

برآورد تبخیر و تعرق مرجع با استفاده از داده‌های سنجش‌ازدور در دشت همدان بهار

زینب نیاستی^۱، حمید عبادی^۲ و عباس کیانی^{۳*}

چکیده

باتوجه به افزایش تولید محصولات کشاورزی و همچنین وقوع خشکسالی مکرر در بسیاری از مناطق جهان، نیاز شدیدی به برآورد دقیق‌تری از میزان آب مصرفی گیاهان و در نتیجه برآورد دقیق تبخیر و تعرق مرجع احساس می‌شود. معادله پنمن مانیتث فائو برای برآورد تبخیر و تعرق مرجع به‌عنوان روشی استاندارد در بسیاری از تحقیقات معرفی شده است. از جمله معایب اصلی این روش، به‌صورت نقطه‌ای بودن و دردسترس بودن داده‌های هواشناسی در مکان‌های خاص است؛ درحالی‌که با استفاده از داده‌های سنجش‌ازدور می‌توان این مشکل را برطرف کرد. در این پژوهش، هدف اصلی ترکیب داده‌های سنجش‌ازدور با مدل‌های یادگیری ماشین، برآورد تبخیر و تعرق مرجع است. با استفاده از مدل‌های یادگیری ماشین، چالش‌های انتخاب بهترین مدل ممکن، متغیرهای ورودی مدل و دردسترس بودن داده‌های موردنیاز ایجاد می‌شود؛ بنابراین در این پژوهش مدل‌های مطرح RF، GBR و SVR، انتخاب و از داده‌های تصاویر لندست و شاخص‌های پوشش گیاهی استفاده شد. منطقه مورد مطالعه، دشت همدان بهار واقع در مناطق غربی کشور است. در این پژوهش برای برآورد تبخیر و تعرق مرجع، از دو رویکرد استفاده شد که در رویکرد اول، متغیرهای ورودی مدل‌ها با مقادیر همه باندهای تصاویر لندست؛ درحالی‌که در رویکرد دوم، شاخص‌های پوشش گیاهی به‌عنوان ورودی مدل معرفی و استفاده شد. مدل RF با شاخص‌های پوشش گیاهی، نتایج آماری برابر با ($RMSE=14/1\%$ و $R^2=76/4\%$) داشت؛ درحالی‌که با استفاده از همه باندهای لندست ($RMSE=11/7\%$ و $R^2=84/1\%$) و همچنین در مقایسه با الگوریتم‌های دیگر، با مقداری دقت بیشتر، تبخیر و تعرق مرجع را برآورد کرد. نتایج، بیان‌کننده توانایی و پتانسیل شاخص‌های پوشش گیاهی به‌تنهایی و تصاویر لندست در تهیه اطلاعات لازم برای مدیریت آبیاری در کشاورزی و همچنین توانایی الگوریتم‌های یادگیری ماشین در برآورد پارامترهایی نظیر تبخیر و تعرق مرجع بود.

واژه‌های کلیدی: تبخیر و تعرق، سنجش‌ازدور، شاخص‌های پوشش گیاهی، مدیریت آبیاری، یادگیری ماشین.

ارجاع: نیاستی ز. حمید عبادی ح. و کیانی ع. ۱۴۰۰. برآورد تبخیر و تعرق مرجع با استفاده از داده‌های سنجش‌ازدور در دشت همدان بهار. مجله پژوهش آب ایران. ۴۳: ۹۹-۹۹.

۱- دانشجوی کارشناسی ارشد سنجش‌ازدور، دانشکده نقشه‌برداری، دانشگاه صنعتی خواجه‌نصیرالدین طوسی.

۲- استاد دانشکده مهندسی نقشه‌برداری، عضو قطب علمی فناوری اطلاعات مکانی، دانشگاه صنعتی خواجه‌نصیرالدین طوسی.

۳- استادیار گروه مهندسی نقشه‌برداری، دانشکده عمران، دانشگاه صنعتی نوشیروانی بابل.

* نویسنده مسئول: a.kiani@nit.ac.ir

تاریخ پذیرش: ۱۴۰۰/۰۶/۲۷

تاریخ دریافت: ۱۴۰۰/۰۲/۰۶

سرعت باد، رطوبت نسبی، تابش خورشید و ... نیاز دارد؛ درحالی‌که مشاهدات و تهیه این پارامترها در ایستگاه‌های هواشناسی در کشورهای درحال توسعه محدود است (دراگوز و الن، ۲۰۰۲). حتی اگر یک ایستگاه هواشناسی در یک منطقه خاص وجود داشته باشد، ممکن است داده‌های جمع‌آوری‌شده به دلیل توپوگرافی پیچیده زمین، برای تعیین مقدار تبخیر و تعرق مرجع کافی نباشند. در چنین مناطقی دشوار است و خطر کمبود آب را افزایش می‌دهد (مائدا و همکاران، ۲۰۱۱).

