



مقایسه تطبیقی رگرسیون های خطی چندگانه و جنگل تصادفی در تخمین متوسط دمای سطح زمین: مطالعه موردي شهر تبریز

محمدعلی کوشش وطن^{*}، اکبر اصغری زمانی، شهریور روستایی

- ۱- محمدعلی کوشش وطن: دانشجوی دکتری جغرافیا و برنامه ریزی شهری. گروه، جغرافیا و برنامه ریزی شهری، دانشکده
برنامه ریزی و علوم محیطی، دانشگاه تبریز، شهر تبریز، کشور ایران. ایمیل m.alikousheshvatan@gmail.com

۲- اکبر اصغری زمانی: هیات علمی گروه جغرافیا و برنامه ریزی شهری، دانشکده برنامه ریزی و علوم محیطی، دانشگاه
تبریز، شهر تبریز، کشور ایران. ایمیل azamani621@gmail.com

۳- شهریور روستایی: هیات علمی گروه جغرافیا و برنامه ریزی شهری، دانشکده برنامه ریزی و علوم محیطی، دانشگاه تبریز،
شهر تبریز، کشور ایران. ایمیل sroustaie@gmail.com

چکیدہ

دماي سطح زمين به عنوان يكى از پارامترهای مهم و پايهای در مباحث اقلیمي، نشان دهنده رابطه بین اتمسفر و زمين می باشد. با درنظرداشتن مشکلات زیست محيطی شهرها از جمله شدت یافتن جزایر حرارتی شهری، تخمين دماي سطح زمين با دقت مطلوب و همچنین استخراج عوامل مؤثر بر آن نقش قابل توجهی را در مدیریت حرارتی محيطهای شهری و همچنین اتخاذ استراتژی های انطباقی با جزایر حرارتی دارد. پژوهش حاضر در اين راستا به مقاييسه دو روش رگرسيونی خطی چندگانه و جنگل تصادفي پرداخته است. از تصاویر ماديس روزانه در بازه شب (٣٠:١٠) جهت استخراج دماي سطح زمين فصل تابستان شهر تبريز بهره گرفته شد. تصاویر مذكور در سامانه گوگل ارث انجين پردازش شده و برای بازه ٢٠١٨ الى ٢٠٢٢ ميانگين گيري گردید. بر اساس نتایج پژوهش، جنگل تصادفي با ضريب تعين ٩٤٤/٠ = ٠٠٩/٠ = (RMS) عملکرد بسيار بهتری را نسبت به رگرسيون خطی چندگانه از خود نشان داد. جهت استخراج اهميت شاخصها نيز از جنگل تصادفي بهره گرفته شد. بر اساس نتایج اهميت شاخصها، شاخص های نور شب (٥٦/٥ درصد)، ضريب ديد به آسمان (١٠/٤٨ درصد) و مساحت ناحيه رو به باد (٧٢/٤٥) به ترتيب مهم ترين شاخص های اثرگذار بر متوسط دماي سطح زمين شبانه فصل تابستان شهر تبريز هستند. نتایج پژوهش حاضر علاوه بر آشكار نمودن قوت رگرسيون جنگل تصادفي در تخمين دماي سطح زمين، اهميت شاخص های متعدد بر آن را نيز آشكار مى كند. در اين راستا، یافته های اين مطالعه برای مدیریت حرارتی محيط شهری تبريز و اتخاذ استراتژي های سازگاري با جزایر حرارتی آن کاربردي خواهد بود.

کلمات کلیدی: دمای سطح زمین، رگرسیون جنگل تصادفی، رگرسیون خطی چندگانه، یادگیری ماشینی، تبریز.

۱- مقدمه

دمای سطح زمین یک پارامتر مهم محیطی است که به طور قابل توجهی بر مدل سازی اقلیمی، پایش کشاورزی و برنامه ریزی شهری تأثیرگذار است. از کاربردهای قابل توجه داده های دمای سطح زمین در مطالعه اثر جزیره گرمایی شهری است؛ جایی که مناطق شهری به دلیل فعالیت های انسانی و تغییر سطوح زمین دمای بالاتری نسبت به مناطق روستایی اطراف خود دارند (Voogt & Oke, 2003). این پدیده پیامدهای جدی برای پایداری شهری، بهداشت عمومی و مصرف انرژی دارد (Li et al., 2013; Sobrino et al., 2016). دماهای بالا در مناطق شهری می تواند استرس گرمایی را در میان ساکنان تشدید کرده، تقاضای انرژی برای خنکسازی را افزایش داده و کیفیت هوا را در سطح قابل توجهی کاهش می یابد (Li et al., 2013; Zhan et al., 2020)؛ بنابراین، برآورد دقیق دمای سطح زمین برای مدیریت حرارتی مؤثر شهری و استراتژی های کاهش اثرات جزایر گرمای شهری بسیار مهم است.

روش های سنتی برای برآورد دمای سطح زمین به شکل عمده به داده های سنجش از دور و الگوریتم های تجربی متکی است که اغلب به دلیل تداخل جوی، نویز حسگر و ماهیت ناهمگن سطح زمین با محدودیت هایی مواجه می گردد (Li et al., 2013; Sobrino et al., 2016). در سال های اخیر، تکنیک های یادگیری ماشین به عنوان ابزارهای قدرتمند برای افزایش دقت و پایداری تخمین دمای سطح زمین استفاده شده اند. در میان این تکنیک ها، الگوریتم جنگل تصادفی ^۱ به دلیل توانایی آن در مدیریت مجموعه داده های بزرگ، مقادیر ناموجود و مدل سازی روابط پیچیده و غیرخطی بین ویژگی های ورودی موردن توجه قرار گرفته است (Breiman, 2011). این الگوریتم یک روش یادگیری تجمعی مبتنی بر درخت های تصمیم می باشد که پیش بینی های چندین درخت را ترکیب کرده و عملکرد پیش بینی را بهبود می دهد (Rodriguez-Galiano et al., 2012).

