلخانه‌ای راهی برای دستیابی به محصولات سودآور شناخته می‌شود. یک سیستم تولید محصول پایدار، نیازمند حفظ کیفیت بالای برداشت، همراه با مصرف پایین انرژی و مواد اولیه است [2].


گلخانه‌های مدرن با فراهم کردن شرایط کنترل‌شده برای رشد گیاهان، از جمله دما، رطوبت، نور و سطح دی‌اکسیدکربن بهینه، نقش بسیار مفیدی در افزایش بهره‌وری و امکان کشت در تمام طول سال ایفا می‌کنند. این سازه‌ها علاوه بر محافظت

محصولات در برابر رویدادهای نامساعد جوی، به بهبود کیفیت و افزایش کمیت تولید منجر می‌شوند. کنترل دقیق اقلیم درون گلخانه نقشی تعیین‌کننده در بهینه‌سازی رشد، افزایش عملکرد و حفظ استانداردهای کیفی دارد. در این میان، حفظ دمای بهینه از اهمیت ویژه‌ای برخوردار است، چرا که محصولات مختلف در مراحل گوناگون رشد نیازهای حرارتی متفاوتی دارند. کنترل رطوبت نیز برای پیشگیری از بیماری‌ها و حفظ تعادل تعرق و جذب مواد مغذی حیاتی است [3]. سیستم‌های کنترل خودکار با بهره‌گیری از الگوریتم‌های پیشرفته‌ای مانند شبکه‌های عصبی، منطق فازی و کنترل پیش‌بین، امکان تنظیم دقیق و قابل سفارشی‌سازی پارامترهای محیطی را فراهم می‌آورند. با این حال، بسیاری از سیستم‌های کنترلی موجود هنوز بر استراتژی‌های واکنشی متکی هستند که منجر به تلفات انرژی چشمگیر و شرایط ناکافی برای رشد گیاه می‌شود [4]. استان تهران، با تمرکز بالای جمعیتی و محدودیت منابع آبی و زمین‌های زراعی، از جمله مناطق پیشرو در توسعه گلخانه‌ها در ایران محسوب می‌شود [5]. با این حال، یکی از موانع مهم در توسعه پایدار این سیستم‌ها، مصرف بالای انرژی به‌ویژه در بخش‌های گرمایش، سرمایش، تهویه و روشنایی است که درصدی از کل هزینه‌های تولید را به خود اختصاص می‌دهد. انرژی به‌عنوان اصلی‌ترین نهاده هزینه‌بر در گلخانه‌ها، تأثیر مستقیمی بر اقتصادی بودن تولید و نیز انتشار آلاینده‌های زیست‌محیطی دارد [6]. وابستگی به سوخت‌های فسیلی، نه تنها هزینه‌های عملیاتی را افزایش می‌دهد، بلکه با انتشار گازهای گلخانه‌ای، در تغییر اقلیم نیز نقش دارد [7]. در شرایط کنونی، با توجه به نوسانات قیمت حامل‌های انرژی و سیاست‌های اصلاح الگوی مصرف، پیش‌بینی دقیق مصرف انرژی در گلخانه‌ها به یک ضرورت راهبردی تبدیل شده است. رویکردهای نوین، ادغام اینترنت اشیا و یادگیری ماشین را برای نظارت بر داده‌های لحظه‌ای و تصمیم‌گیری پیش‌گیرانه پیشنهاد می‌کنند. این فناوری‌ها با تحلیل داده‌های تاریخی و بلادرنگ، به بهینه‌سازی مصرف آب، مواد مغذی و انرژی کمک شایانی می‌کنند [8].