روش‌های مرسوم به اندازه‌گیری تبخیر و تعرق (نسبت باون، همبستگی ادی و لایسمتری) پرهزینه و وقت‌گیر هستند و قابل‌تعمیم به سطوح بزرگ نیستند. این روش‌ها تنها می‌توانند میزان تبخیر و تعرق را در یک نقطه یا یک منطقه کوچک تعیین کنند و برای ناحیه‌های وسیع‌تر کاربرد ندارند. در حال حاضر، روش‌های سنجش‌ازدور تنها راه برای به‌دست‌آوردن متغیرهای مختلف در مقیاس‌های زمانی و مکانی موردنیاز به‌منظور برآورد تبخیر و تعرق هستند؛ به‌طوری‌که در سال‌های اخیر، سنجش‌ازدور به‌عنوان یکی از مهم‌ترین ابزارهای برآورد متغیرهای مربوط به مدیریت آبیاری از جمله تبخیر و تعرق شناخته شده است (مو و همکاران، ۲۰۱۱؛ ژانگ و همکاران، ۲۰۱۸). داده‌های سنجش‌ازدور با افزایش قدرت تفکیک مکانی، ابزاری مفید در جهت تهیه اطلاعات در مقیاس‌های مکانی و زمانی مختلف هستند. با استفاده از تکنیک سنجش‌ازدور می‌توان تبخیر و تعرق مرجع را تخمین زد و حتی توزیع مکانی آن را مورد بررسی قرار داد؛ زیرا تنها روشی است که می‌تواند پارامترهای دمایی سطح و شاخصه‌های پوشش گیاهی را به‌صورت منطبق با سازگار با محیط فراهم کند و همچنین از لحاظ اقتصادی مقرون‌به‌صرفه باشد (طباطبایی و همکاران، ۱۳۹۳).

در سالیان اخیر، الگوریتم‌های متعددی برای برآورد تبخیر و تعرق مرجع با استفاده از سنجش‌ازدور ارائه شده است. برخی از این مدل‌ها که بر رابطه بیلان انرژی استوار هستند، روش‌های توازن انرژی سطحی نام دارند. روش‌های مبتنی بر بیلان انرژی بر ترکیب مدل‌های تجربی و فیزیکی با در نظر گرفتن فرضیات ساده‌کننده استوار هستند. به‌طورکلی روش‌هایی که براساس بیلان انرژی عمل می‌کنند، به دو دسته مدل‌های تک منبعی و

تبخیر و تعرق یکی از عوامل مهم بیلان آب در چرخه هیدرولوژی و از جمله عوامل تعیین‌کننده معادلات انرژی در سطح زمین است و برآورد آن در زمینه‌های مختلف علمی همچون هیدرولوژی، کشاورزی، مدیریت جنگل و مرتع و مدیریت منابع آب موردنیاز است (تیکسیرا و همکاران، ۲۰۰۹). تبخیر و تعرق مرجع^۱ (ET_0)، بیانگر تبخیر و تعرق از یک سطح مرجع فرضی است که دارای ویژگی‌های خاص باشد. مهم‌ترین و مرتبط‌ترین کاربرد تبخیر و تعرق مرجع، در زمینه آبیاری است. تبخیر و تعرق مرجع پارامتر کلیدی مورد استفاده برای محاسبه تبخیر و تعرق محصول در شرایط مزرعه است. بسیاری از مطالعات نشان داده است که یک سیستم آبیاری دقیق می‌تواند بهره‌وری آب آبیاری را بهبود بخشد (دو و همکاران، ۲۰۱۰). شرط لازم برای تخمین نیاز بهینه آب برای محصول، ایجاد رابطه بین شرایط آب‌وهوایی و تبخیر و تعرق است (مائدا و همکاران، ۲۰۱۱). تبخیر و تعرق، به‌طورکلی با ضرب ET_0 در ضریب محصول^۲ (k_c) که مخصوص یک محصول خاص در یک دوره رشد خاص مانند کاشت، اواسط فصل و برداشت است به دست می‌آید (استرانگ و همکاران، ۲۰۱۷)؛ بنابراین برآورد دقیق تبخیر و تعرق مرجع اساس سیستم‌های آبیاری کارآمد است.

در دهه‌های گذشته، روش‌های مختلفی برای محاسبه تبخیر و تعرق مرجع ارائه شده است. یکی از روش‌های متعارف تخمین تبخیر و تعرق مرجع که از داده‌های هواشناسی استفاده می‌کنند، معادله پنمن مانتیث فائو است. این معادله به دلیل نتایج رضایت‌بخش، در شرایط مختلف آب‌وهوایی در سراسر جهان مورد استفاده قرار گرفته است (کای و همکاران، ۲۰۰۷؛ گارسیا و همکاران، ۲۰۰۴). با این حال، استفاده از پنمن مانتیث دارای محدودیت‌هایی است، زیرا این روش نیازمند تعداد نسبتاً زیاد داده‌های هواشناسی ذخیره‌شده از ایستگاه‌های زمینی می‌باشد (گاویلان و همکاران، ۲۰۰۶).