مطالعات انجام شده بر عملکرد مطلوب الگوریتم جنگل تصادفی در کاربردهای مختلف سنجش از دور، از جمله طبقه بندی پوشش زمین، برآورد رطوبت خاک و نقشه برداری پوشش گیاهی اشاره کرده اند (Belgiu & Drăgut, 2016; Chan & Paelinckx, 2008). در زمینه برآورد دمای سطح زمین نیز این روش عملکرد بهتری نسبت به روش های سنتی مانند رگرسیون خطی چندگانه را از خود نشان داده است. به عنوان نمونه، فان و همکاران (۲۰۱۸) از جنگل تصادفی جهت برآورد دمای سطح زمین حاصل از لندست ۸ پرداخته اند.

¹ Random Forest (RF)

² Phan

نتایج ایشان نشان می‌دهد که رگرسیون جنگل تصادفی عملکرد بهتری را نیست به رگرسیون خطی چندگانه دارد. منگ^۱ و همکاران (۲۰۲۰) نیز دریافتند که رگرسیون جنگل تصادفی نبست به رگرسیون خطی چندگانه برآورد دقیق‌تری را دمای سطح زمین حاصل از ماهواره مادیس ارائه می‌دهد. علاوه بر این، حقوقی و همکاران (۲۰۲۱) در مقایسه این دو روش در برآورد دمای سطح زمین با استفاده از داده‌های مادیس دریافتند که رگرسیون جنگل تصادفی به طور قابل توجهی دارای دقت و پایداری بالایی است. این مطالعه توانایی جنگل تصادفی در کاهش بیش‌برازش و همچنین اثربخشی آن در مدیریت داده‌های با حجم بالا که از چالش‌های رایج در برآورد دمای سطح زمین هستند را بر جسته کرده است. این مطالعات همچنین نیاز به بررسی بیشتر ویژگی‌های ورودی بهینه، تنظیمات پارامترها و عملکرد الگوریتم در مناطق مختلف را اشاره کرده‌اند. با این حال، هنوز یک شکاف در ارزیابی سیستماتیک قابلیت‌ها و محدودیت‌های رگرسیون جنگل تصادفی در برآورد دمای سطح زمین به ویژه در مناطق شهری تحت تأثیر اثر جزایر حرارتی وجود دارد. علاوه بر شاخص‌های معمول مانند شاخص‌های طیفی و داده‌های هواشناسی، متغیرهای مورفولوژی شهر همچون ارتفاع، تراکم و حجم ساختمان به عنوان تعیین‌کننده‌های مهم دمای سطح زمین در مطالعات متعدد استفاده شده‌اند. ویژگی‌های مورفولوژیکی بر خواص حرارتی سطوح شهری و ریزاقلیم تأثیر آن تأثیر قابل توجهی دارند و در نتیجه بر توزیع دمای سطح زمین تأثیر می‌گذارند. ادغام این متغیرها در مدل‌های پیش‌بینی کننده، می‌تواند وضوح فضایی و دقت برآورد دما را افزایش دهد. خروجی این عمل نیز در شکل‌دهی بینش‌های ضروری برای برنامه‌ریزی شهری و استراتژی‌های کاهش جزایر حرارتی بسیار مفید خواهد بود (Zhan et al., 2020; Zhang & Yu, 2023).

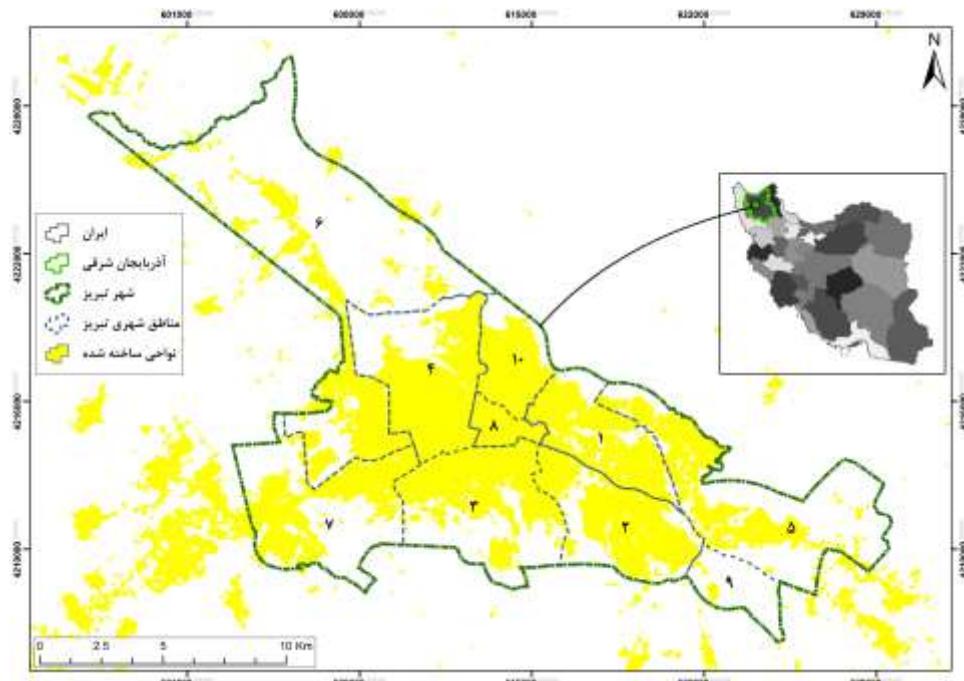
باتوجه به موارد مطرح شده، هدف پژوهش حاضر مقایسه دو روش رگرسیونی خطی چندگانه و جنگل تصادفی در پیش‌بینی دمای سطح زمین شبانه فصل تابستان و همچنین استخراج اهمیت مؤلفه‌های مختلف در راستای تخمین آن است. مؤلفه‌های مذکور شامل شاخص‌های مساحت نفوذناپذیری سطح، دید به آسمان، شاخص مساحت رو به باد، شاخص تفاضلی پوشش گیاهی، آلbedo و نور شب می‌باشد.