در این راستا، پژوهش حاضر به بررسی و پیش‌بینی مصرف انرژی در گلخانه‌های استان تهران با در نظرگیری متغیرهای کلیدی مؤثر می‌پردازد. در این مقاله، اقلیم متنوع استان تهران، فاصله شهرستان‌های مختلف از سطح دریا، انواع محصولات کشت‌شده و همچنین سطح زیر کشت این گلخانه‌ها در بازه زمانی ۱۳۹۳ تا ۱۴۰۲ به‌طور جامع مورد بررسی قرار گرفته است. پس از محاسبه دقیق انرژی مورد نیاز برای تمامی این گلخانه‌ها بر اساس پارامترهای فوق، داده‌های جمع‌آوری شده مبنای آموزش مدل‌های پیش‌بینی قرار گرفته‌اند (آمارنامه کشاورزی، وزارت جهاد کشاورزی، ایران). در حال حاضر، سیستم‌های پیش‌بینی مصرف انرژی به‌طور فزاینده‌ای به سمت استفاده از مدل‌های داده‌محور گرایش یافته‌اند [9]. در این مطالعه، با بهره‌گیری از قابلیت‌های یادگیری ماشین و به‌طور خاص مدل‌های درخت تصمیم و جنگل تصادفی، و با در نظرگیری متغیرهای مؤثر کلیدی از جمله پارامترهای اقلیمی و عملیاتی، سعی می‌شود ابزاری کارآمد و دقیق برای پیش‌بینی نیاز انرژی ارائه گردد. این مدل‌ها به دلیل توانایی بالا در پردازش داده‌های پیچیده و غیرخطی و همچنین مقاومت در برابر بیش‌برازش، گزینه‌های مناسبی برای این پیش‌بینی هستند. دستاورد این تحقیق می‌تواند مبنای تصمیم‌گیری برای بهینه‌سازی مدیریت انرژی، کاهش هزینه‌ها، برنامه‌ریزی برای استفاده از انرژی‌های تجدیدپذیر و در نهایت توسعه پایدار کشاورزی گلخانه‌ای در استان تهران قرار گیرد.

۲. مواد و روش‌ها

در ابتدا با استفاده از داده‌های آمارنامه‌های رسمی و سالانه وزارت جهاد کشاورزی که بصورت سالیانه توسط این ارگان به انتشار می‌رسد داده‌ها از سال ۱۳۹۳ تا ۱۴۰۲ جمع‌آوری شدند که جمعا ۵۹۹ داده بودند، این داده‌ها شامل مواردی از جمله سطح زیر کشت گلخانه‌ها و محصولات آن‌ها و میزان عملکرد آن‌ها است، با استفاده از این داده‌ها یک مجموعه داده ساخته شد. روند سطح زیر کشت گلخانه‌ها در استان تهران طبق آمارنامه‌ها بصورت شکل زیر نمایش داده شده‌اند (شکل ۱).



شکل ۱- روند سطح زیر کشت گلخانه‌ها در استان تهران

با استفاده از اطلاعات ثبت شده در استاندارد ملی ایران شماره ۱۴۳۰۰ (معیار مصرف انرژی در فرآیند تولید گلخانه‌ها) اقلیم بندی شهرستان‌های استان تهران انجام پذیرفت و با استفاده از نقشه جغرافیایی فاصله شهرستان‌ها با سطح دریا اندازی‌گیری شد. طبق این استانداردها استان تهران و شهرستان‌های آن در اقلیم معتدل کشور قرار دارند و با استفاده از میانگین ضرایب مصرف ویژه انرژی حرارتی (MJ/m^2) و الکتریکی (kWh/m^2)، مصارف انرژی حرارتی و الکتریکی برای محصولات مختلف محاسبه شدند. بدلیل عدم پوشش تمامی محصولات در فایل استاندارد فرض برای محصولاتی که در فایل استاندارد وجود نداشتن بنا بر این گرفته شد که برخی از محصولات که خصوصیت یکسانی به لحاظ مصرف انرژی دارند مصارف آن‌ها نیز مانند اقلامی که در در استاندارد وجود دارند، است. در جدول زیر ضرایب ویژه انرژی حرارتی و الکتریکی اشاره شده است (جدول ۱).

جدول ۱- مصرف ویژه انرژی حرارتی و الکتریکی در نظر گرفته شده برای محصولات مختلف

نام محصول	انرژی حرارتی	انرژی الکتریکی
آلوئه ورا	۷۵۰/۶۷	۳/۰۳
خیار	۵۷۵/۰۰	۲/۷۰
گوجه فرنگی	۸۱۸/۰۰	۳/۴۰
کاهو	۷۵۰/۶۷	۳/۰۳
گیاهان دارویی	۷۵۰/۶۷	۳/۰۳
سبزیجات برگی	۷۵۰/۶۷	۳/۰۳
بادمجان	۷۵۰/۶۷	۳/۰۳
قارچ دکمه ای	۷۵۰/۶۷	۳/۰۳
سایر قارچ های پرورشی خاص	۴۰۰/۰۰	۸/۰۰
توت فرنگی	۷۵۰/۶۷	۳/۰۳
فلفل دلمه	۸۵۹/۰۰	۳/۰۰
ریحان	۷۵۰/۶۷	۳/۰۳

طبق معادله ۱ انرژی ویژه حرارتی متناسب با سطح زیر کشت گلخانه‌ها، میزان کل مصرف انرژی حرارتی گلخانه را نشان داد (Mj/year):

$$(1) \quad 10000 \times \text{سطح زیر کشت} \times \text{انرژی ویژه حرارتی} = \text{انرژی حرارتی}$$