گزارش شده است که تعداد و توزیع ایستگاه‌های هواشناسی به توسعه اقتصادی ملی یا محلی و ایجاد شبکه‌های مشاهده هواشناسی بستگی دارد (هیچمنس و همکاران، ۲۰۰۵). روش پنمن مانتیث به دمایی هوا،

1- Reference Evapotranspiration

2- Crop coefficient

طالقان با استفاده از تصاویر مودیس و مدل سبال را بررسی کردند، نتایج نشان داد که مقادیر برآوردی و اندازه‌گیری‌شده از همبستگی $0/88$ برخوردار هستند. کرباسی و همکاران (۱۳۹۵)، میزان تبخیر و تعرق واقعی یونجه و ذرت با استفاده از الگوریتم سبال در منطقه خرم‌دره زنجان مورد مطالعه قرار دادند، نتایج نشان داد مقادیر برآوردی تبخیر و تعرق با استفاده از آمارهای RMSE برای ذرت $0/92$ و یونجه $1/25$ میلی‌متر در روز و میزان همبستگی آن‌ها به ترتیب $0/89$ و $0/83$ با داده‌های واقعی برآورد شده است. مرشدی و همکاران، (۱۳۹۴) تبخیر و تعرق در محدوده دشت شهرکرد با روش سبال برآورد کردند و نتایج حاصل را با روش لایسیمتری و هارگریوز- سامانی به دلیل مناسب بودن با منطقه مطالعه ارزیابی کردند. همچنین به این نکته اشاره کردند که تبخیر و تعرق متغیری است که در طول دوره رشد گیاهان متفاوت بوده و نیاز به سری زمانی کاملی از داده‌های ماهواره‌ای است.

در علم سنجش‌ازدور، همچنین از شاخص‌های پوشش گیاهی برای مسائل مربوط به کشاورزی استفاده می‌شود. این شاخص‌ها علاوه بر در اختیار گذاشتن اطلاعات مکانی از سطح زمین، ارتباط بسیار زیادی با متغیرهای بیوفیزیکی دارند (دجامان و همکاران، ۲۰۱۵؛ اولیویرا و همکاران، ۲۰۱۶؛ توماس-بورگوئرا و همکاران، ۲۰۱۷). تحقیقات زیادی برای برآورد تبخیر و تعرق واقعی، با استفاده از شاخص‌های پوشش گیاهی به دست آمده از تصاویر ماهواره‌ای انجام شده است. در اکثر مطالعات، از سنسور طیف‌سنج تصویربرداری با وضوح متوسط^۵ (MODIS) برای پیش‌بینی تبخیر تعرق در فصول و سال‌های مختلف استفاده شده است. مزیت استفاده از MODIS امکان دستیابی به تصاویر با قدرت تفکیک طیفی متفاوت و قدرت تفکیک مکانی 250 متر است (گلین و همکاران، ۲۰۱۰).

در سال‌های اخیر مدل‌های هوشمند به‌عنوان روش‌های جدید برای مدل‌سازی روابط پیچیده مورد استفاده قرار گرفته‌اند؛ از جمله این روش‌ها، الگوریتم‌های ماشین‌بردار پشتیبان، درخت‌های تصادفی و نظایر آن‌ها است که به‌عنوان روش‌های یادگیری ماشین شناخته شده‌اند و در سایر علوم مهندسی نیز کاربرد زیادی پیدا کرده‌اند.

دو منبعی تقسیم می‌شوند. با توجه به اینکه مدل‌های تک منبعی مجموعه خاک و گیاه را به‌عنوان یک منبع واحد در نظر می‌گیرند، برای شرایطی که پوشش گیاهی کم و یکنواخت است توصیه می‌شود؛ در حالی که مدل‌های دو منبعی خاک و گیاه را جدا از هم و از چندین مقاومت آیرودینامیکی در فرایند انتقال آب - گرما استفاده می‌کنند، برای مناطق با پوشش گیاهی پراکنده توصیه می‌شوند (اسمعیلی و همکاران، ۱۳۹۵). از جمله آن‌ها می‌توان به الگوریتم توازن انرژی سطحی زمین^۱ (SEBAL) (باستیانسین و همکاران، ۱۹۹۸)، ساده‌شده شاخص توازن انرژی سطحی زمین^۲ (S-SEBI) (روبرینک و همکاران، ۲۰۰۰)، سیستم توازن انرژی سطحی^۳ (SEBS) (سو و همکاران، ۲۰۰۲)، نقشه تبخیر و تعرق با واسنجی درونی^۴ (METRIC) (آلن و همکاران، ۲۰۰۷) اشاره کرد. هارونی و همکاران (۱۳۹۴)، تلاش کرده‌اند تا مدل SEBAL در حوزه‌های آبریزاریابی کنند، بدین منظور با استفاده از تصاویرهای ماهواره Terra (سنجنده MODIS) برای دوره زمانی ۲۰۰۲ تا ۲۰۰۸، مقادیر ماهانه تبخیر و تعرق واقعی برآورد شده است. جدیدترین الگوریتم برآورد تبخیر و تعرق با استفاده از تصاویر ماهواره‌ای، الگوریتم METRIC است که با حداقل استفاده از داده‌های زمینی، میزان تبخیر و تعرق را در مقیاس‌های زمانی لحظه‌ای، روزانه و فصلی محاسبه می‌کند. پایه و اساس این الگوریتم را ارتباط بین تشعشعات دریافتی توسط ماهواره‌ها از سطح زمین در باندهای مرئی و مادون‌قرمز حرارتی و همچنین تفاوت هیدرولوژیکی سطوح زمین تشکیل می‌دهد. آلبیدوی سطح، دمای سطح و شاخص‌های پوشش گیاهی مؤلفه‌های کلیدی در این الگوریتم هستند که به‌وسیله داده‌های ماهواره‌ای چندطیفی قابل‌برآورد هستند (اسمعیلی و همکاران، ۱۳۹۵).