۲- مواد و روش تحقیق

۲-۱- منطقه مورد مطالعه

تبریز (شرقی ۱۷°، شمالی ۴۶°، شمالی ۵°، شرقی ۳۸°) یکی از شهرهای مهم شمال غرب کشور در استان آذربایجان شرقی است. بر اساس آخرین سرشماری این شهر دارای جمعیتی حدود دو میلیون نفر است. متوسط ارتفاع شهر تبریز

۱۳۵۰ متر بالاتر از آب‌های آزاد بوده که توسط کوههای عینالی و سهند از شمال و جنوب محدود شده است (کوشش وطن و اصغری زمانی، ۱۴۰۰). این شهر به لحاظ طبقه‌بندی اقلیمی کوپن در دسته اقلیم سرد نیمه خشک واقع شده است؛ بنابراین، تغییرات فصلی قابلی توجهی را دارد. فصل تابستان آن اغلب گرم و خشک و زمستان آن سرد و همراه با بارش برف است. متوسط دمای هوای شهر تبریز بر اساس دوره آماری ۱۹۷۰ الی ۲۰۲۲ برابر با ۱۲/۷ درجه سانتی‌گراد است. شکل (۱) نقشه موقعیت محدوده مورد مطالعه را نشان می‌دهد.



شکل (۱): موقعیت جغرافیایی شهر تبریز
Fig. (1): The geographical location of Tabriz City

۲-۲- داده‌های مورد استفاده

جهت استخراج دمای سطح زمین شهر تبریز از پرداخت شبانه MODIS Terra به صورت روزانه استفاده شد. تصاویر موردنظر برای فصل تابستان در بازه ۲۰۱۸ الی ۲۰۲۲ در سامانه گوگل ارث انجین مورد پردازش قرار گرفته و دانلود گردید. کیفیت تصاویر نیز با استفاده از باند QA کنترل شد. جهت آماده‌سازی شاخص‌های آلدو

و شاخص تفاضلی پوشش گیاهی^۱ از تصاویر لندست ۸ به صورت تصحیح شده بهره گرفته شد. شاخص‌های موردنظر برای بازه ۲۰۱۸ الی ۲۰۲۲ در فصل تابستان در سامانه گوگل ارث انجین پردازش شده و دانلود گردید. شاخص مساحت سطح نفوذناپذیر،^۲ نیز با استفاده از تصویر سنتینل ۲ در سامانه مذکور تهیه شد. همچنین، شاخص‌های دید به آسمان^۳ و مساحت ناحیه رو به باد^۴ از مدل رقومی ارتفاعی سطح تبریز تهیه شد. شاخص نور شب نیز از تصاویر VIIIRS stray light corrected night-time^۵ برای بازه مورد پژوهش به صورت میانگین فصل تابستان از سامانه ارث انجین تهیه شد. جدول (۱) شاخص‌های پژوهش را نشان می‌دهد. این شاخص‌ها از جمله شاخص‌های مهم در راستای تخمین دمای سطح زمین و همچنین جزایر حرارتی هستند که در پژوهش‌های متعدد مورد استفاده قرار گرفته است.

جدول شماره (۱): متغیرهای پژوهش جهت تخمین متوسط دمای سطح زمین

شاخص	منبع
مساحت سطح نفوذناپذیر	Pan et al., 2023; Zhang et al., 2021
ضریب دید به آسمان	Chen et al., 2021; Bernard et al., 2018; Hodul et al., 2016
مساحت ناحیه رو به باد	Gong et al., 2023; Keerthi Naidu and Chundeli, 2023; Li et al., 2022
شاخص تفاضلی پوشش گیاهی	Gadekar et al., 2023; Guha and Ghovil 2020; Parastatidis et al., 2017
آلبدو	Mansourmoghaddam et al., 2024; Andrés-Anaya, 2021
نور شب	Li et al., 2022; Mpakairi & Muvengwi, 2019

۲-۳- روش اجرای پژوهش

در پژوهش حاضر، جهت مدل‌سازی دمای سطح زمین شبانه، متغیرهای متعددی استفاده شد. این شاخص‌ها عبارت‌اند از: مساحت سطح نفوذناپذیر، ضریب دید به آسمان، شاخص مساحت ناحیه رو به باد، شاخص تفاضلی پوشش گیاهی، آلbedo و نور شب. شاخص مساحت سطح نفوذناپذیر با استفاده از تصویر سنتینل ۲ تهیه گردید. جهت استخراج آن از الگوریتم طبقه‌بندی جنگل تصادفی استفاده شد. اراضی ساخته شده به عنوان سطوح نفوذناپذیر در نظر گرفته شد. تخمین شاخص ضریب دید به آسمان نیز با استفاده از مدل رقومی ارتفاعی سطح شهر تبریز با استفاده از نرم‌افزار SAGA تهیه گردید. در ادامه، شاخص مساحت ناحیه رو به باد با استفاده از

¹ Normalized difference vegetation index (NDVI)

² Impervious surface area (ISA)

³ Sky view factor (SVF)

⁴ Frontal area index (FAI)

⁵ Digital Surface Model (DSM)

DSM برآورد گردید. رابطه (۱) فرمول محاسبه این شاخص را نشان می‌دهد. این شاخص λ_f از نسبت مجموع مساحت وجهه ساختمان رو به جهت باد (A_{facets}) با مساحت حجمی ساختمان (A_{plane}) حاصل می‌گردد.(Wong et al., 2010)

$$\lambda_f = A_{facets}/A_{plane} \quad (1)$$

شاخص NDVI نیز با استفاده از رابطه (۲) برآورد گردید. بدین جهت از باندهای ۴ (NIR) و ۵ (RED) ماهواره لندست ۸ استفاده شد (Carlson & Riziley, 1997).

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)} \quad (2)$$

جهت تخمین آلدو در بازه موردمطالعه نیز از رابطه (۳) استفاده شد که توسط Liang (2000) ارائه شده است. در این رابطه ρ نشانگر باندهای لندست می‌باشد.

$$a_{TOA} = \frac{0.356\rho_1 + 0.13\rho_3 + 0.373\rho_4 + 0.085\rho_5 + 0.072\rho_7 - 0.0018}{0.356 + 0.13 + 0.373 + 0.085 + 0.072} \quad (3)$$

تصاویر نور شب نیز در سامانه ارث انجین برای بازه موردمطالعه تهیه گردید. این شاخص به عنوان مولفه‌ای از فعالیت‌های انسانی در نواحی شهری توسط پژوهش‌های متعددی استفاده شده است (Mpakairi & Muvengqi, 2019). در نهایت تمام متغیرهای تهیه شده، در قالب شبکه $300 * 300$ میانگین‌گیری شد که نشانگر مقیاس واحد همسایگی می‌باشد. لازم به ذکر است همه تصاویر تولید شده در یک سیستم تصویر (UTM) قرار داده شده و به لحاظ تفکیک مکانی نیز به دقت مکانی 100 متر رسیمپل شدن. بدین جهت از الگوریتم Bilinear Interpolation تورم واریانس استفاده شد. در نهایت جهت سنجش میزان هم خطی چندگانه شاخص‌ها از عامل راستا، هم خطی چندگانه برای هیچ یک از متغیرها مشاهده نشد ($VIF < 10$). واحد همه شاخص‌های مورد استفاده در پژوهش نیز با استفاده از لگاریتم طبیعی یکسان‌سازی گردید.