طبق معادله ۲ کل انرژی الکتریکی یکساله برای گلخانه‌ها محاسبه شد (kWh/year):

$$(2) \quad 10000 \times \text{سطح زیر کشت} \times \text{انرژی ویژه الکتریکی} = \text{انرژی الکتریکی}$$

برای تبدیل واحد کیلووات ساعت بر سال (kWh/year) مقدار معادله ۲ با یک ضریب ۳/۶ به واحد یکسانی تبدیل شدند و محاسبه کل انرژی نیز از معادله ۳ استفاده شد:

$$(3) \quad \text{انرژی حرارتی} + (\text{انرژی ویژه الکتریکی} \times 3/6) = \text{کل انرژی}$$

برای آموزش مدل یادگیری ماشین از دو مدل یادگیری ماشین با نام‌های جنگل تصادفی (Random Forrest) [10] و درخت تصمیم‌گیری (Decision Tree) [11] استفاده شد، این دو مدل با استفاده از جستجوی شبکه‌ای (Grid Search) فرآپارامترهای مختلف را تست کرده و بهینه‌ترین فرآپارامترها را برای هر دو مدل براساس پارامتر دقت مدل‌های رگرسیونی (R^2) پیدا کردند و بهترین مدل از نظر داشتن پارامتر دقت بهتر برای استفاده ذخیره و بارگیری شد. داده‌های ورودی برای آموزش به مدل شامل داده‌های سالیانه گلخانه‌های استان تهران بودند که شامل داده‌های سال، نوع محصول، سطح زیر کشت و فاصله شهرستان‌ها از سطح دریا بودند. برای نمایش تاثیرگذار بودن هر یک از این موارد بر مصرف انرژی در گلخانه‌ها از نمودارهای shap استفاده شد. جهت آموزش داده نیز داده‌ها به دو دسته آموزش و آزمون تقسیم‌بندی شدند که در این تقسیم‌بندی ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد آن‌ها برای آزمون اختصاص یافتند.


نتایج

در نتایج بدست آمده نشان داده شد که هر دو مدل چه نتایجی را به همراه داشته‌اند و فرآپارامترهای بهینه آن‌ها به همراه نتایج آن‌ها در جدول زیر نمایش داده شده است (جدول ۲).


جدول ۲- نتایج و فرآپارامترهایی که با جستجوی شبکه‌ای بهترین نتیجه را داده‌اند

مدل	Decision Tree	Random Forrest
فرآپارامترها	Max depth = ۲۰	Max depth = ۱۰
	Min sample leaf = ۱	Min sample leaf = ۲
	Min sample split = ۲	Min sample split = ۲
		n estimator = ۲۰۰
R^2	۰/۹۹۸۶	۰/۹۹۰۵

با ترسیم نمودار مقادیر پیش‌بینی شده در مقابل مقادیر واقعی برای داده‌های آزمون و بررسی میزان انطباق این دو منحنی، می‌توان دقت مدل‌ها را ارزیابی کرد. هم‌پوشانی و نزدیکی قابل توجه این دو منحنی بیانگر توان پیش‌بینی بالا و عملکرد مناسب مدل‌ها است. نتایج حاصل برای هر دو مدل در شکل‌های زیر ارائه شده‌اند؛ به‌طوری‌که شکل ۲ مربوط به مدل جنگل تصادفی و شکل ۳ مربوط به مدل درخت تصمیم‌گیری است.




شکل ۲- نتایج پیش‌بینی نسبت به حالت اصلی مقادیر پیش‌بینی شده مدل جنگل تصادفی




شکل ۳- نتایج پیش‌بینی نسبت به حالت اصلی مقادیر پیش‌بینی شده مدل درخت تصمیم‌گیری

در شکل ۴ رابطه بین مقادیر واقعی و مقادیر پیش‌بینی شده مصرف انرژی را برای داده‌های آزمون و با استفاده از مدل‌های مختلف نشان داده شده است. خط چین قرمز معرف حالت ایده‌آل برابری مقادیر واقعی و پیش‌بینی شده است. نزدیکی قابل توجه نقاط پیش‌بینی شده به این خط بیانگر دقت مناسب مدل‌ها در تخمین مصرف انرژی می‌باشد. نتایج نشان می‌دهد که مدل درخت تصمیم‌گیری نسبت به مدل جنگل تصادفی از پراکندگی کمتری برخوردار بوده و عملکرد پایدارتری ارائه می‌دهد. همچنین مدل برتر بیشترین انطباق را با مقادیر واقعی داشته و کمترین میزان خطا را ثبت کرده است که نشان‌دهنده توان بالای این مدل در پیش‌بینی مصرف انرژی است. در این تصویر بدلیل اینکه مدل درخت تصمیم‌گیری به عنوان بهترین مدل با دقت بالاتر انتخاب شده است نقاط آن بر روی نقاط بهترین مدل منطبق شده است.