ثناپی‌نژاد و همکاران (۱۳۹۰)، در تحقیقی با برآورد تبخیر و تعرق واقعی در منطقه مشهد با استفاده از سنجنده مودیس اثبات‌شده الگوریتم سبال قادر است مقدار تبخیر و تعرق واقعی را در مقیاس روزانه به‌خوبی برآورد کند. نصرتی و همکاران (۱۳۹۴)، تبخیر و تعرق در حوزه آبخیز

1- Surface Energy Balance Algorithm for Land

2- Simplified Surface Energy Balance Index

3- Surface Energy Balance System

4- Mapping Evapotranspiration at high Resolution with Internalized Calibration

5- Moderate Resolution Imaging Spectroradiometer

خاک را دارند. علی و همکاران (۲۰۱۵) یک بررسی جامع در مورد برآورد زیست‌توده و رطوبت خاک از داده‌های ماهواره‌ای انجام دادند و به این موضوع که روش‌های یادگیری ماشین در بیشتر موارد از روش‌های پارامتری بهتر عمل می‌کنند نیز اشاره کردند.

هدف این پژوهش، تخمین تبخیر و تعرق مرجع با استفاده از الگوریتم‌های یادگیری ماشین و داده‌های سنجش‌ازدور و در نهایت تجزیه و تحلیل الگوریتم‌های مورد استفاده است. به‌طور کلی نتایج نهایی برآورد تبخیر و تعرق به عواملی چون نوع داده‌ها و روش مورد نظر برای برآورد تبخیر و تعرق وابسته است. با توجه به این عوامل تأثیرگذار در عملکرد برآورد، لازم است که هر کدام از این عوامل به‌طور مناسب مشخص شوند. در این پژوهش، از چند الگوریتم یادگیری ماشین استفاده شد و در نهایت عملکرد مدل‌ها در برآورد تبخیر و تعرق مرجع مقایسه شد.

مواد و روش‌ها

در این پژوهش، ابتدا تبخیر و تعرق مرجع ایستگاه‌های سینوپتیک از معادله پنمن مانیتث فائو برآورد شد. سپس تبخیر و تعرق مرجع سایر نقاط منطقه نیز از طریق درون‌یابی محاسبه شد. برای آموزش مدل نیاز به ایجاد رابطه پیکسل‌به‌پیکسل تصاویر ماهواره‌ای و تبخیر و تعرق مرجع حاصل از پنمن مانیتث فائو است. از آنجایی که تصاویر ماهواره‌ای زمین مرجع هستند، تصاویر حاصل از رابطه پنمن مانیتث نیز زمین مرجع شدند. ساختار اصلی مدل در شکل ۱ نمایش داده شده است.

منطقه مطالعه

دشت همدان بهار به‌عنوان یکی از دشت‌های ممنوع‌شده از نظر حفاری چاه در استان همدان، بین طول شرقی ۱۷°، ۴۸° تا ۳۳°، ۴۸° عرض شمالی ۴۹°، ۳۴° تا ۲°، ۳۵° واقع شده است. حوزه آبریز دشت مذکور، با ۲۴۱۵ کیلومتر مربع مساحت از زیرحوزه‌های آبریز دریاچه قم است. آبخوان اصلی دشت با وسعت ۵۲۰ کیلومتر مربع در مرکز دشت قرار دارد و ضخامت آبرفت در برخی از مناطق بیش از ۱۰۰ متر است. بیشترین میزان ورودی آب زیرزمینی به محدوده مورد مطالعه، از سمت جنوب غرب صورت می‌گیرد. براساس آمار موجود، بیلان آب‌های زیرزمینی دشت، منفی است. در این منطقه تحقیقات دیگری مربوط