¹ Variance Inflation Factor (VIF)

۳-۲-۱- رگرسیون خطی چندگانه

رگرسیون خطی چندگانه، یکی از روش‌های آماری است که به مدل‌سازی رابطه بین متغیرهای مستقل و وابسته بر مبنای معادله خطی در داده‌های مشاهده شده می‌پردازد (Abrougui et al., 2019). این رگرسیون مدل گسترش یافته رگرسیون خطی ساده بوده و تأثیر دو یا چند متغیر بر یک متغیر وابسته را نشان می‌دهد (Abbot, 2017; George & Mallery, 2020).

$$Y_i = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_n X_n + \varepsilon_i \quad (4)$$

در این معادله Y_i معرف میزان پیش‌بینی شده برای متغیر وابسته، X معرف متغیرهای پیش‌بین، β_0 معرف عرض از مبدأ، β معرف شیب خطوط و ε_i معرف خطای مدل است (Richardson, 2015; Pal & Bharati, 2019).

۳-۲-۲- رگرسیون جنگل تصادفی

رگرسیون جنگل تصادفی یکی از قوی‌ترین الگوریتم‌های یادگیری ماشینی است که توسط Breiman^۱ در سال ۲۰۰۱ ارائه شده است (کوشش وطن و همکاران، ۱۴۰۰). این روش از نوع نظارت شده است که برای مسائل رگرسیون و طبقه‌بندی بر اساس توسعه درخت تصمیم ارائه شده است (Makhija et al., 2021; Sharma & Rani, 2021). این روش با استفاده از یک درخت تصمیم ضعیف، یک یادگیرنده قوی‌تر تشکیل می‌دهد. همچنین، رگرسیون جنگل تصادفی، توانایی مناسبی را در راستایی کنترل داده‌های ازدست‌رفته و نامتوازن از خود نشان می‌دهد. علاوه بر این، آن‌ها در مقایسه با سایر الگوریتم‌های یادگیری ماشینی، کمتر مستعد بیش برآذش ۰ هستند (Wlodarczak, 2020).

در پژوهش حاضر از ضریب تعیین^۲(۵)، خطای جذر میانگین مربعات^۳(۶) برای ارزیابی عملکرد دو مدل رگرسیون خطی چندگانه و رگرسیون جنگل تصادفی بهره گرفته شد. در فرمول‌های زیر N بیانگر تعداد

¹ Breiman

² Overfitting

³ Coefficient Of Determination

⁴ Root Mean Squared Error (RMSE)

مشاهدات، A_i ، \hat{P}_i و \bar{A} به ترتیب بیانگر اعداد مشاهده شده، اعداد پیش‌بینی شده و میانگین اعداد مشاهده شده است (کوشش وطن و همکاران، ۱۴۰۰).

$$R^2 \left(1 - \frac{\sum_{i=1}^N (A_i - \hat{P}_i)^2}{\sum_{i=1}^N (A_i - \bar{A})^2} \right) \quad (5)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (A_i - \hat{P}_i)^2} \quad (6)$$

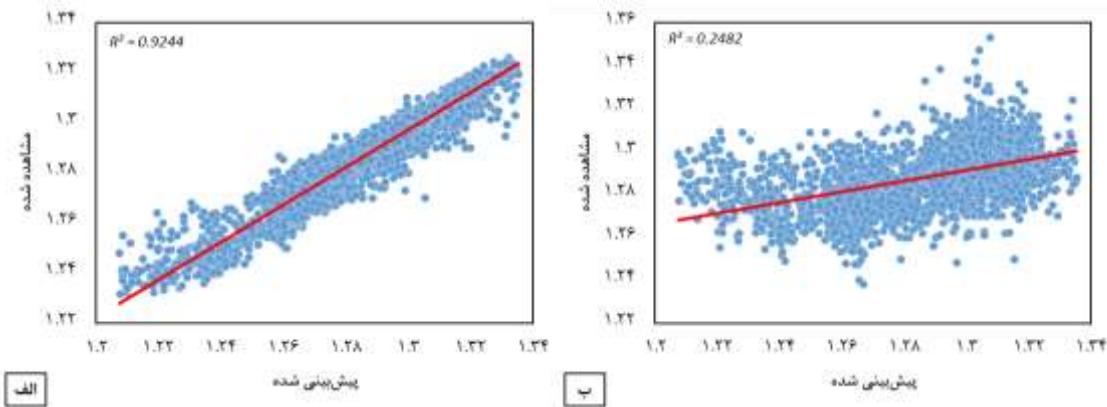
جهت انجام مدل‌سازی و همچنین استخراج عوامل مؤثر در دمای سطح زمین شبانه فصل تابستان، داده‌های پژوهش به دودسته آزمایش (۳۰ درصد) و آموزش (۷۰ درصد) تقسیم شد. جهت اجرای رگرسیون جنگل تصادفی نیاز است تا دو پارامتر n_{tree} و $mtry$ با مقدار مطلوب بهینه گردد. n_{tree} بیانگر فراوانی درخت در جنگل تصادفی بوده و $mtry$ نشانگر تعداد متغیرهای موجود برای تقسیم در هر گره درخت است. در این الگوریتم، هرچه تعداد درختان تا حدی بیشتر باشد، مدل عملکرد بهتری خواهد داشت (Breiman, 2002; Liaw & Wiener, 2001). در پژوهش حاضر، تعداد درختان در عدد ۱۵۰۰ بهینه شده و تعداد متغیرهای موجود برای تقسیم در هر گره نیز ۲ عدد در نظر گرفته شد. هر دو روش رگرسیونی در نرم‌افزار RStudio اجرا شد. همچنین، جهت اجرای رگرسیون جنگل تصادفی نیز از بسته randomForest بهره گرفته شد.