شکل ۴- رابطه بین مقادیر واقعی و پیش‌بینی شده توسط دو مدل و پایداری در پیش‌بینی نتایج


شکل‌های ۵ و ۶ نتایج تحلیل اهمیت ویژگی‌ها با استفاده از روش SHAP را برای مدل نهایی نشان می‌دهند. شکل ۵ میانگین قدر مطلق مقادیر SHAP را برای هر یک از ویژگی‌ها ارائه می‌دهد که بر اساس آن، متغیر سطح زیر کشت (area) بیشترین تأثیر را بر پیش‌بینی مصرف انرژی داشته و به‌عنوان مهم‌ترین عامل تعیین‌کننده در مدل شناسایی می‌شود. سایر ویژگی‌ها، از جمله سال، فاصله، نوع محصول و شهرستان، سهم به‌مراتب کمتری در خروجی مدل دارند.



شکل ۵- میانگین قدر مطلق مقادیر SHAP


در شکل ۶، توزیع مقادیر SHAP برای هر ویژگی نمایش داده شده است. دامنه وسیع و پراکندگی بالای مقادیر SHAP مربوط به متغیر سطح زیر کشت نشان‌دهنده تأثیرگذاری قوی و غیرخطی این متغیر بر مصرف انرژی می‌باشد، به‌طوری‌که افزایش آن منجر به افزایش قابل توجه مصرف انرژی می‌شود. در مقابل، توزیع مقادیر SHAP برای سایر ویژگی‌ها

عمدتاً در حوالی صفر متمرکز بوده که بیانگر نقش محدود آن‌ها در فرآیند پیش‌بینی است. این نتایج حاکی از آن است که مدل توسعه‌یافته تصمیم‌گیری خود را عمدتاً بر اساس سطح زیر کشت انجام داده و از نظر تفسیرپذیری، رفتاری سازگار با منطق فیزیکی و کشاورزی سیستم مورد مطالعه دارد.



شکل ۶- توزیع مقادیر SHAP برای هر ویژگی

دلیل پایین بودن تاثیر نوع محصول نسبت سه سایر این موارد این است که سطح زیر کشت خیار نسبت به سایر محصولات در این استان بیشتر است و مجموع سطح زیرکشت این محصول در استان تهران حدود ۲۵ هزار هکتار در این مجموعه داده ۹ ساله است. در شکل ۷ سطوح زیرکشت هریک از محصولات نمایش داده شده است. هانطور که نشان داده شده است سطح زیرکشت خیار از سایر محصولات بیشتر بوده و به این دلیل تاثیر گذاری کلی نوع محصول در نمودار توزیع SHAP بسیار پایین بوده است.



شکل ۷- سطوح زیر کشت هریک از محصولات در گلخانه‌های استان تهران

نتیجه‌گیری

در این پژوهش، با استفاده از داده‌های رسمی آمارنامه‌های وزارت جهاد کشاورزی طی سال‌های ۱۳۹۳ تا ۱۴۰۲، مدلی داده‌محور برای برآورد مصرف انرژی در گلخانه‌های استان تهران توسعه داده شد. نتایج نشان داد که بهره‌گیری از روش‌های یادگیری ماشین، به‌ویژه مدل‌های درخت تصمیم‌گیری و جنگل تصادفی، قابلیت بالایی در پیش‌بینی مصرف انرژی گلخانه‌ای دارند و می‌توانند به‌عنوان ابزاری کارآمد در تحلیل و مدیریت انرژی در بخش کشاورزی مورد استفاده قرار گیرند.

مقایسه عملکرد دو مدل نشان داد که هر دو مدل از دقت بسیار بالایی برخوردار هستند، اما مدل درخت تصمیم‌گیری با مقدار پارامتر دقت ۰/۹۹۸۶ عملکرد اندکی بهتر و پایدارتری نسبت به مدل جنگل تصادفی ارائه داد. نزدیکی مقادیر پیش‌بینی شده به مقادیر واقعی در داده‌های آزمون و هم‌راستایی آن‌ها با خط ایده‌آل، بیانگر توان بالای مدل نهایی در تخمین مصرف انرژی و تعمیم‌پذیری مناسب آن است.