الگوریتم‌های یادگیری ماشین، زیرمجموعه‌ای از هوش مصنوعی به شمار می‌آیند که برای برآورد نیاز به آموزش دارند. این دسته از الگوریتم‌ها، درعین حال که با دقت بالایی پیش‌بینی می‌کنند، متغیرهای ورودی را کاهش می‌دهند. روش‌های یادگیری ماشین با داشتن سری زمانی از داده‌ها روشی دقیق برای تخمین تبخیر و تعرق هستند. الگوریتم‌های یادگیری ماشین، با استفاده از بخشی از داده‌های ورودی که به‌عنوان داده‌های آموزشی معرفی می‌شوند، الگویی را طراحی می‌کنند. به‌منظور کاهش وابستگی به داده‌های اقلیمی و تفکیک‌پذیری بهتر از روش‌های یادگیری ماشین برای محاسبه تبخیر و تعرق استفاده می‌شود. برخی از پژوهشگران با استفاده از الگوریتم یادگیری ماشین و صرفاً داده‌های هواشناسی تبخیر و تعرق را برآورد می‌کنند. یاماک و همکاران (۲۰۲۰) از ترکیب‌های مختلف مجموعه داده‌های ایستگاه هواشناسی و سه الگوریتم یادگیری ماشین برای برآورد تبخیر و تعرق محصول استفاده کردند. با ترکیب داده‌های هواشناسی و سنجش‌ازدور و با استفاده از الگوریتم رگرسیون جنگل تصادفی، تبخیر و تعرق روزانه را برآورد کردند. شاخص سطح برگ و دمای سطح زمین از تصاویر ماهواره‌ای محاسبه شده و همچنین به اهمیت شاخص سطح برگ در این پژوهش برای برآورد تبخیر و تعرق نیز اشاره شده است (دونا و همکاران، ۲۰۲۱). در پژوهشی دیگر، یک مدل فقط براساس داده‌های دما و سرعت باد با استفاده از شبکه‌های عصبی مصنوعی در استرالیا انجام شد که در برآورد تبخیر و تعرق مرجع موفق بود (فلامرزی و همکاران، ۲۰۱۴). فنگ و همکاران (۲۰۱۶) روش یادگیری ماشین شدید^۱ (ELM)، شبکه‌های عصبی مصنوعی بهینه‌سازی شده توسط الگوریتم ژنتیک^۲ (GANN)، شبکه‌های عصبی موجک^۳ (WNN) و مدل‌های تجربی برای تخمین تبخیر و تعرق مرجع با استفاده از چند داده هواشناسی مقایسه کردند و نتایج نشان داد که مدل‌های ELM و GANN دقت قابل‌قبولی دارند. الگوریتم‌های یادگیری ماشین به همراه داده‌های سنجش‌ازدور، توانایی پیش‌بینی متغیرهای بیوفیزیکی را دارند؛ زیرا توانایی پیدا کردن الگو در رفتارهای غیرخطی متغیرهایی مثل تبخیر و تعرق و میزان آب موجود در