۳- نتایج و بحث

۱- مقایسه دقت الگوریتم جنگل تصادفی و رگرسیون خطی چندگانه

شکل (۲) نتایج حاصل از آموزش رگرسیون‌های مورد استفاده در پژوهش را نشان می‌دهد. در این راستا، ضریب تعیین رگرسیون جنگل تصادفی برابر با 0.924 و ضریب تعیین رگرسیون خطی چندگانه برابر با 0.248 است. همچنین خطای رگرسیون جنگل تصادفی برابر با 0.009 و خطای رگرسیون خطی چندگانه برابر با 0.024 است. بدین ترتیب، رگرسیون جنگل تصادفی با خطای کمتر و ضریب تعیین بالاتر نسبت به رگرسیون خطی چندگانه عملکرد بهتری در مدل‌سازی دمای سطح زمین شبانه فصل تابستان داشته است. مپاکایری و موونگوی (۲۰۱۹) در پژوهش خود از رگرسیون جنگل تصادفی برای مدل‌سازی دمای سطح زمین استفاده کرده‌اند که نتایج ایشان ضریب تعیین 0.65 را نشان می‌دهد. مطالعه حاضر مدل‌سازی بهتری را با استفاده

از این روش رگرسیونی انجام داده است. تنگ^۱ و همکاران (۲۰۲۲) نیز در مطالعه خود با استفاده از رگرسیون جنگل تصادفی تخمین مطلوبی ($R^2 \geq 0.9$) را از دمای سطح زمین انجام داده‌اند که هم راستا با یافته پژوهش حاضر است.



شکل (۲): نمودار ضریب تعیین (الف) الگوریتم جنگل تصادفی و (ب) رگرسیون خطی چندگانه
Fig. (2): Determination coefficient of (a) the random forest regression and (b) the multiple linear regression

۳-۲- اهمیت شاخص‌ها

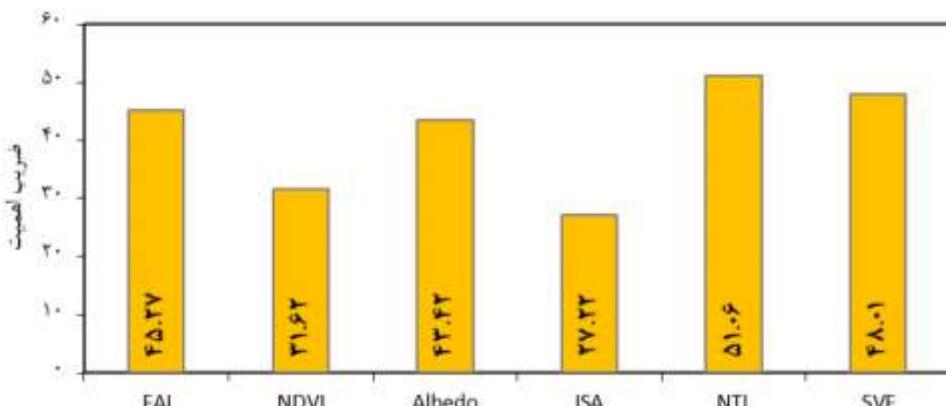
به جهتی که رگرسیون جنگل تصادفی عملکرد بهتری داشت، نتایج مربوط به اهمیت شاخص این روش گزارش می‌شود. شکل (۳) اهمیت شاخص‌های مورد استفاده در پژوهش در راستای دمای سطح زمین را نشان می‌دهد. در بین شاخص‌های استفاده شده، شاخص NTL با ۵۱/۰ درصد دارای بیشترین اهمیت در راستای دمای سطح زمین شبانه فصل تابستان است. در زمینه نتایج هم راستا، نتیجه مطالعه مپاکایری و موونگوی^۲ (۲۰۱۹) نشان می‌دهد که شاخص نور شب مهمترین عامل موثر بر دمای سطح زمین است. همچنین نتایج مطالعه تیموری و همکاران (۱۴۰۲) نیز نتایج مشابهی را در این زمینه نشان می‌دهد. شاخص SVF نیز دومین ۴۸/۰ درصد (b) شاخص مهم در راستای دمای سطح زمین شبانه فصل تابستان می‌باشد. نتیجه مشابه در این زمینه در پژوهش چن^۳ و همکاران (۲۰۲۱) مشاهده شده است. ایشان همبستگی قویی را بین SVF و LST روز و شب با استفاده از تصاویر لندست و استر به دست آورده‌اند. شاخص FAI نیز با ۴۵/۲۷ درصد سومین شاخص موثر در دمای سطح زمین شبانه فصل تابستان است. هم راستا با نتیجه مطالعه حاضر، در پژوهش دیگری نیز تاثیر

¹ Tang

² Mpakairi & Muvengwi

³ Chen

مثبتی ($R^2 = 0.59$) بین FAI و LST مشاهده شده است (Li et al., 2022). علاوه بر این، نتایج لی^۱ و همکاران (۲۰۲۱) خلاف یافته مطالعه حاضر در زمینه شاخص FAI در ووهان چین را نشان می‌دهد. نتایج ایشان با استفاده از رگرسیون جنگل تصادفی نشان می‌دهد که شاخص FAI دارای کمترین تاثیر بر LST در تمام فصول می‌باشد. شاخص آلبدو نیز با $43/42$ درصد چهارمین مولفه موثر در دمای سطح زمین است که تاثیر آن بر دما در پژوهش‌های متعددی مشاهده شده است (Andrés-Anaya et al., 2021). شاخص‌های ISA (۳۱/۶۲) و NDVI (۲۷/۲۵) نیز به ترتیب کمترین اهمیت را در مدلسازی دمای سطح زمین شبانه فصل تابستان شهر تبریز دارند. همچنین، تاثیر ضعیف NDVI در LST روز نیز در پژوهش دیگری در شهر تبریز مشاهده شده است (آزادی مبارکی و احمدی، ۱۴۰۰). در زمینه شاخص ISA نیز تاثیر قابل توجهی ($0.69/0.85$) بین این مولفه با LST شبانه در پژوهش‌های دیگر مشاهده شده است که مغایر با نتیجه پژوهش حاضر می‌باشد (Mallick et al., 2013; Mathew et al., 2022).