نتایج تحلیل اهمیت ویژگی‌ها با استفاده از روش SHAP نشان داد که متغیر سطح زیر کشت گلخانه‌ها مهم‌ترین عامل مؤثر بر مصرف انرژی است و تأثیری به‌مراتب بیشتر از سایر متغیرها دارد. این یافته با منطق فیزیکی مصرف انرژی در گلخانه‌ها هم‌خوانی دارد، چراکه افزایش سطح زیر کشت مستقیماً منجر به افزایش نیاز به انرژی حرارتی و الکتریکی می‌شود. در مقابل، متغیرهایی مانند نوع محصول، فاصله از سطح دریا، شهرستان و سال نقش کمتری در پیش‌بینی مصرف انرژی ایفا کردند. پایین بودن تأثیر نوع محصول عمدتاً ناشی از غلبه سطح زیر کشت محصول خیار در استان تهران است، به‌طوری‌که سهم بالای این محصول در کل داده‌ها باعث کاهش تنوع اثرگذاری نوع محصول در مدل شده است.

در مجموع، نتایج این پژوهش نشان می‌دهد که ترکیب داده‌های آماری رسمی، استانداردهای ملی انرژی و روش‌های یادگیری ماشین می‌تواند ابزاری مؤثر برای تحلیل، پیش‌بینی و بهینه‌سازی مصرف انرژی در گلخانه‌ها فراهم آورد. مدل توسعه‌یافته می‌تواند به‌عنوان پایه‌ای برای تصمیم‌گیری مدیران، سیاست‌گذاران و برنامه‌ریزان بخش کشاورزی در جهت بهبود بهره‌وری انرژی و توسعه پایدار گلخانه‌ها مورد استفاده قرار گیرد.

مراجع

1. A. Raihan, M. Ridwan, and M. S. Rahman, "An exploration of the latest developments, obstacles, and potential future pathways for climate-smart agriculture," *Clim. Smart Agric.*, vol. 1, no. 2, 2024, doi: 10.1016/j.csag.2024.100020.
2. N. N. Thilakarathne, M. S. Abu Bakar, P. E. Abas, and H. Yassin, "Internet of things enabled smart agriculture: Current status, latest advancements, challenges and countermeasures," *Heliyon*, vol. 11, no. 3, 2025, doi: 10.1016/j.heliyon.2025.e42136.
3. F. E. Allali, H. Fatnassi, H. Demrati, R. Errais, A. Wifaya, and A. Aharoune, "Greenhouse cooling systems: A systematic review of research trends, challenges, and recommendations for improving sustainability," *Clean. Eng. Technol.*, vol. 26, 2025, doi: 10.1016/j.clet.2025.100973.
4. A. Aborujilah, M. Al-Sarem, and M. A. Abu-Zanona, "Forecast-Driven Climate Control for Smart Greenhouses: Energy Optimization Using LSTM Model," *Energies*, vol. 18, no. 21, 2025, doi: 10.3390/en18215821.
5. S. Binaei, H. Shabanali Fami, K. Kalantari, A. Barati, and -PhD Student, "Investigation of Developing Smart Agriculture in Greenhouses of Tehran Province," *J. Agric. Econ. Dev.*, vol. 37, no. 4, pp. 433–450, 2024, [Online]. Available: https://jead.um.ac.ir/article_44912_en.html



6. M. Zhang, T. Yan, W. Wang, X. Jia, J. Wang, and J. J. Klemeš, "Energy-saving design and control strategy towards modern sustainable greenhouse: A review," *Renew. Sustain. Energy Rev.*, vol. 164, 2022, doi: 10.1016/j.rser.2022.112602.
7. T. Choudhry, U. N. Kayani, A. Gul, S. A. Haider, and S. Ahmad, "Carbon emissions, environmental distortions, and impact on growth," *Energy Econ.*, vol. 126, 2023, doi: 10.1016/j.eneco.2023.107040.
8. H. Majidi *et al.*, "Overview of energy modeling requirements and tools for future smart energy systems," *Renew. Sustain. Energy Rev.*, vol. 212, 2025, doi: 10.1016/j.rser.2025.115367.
9. Y. Hu and Y. Man, "Energy consumption and carbon emissions forecasting for industrial processes: Status, challenges and perspectives," *Renew. Sustain. Energy Rev.*, vol. 182, 2023, doi: 10.1016/j.rser.2023.113405.
10. Y. Liu, Y. Wang, and J. Zhang, "New machine learning algorithm: Random forest," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 7473 LNCS, pp. 246–252, 2012, doi: 10.1007/978-3-642-34062-8_32.
11. J. Su and H. Zhang, "A fast decision tree learning algorithm," *Proc. Natl. Conf. Artif. Intell.*, vol. 1, pp. 500–505, 2006.