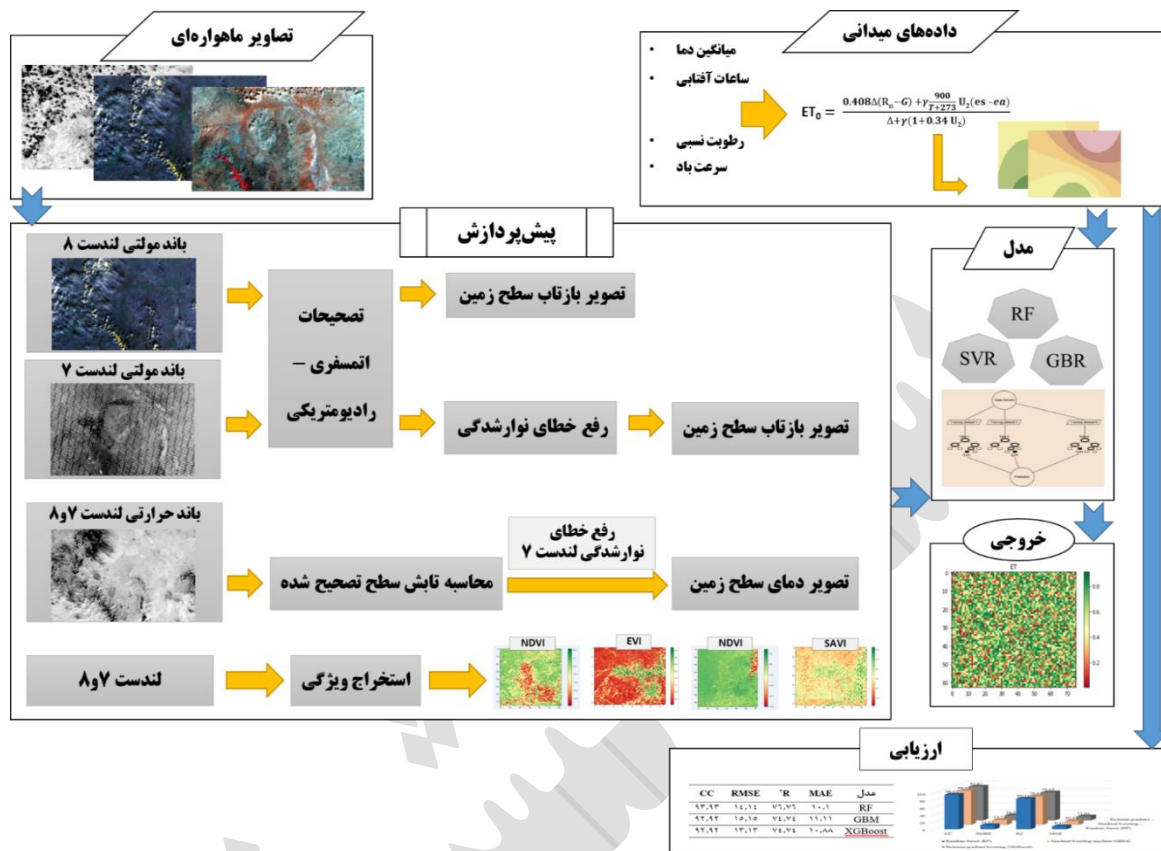
1- Extreme Learning Machine

2- Genetic Algorithm Neural Networks

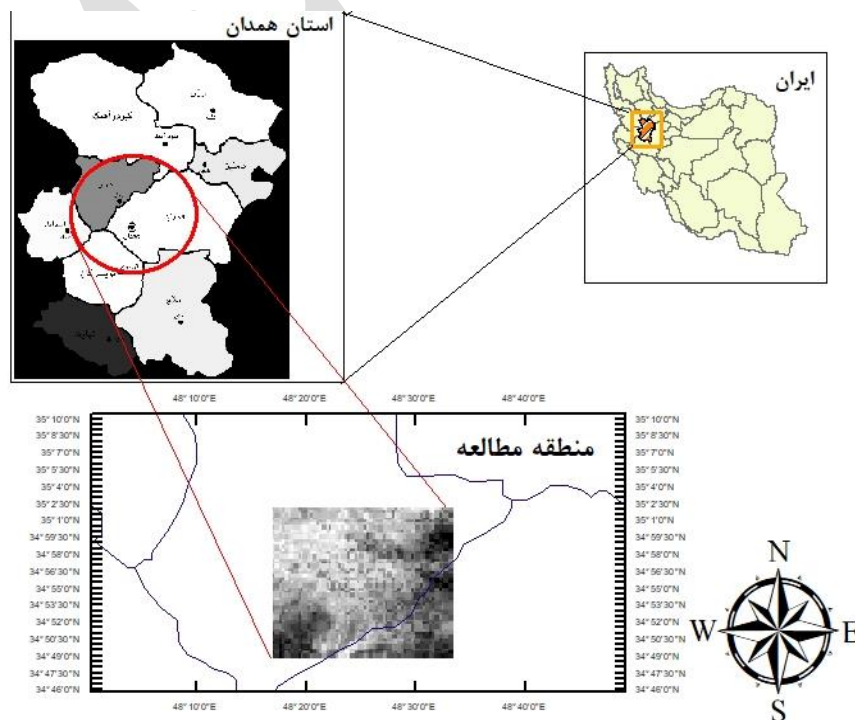
3- Wavelet Neural Networks

همکاران، ۱۳۹۱). موقعیت دشت همدان بهار در استان همدان در شکل ۲ مشخص شده است.

به برآورد تبخیر و تعرق واقعی و پتانسیل با استفاده از تکنیک سنجش از دور صورت گرفته است (امینی بازینی و



شکل ۱- روند کلی برآورد تبخیر و تعرق مرجع



شکل ۲- موقعیت جغرافیایی دشت همدان بهار

داده‌های مورد استفاده

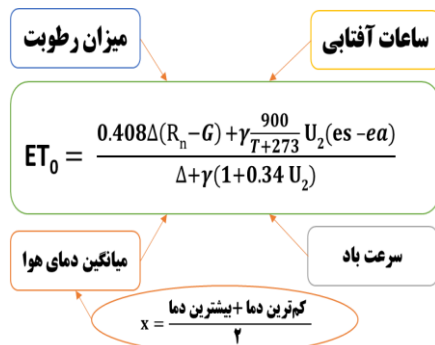
داده‌های مورد استفاده در این تحقیق شامل، تصاویر ماهواره‌ای لندست ۷ و ۸ و داده‌های هواشناسی مربوط به سال‌های ۲۰۰۳ تا ۲۰۱۸ هستند. داده‌های هواشناسی از سازمان هواشناسی ایران که توسط ایستگاه‌های سینوپتیک واقع در استان همدان ذخیره می‌شوند، تهیه شد. تبخیر و تعرق مرجع که با استفاده از داده‌های هواشناسی و روش پنمن مانیتیت فائو برآورد شده، به‌ترتیب به‌عنوان ورودی و خروجی مدل برای آموزش و ارزیابی مورد استفاده قرار می‌گرفت. در صورتی که داده‌های سنجش‌ازدور، ورودی و خروجی مدل فقط برای آموزش هستند.

داده‌های هواشناسی

برای برآورد تبخیر و تعرق مرجع نیاز به داده‌های هواشناسی است. داده‌های هواشناسی که توسط ایستگاه‌های سینوپتیک ذخیره می‌شوند، می‌توان از سازمان هواشناسی تهیه کرد. در این پژوهش از روش استاندارد برآورد تبخیر و تعرق مرجع با داده‌های هواشناسی، معادله پنمن مانیتیت فائو استفاده شد. روش پنمن مانیتیت می‌تواند یک روش بسیار مفید برای محاسبه تبخیر و تعرق مرجع در یک حوزه آبریز با پوشش گیاهی متفاوت باشد (یقینی و همکاران، ۱۳۸۹)؛ بنابراین روش پنمن مانیتیت فائو این امکان را می‌دهد تا بتوان رابطه بسیار معنی‌دارتری بین داده‌های هواشناسی و اقلیمی مختلف از یک سو و شرایط پوشش گیاهی از سوی دیگر را برقرار کرد. همچنین محققان بسیاری در سراسر دنیا روش پنمن مانیتیت فائو را با روش لایسیمتری مقایسه کردند و روش پنمن مانیتیت فائو را به‌عنوان دقیق‌ترین روش برای برآورد تبخیر و تعرق مرجع معرفی کرده‌اند (سیاسر و همکاران، ۱۳۹۹).