شکل (۳): نمودار اهمیت شاخص‌های موثر بر متوسط دمای سطح زمین

Fig. (2): Variable importance of the mean LST drivers

۴- نتیجه گیری

شناسایی عوامل مؤثر بر دمای سطح زمین در شهرها به جهت مدیریت حرارتی مؤثر نواحی شهری و همچنین اتخاذ استراتژی‌های انطباقی با جزایر حرارتی امری ضروری است. در این راستا، هدف پژوهش حاضر مطالعه

تطبیقی رگرسیون‌های خطی چندگانه و جنگل تصادفی در تخمین دمای سطح زمین شبانه فصل تابستان شهر تبریز و همچنین رتبه‌بندی عوامل مؤثر بر آن بود.

بر اساس نتایج عملکرد دو روش رگرسیونی، روش رگرسیونی جنگل تصادفی خطای کمتری را نسبت به رگرسیونی خطی چندگانه از خود نشان داد؛ بنابراین، از این روش جهت استخراج عوامل مؤثر استفاده شد. بدین اساس، مهم‌ترین شاخص در دمای سطح زمین شبانه تابستان شهر تبریز، شاخص نور شب است. این شاخص دارای همبستگی قابل توجهی با فعالیت‌های انسانی (فعالیت‌های صنعتی و غیره) است که در طول شب رخ می‌دهد. دومین شاخص نیز شاخص ضریب دید به آسمان می‌باشد. مورفولوژی شهر تبریز به‌ویژه نواحی مرکزی آن دارای بافت فشرده و همچنین بلندمرتبه است که نقش مهم این عامل را در تغییرات دمایی محیط شهری توجیه می‌نماید. سومین عامل مهم نیز شاخص مساحت رو به باد بود. این عامل از موارد مهم در مطالعه جزایر حرارتی است که محصورشدنگی محیط شهری به جهت عدم نفوذپذیری باد را نشان می‌دهد. هر چه محیط شهری فشرده باشد، ضریب نفوذ باد نیز کاهش یافته و روند تخلیه حرارتی با سرعت کمتری انجام می‌شود. چهارمین عامل مؤثر بر دمای سطح زمین نیز آبدو بود که از مؤلفه‌های اساسی کنترل و کاهش جزایر حرارتی است. شهر تبریز نیز دارای وسعت بالایی از سطوح تیره و غیرقابل نفوذ است که باعث ذخیره گرمایی در طول روز شده و در شب آن را در محیط شهری آزاد می‌نماید. شاخص‌های پوشش گیاهی و مساحت سطح نفوذناپذیر نیز به ترتیب کمترین اهمیت را در دمای سطح زمین شبانه فصل تابستان داشته‌اند. کمبود پوشش گیاهی نیز از دیگر مشکلات شهر تبریز است که از آن رنج می‌برد. کمبود این مقوله و پراکنش نامناسب آن و همچنین کمبود نسبت مساحتی پهنه‌های سبز نیز منجر به کاهش اهمیت آن در تخمین دمای سطح زمین شده است. پوشش گیاهی از جمله مهم‌ترین استراتژی‌های کاهش جزایر حرارتی است که در وهله اول مورد توجه برنامه‌ریزان می‌باشد. البته این استراتژی باید در قالب توجه به منابع آبی و همچنین نوع اقلیم به مرحله اجرا در آید.

۵- منابع

1. Abbot, M. L. (2017). Using Statistics in the Social and Health Sciences with SPSS and Excel. John Wiley & Sons. DOI: 10.1002/9781119121077
2. Abrougui, K. & Gabsi, K. & Mercatoris, B. & Khemis, C. & Amami, R. & Chehaibi, Sa. (2019). Prediction of organic potato yield using tillage systems and soil properties by artificial neural network and multiple linear regressions. *Soil and Tillage Research*. Vol. 190. pp 202-208. DOI: 10.1016/j.still.2019.01.011.
3. Andrés-Anaya, P., Sánchez-Aparicio, M., del Pozo, S., & Lagüela, S. (2021). Correlation of Land Surface Temperature with IR Albedo for the Analysis of Urban Heat Island. *Engineering Proceedings*, 8(1). <https://doi.org/10.3390/engproc2021008009>
4. Azadi Mubaraky, M., & Ahmadi, M. (2021). Investigation of urban heat islands of Tabriz metropolis using multi-time data of LANDSAT8 satellite based on hot spot analysis method. *Regional Planning*, 11(43), 47–63. <https://doi.org/10.30495/jzpm.2021.3992> (In Persian).
5. Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24-31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
6. Bernard, J., Bocher, E., Petit, G., Palominos, S. (2018). "Sky View Factor Calculation in Urban Context: Computational Performance and Accuracy Analysis of Two Open and Free GIS Tools" *Climate* 6(3). <https://doi.org/10.3390/cli6030060>
7. Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
8. Breiman, L. (2002). Manual on setting up, using, and understanding random forests v3.1. https://www.stat.berkeley.edu/~breiman/Using_random_forests_V3.1.pdf
9. Carlson, T. N., & Riziley, D. A. (1997). On the Relation between NDVI, Fractional Vegetation Cover, and Leaf Area Index. *Remote Sensing of Environment*, 62(3), 241–252. [https://doi.org/10.1016/S0034-4257\(97\)00104-1](https://doi.org/10.1016/S0034-4257(97)00104-1)
10. Chan, J. C.-W., & Paelinckx, D. (2008). Evaluation of Random Forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. *Remote Sensing of Environment*, 112(6), 2999-3011. <https://doi.org/10.1016/j.rse.2008.02.011>
11. Chen, Q., Cheng, Q., Chen, Y., Li, K., Wang, D., & Cao, S. (2021). The Influence of Sky View Factor on Daytime and Nighttime Urban Land Surface Temperature in Different Spatial-Temporal Scales: A Case Study of Beijing. *Remote Sensing*, 13(20). <https://doi.org/10.3390/rs13204117>

12. Gadekar, K., Pande, C.B., Rajesh, J., Gorantiwar, S.D., Atre, A.A. (2023). Estimation of Land Surface Temperature and Urban Heat Island by Using Google Earth Engine and Remote Sensing Data. In: Pande, C.B., Moharir, K.N., Singh, S.K., Pham, Q.B., Elbeltagi, A. (eds) Climate Change Impacts on Natural Resources, Ecosystems and Agricultural Systems. Springer Climate. Springer, Cham. https://doi.org/10.1007/978-3-031-19059-9_14
13. George, D. & Mallery, P. (2020). IBM SPSS Statistics 26 Step by Step: A Simple Guide and Reference. 16th Edition. Routledge: Taylor & Francis Group. <https://www.routledge.com/IBM-SPSS-Statistics-26-Step-by-Step-A-Simple-Guide-and-Reference/George-Mallery/p/book/9780367174354>
14. Gong, D., Dai, X., Zhou, L. (2023). Satellite-Based Optimization and Planning of Urban Ventilation Corridors for a Healthy Microclimate Environment. *Sustainability*, 15(21):15653. <https://doi.org/10.3390/su152115653>
15. Guha, S., Govil, H. (2020). Land surface temperature and normalized difference vegetation index relationship: a seasonal study on a tropical city. *SN Appl. Sci.* 2, 1661. <https://doi.org/10.1007/s42452-020-03458-8>
16. Haghverdi, A., Noori, R., & Tisseyre, B. (2021). Estimating Land Surface Temperature using MODIS data: A Random Forest approach. *Journal of Environmental Management*, 298, 113491. <https://doi.org/10.1016/j.jenvman.2021.113491>
17. Hodul, M., Knudby, A., Chak, H. (2016). "Estimation of Continuous Urban Sky View Factor from Landsat Data Using Shadow Detection" *Remote Sensing* 8(7). <https://doi.org/10.3390/rs8070568>
18. Keerthi Naidu, B., Chundeli, F.A. (2023). Assessing LULC changes and LST through NDVI and NDBI spatial indicators: a case of Bengaluru, India. *GeoJournal* 88, 4335–4350. <https://doi.org/10.1007/s10708-023-10862-1>
19. Koushesh Vatan, M. A., & Asghari Zamani, A. (2021). Study of land surface temperature concerning land-use in Tabriz city using the Landsat 8 data. *Journal of Economic Geography Researches*, 2(3), 49–58. https://jurs.znu.ac.ir/article_244529.html (In Persian).
20. Koushesh Vatan, M. A., Asghari Zamani, A., Nemati, M., & Pourmohammad, F. (2021). A Comparison of Multiple Linear Regression and Random Forest Regression to Evaluate the Price of Residential Units (Case Study: North Valiasr, Tabriz). *Geography and Territorial Spatial Arrangement*, 11(40), 57–82. <https://doi.org/10.22111/gaij.2021.6486> (In Persian).
21. Li, H., Li, Y., Wang, T., Wang, Z., Gao, M., & Shen, H. (2021). Quantifying 3D building form effects on urban land surface temperature and modeling seasonal correlation patterns. *Building and Environment*, 204, 108132. <https://doi.org/https://doi.org/10.1016/j.buildenv.2021.108132>
22. Li, L., Zhao, Z., Wang, H., Shen, L., Liu, N., & He, B.-J. (2022). Variabilities of Land Surface Temperature and Frontal Area Index Based on Local Climate Zone. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 2166–2174. <https://doi.org/10.1109/JSTARS.2022.3153958>

23. Li, Z. L., Tang, R., Wan, Z., Bi, Y., Zhou, C., Tang, B., ... & Zhang, X. (2013). A review of current methodologies for regional evapotranspiration estimation from remotely sensed data. *Sensors*, 13(5), 5977-6010. <https://doi.org/10.3390/s130505977>
24. Li, Z., Wu, F., Ma, H., Xu, Z., Wang, S. (2022). Spatiotemporal Evolution and Relationship between Night Time Light and Land Surface Temperature: A Case Study of Beijing, China. *Land*. 211(4):548. <https://doi.org/10.3390/land11040548>



25. Liang, S. (2000). Narrowband to broadband conversions of land surface albedo I Algorithms. *Remote Sensing of Environment*, 76, 213–238. www.elsevier.com/locate/rse
26. Liaw, Andy & Wiener, Matthew. (2001). Classification and Regression by RandomForest. *RNews*. 23. https://www.researchgate.net/publication/228451484_Classification_and_Regression_by_R_randomForest
27. Makhija R., Ali S., Jaya Krishna R. (2021) Detecting Influencers in Social Networks Through Machine Learning Techniques. In: Hassanien A., Bhatnagar R., Darwish A. (eds) Advanced Machine Learning Technologies and Applications. AMLTA 2020. Advances in Intelligent Systems and Computing, vol 1141. Springer, Singapore. https://doi.org/10.1007/978-981-15-3383-9_23.
28. Mallick, J., Rahman, A., & Singh, C. K. (2013). Modeling urban heat islands in heterogeneous land surface and its correlation with impervious surface area by using night-time ASTER satellite data in highly urbanizing city, Delhi-India. *Advances in Space Research*, 52(4), 639–655. <https://doi.org/10.1016/j.asr.2013.04.025>
29. Mansourmoghaddam, M., Rousta, I., Ghafarian Malamiri, H., Sadeghnejad, M., Krzyszczak, J., Ferreira, CSS. (2024). Modeling and Estimating the Land Surface Temperature (LST) Using Remote Sensing and Machine Learning (Case Study: Yazd, Iran). *Remote Sensing*, 16(3):454. <https://doi.org/10.3390/rs16030454>
30. Mathew, A., P, S., & Khandelwal, S. (2022). Investigating the contrast diurnal relationship of land surface temperatures with various surface parameters represent vegetation, soil, water, and urbanization over Ahmedabad city in India. *Energy Nexus*, 5. <https://doi.org/10.1016/j.nexus.2022.100044>
31. Meng, Q., Li, L., & Dong, Q. (2020). Land surface temperature estimation from MODIS data using the Random Forests regression algorithm. *Remote Sensing*, 12(3), 507. <https://doi.org/10.3390/rs12030507>
32. Mpakairi, K. S., & Muvengwi, J. (2019). Night-time lights and their influence on summer night land surface temperature in two urban cities of Zimbabwe: A geospatial perspective. *Urban Climate*, 29. <https://doi.org/10.1016/j.uclim.2019.100468>
33. Pal, M. & Bharati, P. (2019). Applications of Regression Techniques. Springer Singapore. <https://www.springer.com/gp/book/9789811393136>
34. Pan, T., Li, B., Ning, L. (2023). "Impervious Surface Area Patterns and Their Response to Land Surface Temperature Mechanism in Urban–Rural Regions of Qingdao, China" *Remote Sensing* 15(17). <https://doi.org/10.3390/rs15174265>
35. Parastatidis D, Mitraka Z, Chrysoulakis N, Abrams M. (2017). Online Global Land Surface Temperature Estimation from Landsat. *Remote Sensing*, 9(12):1208. <https://doi.org/10.3390/rs9121208>
36. Phan, T. L., Kappas, M., Degener, J., & Nguyen, L. D. (2018). Application of Random Forest for spatial distribution of tropical forest aboveground biomass estimation using multi-spectral