داده‌های هواشناسی موردنیاز شامل حداقل و حداکثر دما، حداقل و حداکثر رطوبت، شار گرما به داخل خاک، فشار بخار اشباع، فشار بخار واقعی، شیب منحنی فشار بخار، ضریب ثابت سایکرومتری، تابش خالص ورودی به سطح گیاه، ساعات آفتابی و حداکثر سرعت باد به‌صورت روزانه استفاده شده است. مزیت این داده‌ها داشتن قدرت تفکیک زمانی بالا و بلندمدت است. به‌طور معمول، داده‌های هواشناسی به‌صورت نقطه‌ای هستند. در نتیجه نصب و نگهداری این ایستگاه‌ها پرهزینه هستند و توزیع ایستگاه‌ها

به جمعیت و شرایط اقتصادی بستگی دارد. معادله پنمن مانیتیت به‌صورت شکل ۳ است:



شکل ۳- معادله پنمن مانیتیت و متغیرهای آن

که در آن ET_0 : تبخیر و تعرق گیاه مرجع (mm/d)، R_n : تابش خالص در سطح پوشش گیاهی ($Mj\ m^{-2}\ d^{-1}$)، T : متوسط دمای هوا در ارتفاع دو متری (C)، U_2 : سرعت باد (ms^{-1})، $e_s - e_a$: کمبود فشار بخار (KPa)، Δ : شیب منحنی فشار بخار ($KPa\ C^{-1}$)، γ : ضریب رطوبتی ($KPa\ C^{-1}$) و G : شار گرما به داخل خاک ($Mj\ m^{-2}\ d^{-1}$) است. بعد از آموزش، باید مدل موردنظر ارزیابی شود. در این پژوهش، داده‌های ورودی برای ارزیابی همانند مجموعه داده‌های آموزشی از تصاویر لندست؛ اما در زمان متفاوت هستند. مجموعه داده‌های خروجی برای ارزیابی، تبخیر و تعرق مرجع برآوردشده با معادله پنمن مانیتیت است؛ بنابراین تبخیر و تعرق مرجع محاسبه‌شده از داده‌های سنجش‌ازدور و هواشناسی به‌ترتیب به‌عنوان ورودی و خروجی برای ارزیابی استفاده شد. اگر مدل موردنظر دارای دقت کافی باشد، سپس می‌توان از مدل برای برآورد تبخیر و تعرق مرجع با استفاده از داده‌های سنجش‌ازدور استفاده کرد.

تصاویر سنجش‌ازدور

برای انجام این تحقیق، از تصاویر ماهواره‌ای لندست قابل‌دسترس در سایت سازمان ملی زمین‌شناسی آمریکا بر طبق جدول ۱ استفاده شد. علت استفاده از تصاویر ماهواره‌ای مورد اشاره علاوه بر رایگان بودن، قدرت تفکیک مکانی بالاتر نسبت به سنجنده مودیس و همچنین وجود آسمانی صاف و بدون ابر در منطقه است. داده‌های مورد استفاده برای آموزش مدل موردنظر شامل باندهای مولتی اسپکترال و حرارتی تصاویر لندست ۷ و ۸ و شاخص‌های پوشش گیاهی استخراج‌شده از تصاویر هستند.

جدول ۱- مشخصات داده

ستون	سطر	ساعت	تاریخ	سنجنده
۱۶۶	۳۶	۱۰:۴۶:۳۲	۲۰۰۳/۱/۱۴	ETM+
۱۶۶	۳۶	۱۰:۴۰:۳۱	۲۰۰۶/۸/۱۸	ETM+
۱۶۶	۳۶	۱۰:۴۳:۱۰	۲۰۱۶/۹/۲	OLI
۱۶۶	۳۶	۱۰:۴۱:۱۸	۲۰۱۸/۱۱/۱۵	OLI

پیش‌پردازش

برای تحقیق موردنظر، ۱۷۲ تصویر از محصولات لندست ۷ و ۸ دانلود شد. ماهواره‌های لندست توسط سازمان ملی هوانوردی و فضاوردی آمریکا (ناسا) طراحی و در مدار زمین قرار گرفته‌اند. نسل سوم این ماهواره‌ها با پرتاب لندست ۷ در ۱۵ آوریل ۱۹۹۹ با مجهز شدن به سنجنده‌ای به نام نقشه‌بردار موضوعی پیشرفته^۱ (ETM+) ادامه یافت. نسل جدید سری ماهواره‌های لندست، ماهواره لندست ۸ است که با استفاده از دو سنجنده، یکی سنجنده تصویربردار عملیاتی زمین^۲ (OLI) و دیگری سنجنده مادون قرمز حرارتی^۳ (TIRS) داده‌ها را دریافت می‌کند.