- remote sensing data. *International Journal of Digital Earth*, 11(7), 640-660. <https://doi.org/10.1080/17538947.2017.1365965>
37. Richardson, R. (2015). *Business Applications of Multiple Regression*, Second Edition - Quantitative approaches to decision making collection. Business Expert Press. <https://www.businessexpertpress.com/books/business-applications-multiple-regression-second-edition/>
38. Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sánchez, J. P. (2012). An assessment of the effectiveness of a Random Forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93-104. <https://doi.org/10.1016/j.isprsjprs.2011.11.002>
39. Sharma R., Rani S. (2021) A Novel Approach for Smart-Healthcare Recommender System. In: Hassanien A., Bhatnagar R., Darwish A. (eds) *Advanced Machine Learning Technologies and Applications. AMLTA 2020. Advances in Intelligent Systems and Computing*, vol 1141. Springer, Singapore. https://doi.org/10.1007/978-981-15-3383-9_46.
40. Sobrino, J. A., Jiménez-Muñoz, J. C., & Paolini, L. (2016). Land surface temperature retrieval from LANDSAT TM 5. *Remote Sensing of Environment*, 90(4), 434-440. <https://doi.org/10.1016/j.rse.2004.02.003>
41. Song, C., Woodcock, C. E., Seto, K. C., Lenney, M. P., & Macomber, S. A. (2014). Classification and change detection using Landsat TM data: When and how to correct atmospheric effects? *Remote Sensing of Environment*, 75(2), 230-244. <https://doi.org/10.1016/j.rse.2000.11.011>
42. Tang, J., Lan, X., Lian, Y., Zhao, F., & Li, T. (2022). Estimation of Urban-Rural Land Surface Temperature Difference at Different Elevations in the Qinling-Daba Mountains Using MODIS and the Random Forest Model. *International journal of environmental research and public health*, 19(18), 11442. <https://doi.org/10.3390/ijerph191811442>
43. Teymouri, I., Asghari Zamani, A., Torabi, S. (2023). Investigating the impact of urban morphological factors on thermal islands in cities, a case study: Urmia city (2021-2015 period). *Remote Sensing and GIS Applications in Environmental Sciences*, 2(5), 111-97. doi: 10.22034/rsgi.2023.16594 (In Persian)
44. Voogt, J. A., & Oke, T. R. (2003). Thermal remote sensing of urban climates. *Remote Sensing of Environment*, 86(3), 370-384. [https://doi.org/10.1016/S0034-4257\(03\)00079-8](https://doi.org/10.1016/S0034-4257(03)00079-8)
45. Włodarczak, Peter (2020). *Machine Learning and its applications*, First edition. Boca Raton, FL: CRC Press/Taylor & Francis Group. DOI: 10.1201/9780429448782
46. Wong, M. S., Nichol, J. E., To, P. H., & Wang, J. (2010). A simple method for designation of urban ventilation corridors and its application to urban heat island analysis. *Building and Environment*, 45(8), 1880–1889. <https://doi.org/10.1016/j.buildenv.2010.02.019>
47. Zhang, Q., Wu, Z., Singh, V., Liu, C. (2021). "Impacts of Spatial Configuration of Land Surface Features on Land Surface Temperature across Urban Agglomerations, China" *Remote Sensing* 13(19). <https://doi.org/10.3390/rs13194008>

کاربرد سنجش از دور و GIS در علوم محیطی، شماره ۱۱، دوره ۴، فصل تابستان سال ۱۴۰۳، صص ۴۷-۱۷
مینا محسن زاده، علیرضا محمدی

A Comparative Study of Multiple Linear Regression and Random Forest in the Estimation of Land Surface Temperature: A Case Study of Tabriz City

Abstract

Land surface temperature, as one of the important and fundamental parameters in climatology, indicates the relationship between the atmosphere and the Earth. Considering the environmental issues of cities, including the intensification of urban heat islands, accurately estimating LST and identifying its influencing factors play a significant role in urban thermal management and adopting adaptive strategies for heat islands. In this regard, this study compares two regression methods: multiple linear regression and random forest in order to estimate the LST. Daily nighttime MODIS images were used to extract the LST of Tabriz city during the summer. These images were processed in the Google Earth Engine platform and averaged for the period from 2018 to 2022. According to the results, the random forest showed significantly better performance with a coefficient of determination of 0.924 ($RMS = 0.009$) compared to multiple linear regression. The random forest was also used to determine the importance of the indices. Based on the index importance results, night lights (51/06%), sky view factor (48/01%) and frontal area index (45/27%) were the most important factor affecting the nighttime summer LST in Tabriz city, respectively. The findings of this study, in addition to revealing the strength of the random forest regression in estimating LST, also highlight the importance of various indices in the LST. In this context, the study's results will be practical for managing the thermal environment of Tabriz city and adopting mitigation strategies for its heat islands.

Keywords: Land Surface Temperature, Random Forest Regression, Linear Regression, Machine learning, Tabriz.