تصاویر مربوط به لندست ۷ و ۸ از سایت سازمان زمین‌شناسی ایالت متحده^۴ (USGS) به صورت رایگان می‌توان تهیه کرد. با حذف کردن تصاویر با پوشش بالای ابر، ۱۱۴ تصویر باقی ماند. اولین تصویر مربوط به تاریخ ۲۰۰۳/۱/۱۴ و آخرین تصویر در ۲۰۱۸/۱۱/۱۵ است. حجم عملیات پیش‌پردازش بسته به نوع سنجنده، کیفیت اطلاعات رقومی و نوع کاربرد متغیر بود. به‌طور کلی تصحیحات به دو دسته تصحیحات رادیومتریکی و اتمسفری تقسیم می‌شوند. همچنین تصاویر لندست ۷ در برخی مناطق شکاف‌هایی (فاقد اطلاعات) نیز دارند. در نتیجه، علاوه بر تصحیحات رادیومتریک و اتمسفری، تصحیحاتی نیز برای پرکردن این مناطق نیاز است. با انجام دادن پردازش‌های مربوط به باندهای حرارتی تصاویر لندست، می‌توان تصاویر دمای سطح زمین را تهیه کرد. پس از پردازش‌ها و جدا کردن منطقه مورد مطالعه، شاخص‌های پوشش گیاهی نظیر^۵ NDVI،^۶ EVI و

SAVI^۷ به ترتیب مطابق با معادله (۱) روس و همکاران (۱۹۷۴)، معادله (۲) ژیانگ و همکاران (۲۰۰۸) و معادله (۳) هیوت (۱۹۸۸) به صورت زیر تعریف می‌شوند:

$$NDVI = \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R} \quad (1)$$

$$EVI = 2.5 * \frac{\rho_{NIR} - \rho_R}{(\rho_{NIR} + 6 * \rho_R - 7.5 * \rho_B + 1)} \quad (2)$$

$$SAVI = \frac{(\rho_{NIR} - \rho_R) + (1 + L)}{(\rho_{NIR} + \rho_R) + L} \quad (3)$$

در این معادلات NIR بازتاب مربوط به باند مادون قرمز نزدیک و R بازتاب مربوط به باند قرمز و B مربوط به باند آبی و L ضریب تعدیل‌کننده خاک است. شاخص پوشش گیاهی NDVI نشان‌دهنده مقدار پوشش گیاهی سطح زمین بوده و به مرحله اولیه فنولوژی حساس است. مقدار این شاخص بین -۱ تا ۱ بوده و هرچه منطقه دارای پوشش گیاهی متراکم‌تر باشد، NDVI مقدار مثبت نزدیک به ۱ اختیار کرده، برای مناطق برفی و ابری این شاخص مقدار پایینی داشته و برای سطوح آبی مقدار منفی خواهد داشت؛ اما شاخص ارتقایافته پوشش گیاهی (EVI) اثرات جوئی و تفاوت در بازتاب‌های آبی و قرمز را به حداقل می‌رساند. از شاخص SAVI برای محاسبه پوشش گیاهی سطح زمین استفاده می‌شود که اثر خاک را در آن تعدیل کرده است. این شاخص تفاوت بسیار کمی با شاخص پوشش گیاهی NDVI دارد. تصاویر پوشش گیاهی مربوط به فصل تابستان و زمستان به ترتیب در شکل ۴ و ۵ نمایش داده شده است. برای بررسی بیشتر تصاویر لندست از منطقه به رنگ حقیقی و کاذب در شکل ۴ و ۵ نیز نمایش داده شده است. همان‌طور که از شکل ۴ مشخص است، این تصاویر مربوط به فصل تابستان است، متناسب با آن، تصویر NDVI که بیانگر میزان پوشش گیاهی است، دارای پوشش گیاهی بیشتری نسبت به تصویر NDVI مربوط به شکل ۵ است و همچنین تصویر دمای سطح زمین مربوط به شکل ۴ گویای بیشتری بودن دما و گرم‌تر بودن نسبت به شکل ۵ است. از آنجایی که شکل ۵

1- Enhanced Thematic Mapper Plus

2- Operational Land Imager

3- Thermal Infrared Sensor

4- United States Geological Survey

5- Normalized Difference Vegetation Index

6- Enhanced Vegetation Index

7- Soil Adjusted Vegetation Index

ارزیابی نتایج

شاخص‌های ارزیابی عملکرد مدل‌ها به‌منظور مقایسه و ارزیابی عملکرد مدل‌های مورد بررسی، از پارامترهای میانگین مربعات خطا (RMSE)، خطای مطلق میانگین (MAE)، ضریب تعیین (R^2) و ضریب همبستگی (CC) استفاده می‌شود. معادله این معیارها در معادلات (۴) تا (۷) به‌صورت زیر تعریف می‌شوند:

$$RMSE = \left(\frac{1}{N} \sum_{i=1}^N (\rho_i - O_i)^2 \right)^{0.5} \quad (4)$$

$$\frac{1}{N} \sum_{i=1}^N |\rho_i - O_i| = MAE \quad (5)$$

$$R^2 = \frac{[\sum_{i=1}^N (\rho_i - \bar{\rho})(O_i - \bar{O})]^2}{\sum_{i=1}^N (\rho_i - \bar{\rho})^2 \sum_{i=1}^N (O_i - \bar{O})^2} \quad (6)$$

$$CC = \frac{\sum_{i=1}^N (O_i - \bar{O})(\rho_i - \bar{\rho})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^N (\rho_i - \bar{\rho})^2}} \quad (7)$$

در معادلات فوق، N تعداد مشاهدات، P_i تبخیر و تعرق مرجع برآوردشده با استفاده از الگوریتم یادگیری ماشین، O_i تبخیر و تعرق مرجع محاسبه‌شده با استفاده از معادله پنمن مانیتث فائو، $\bar{\rho}$ میانگین تبخیر و تعرق مرجع برآوردشده و \bar{O} میانگین تبخیر و تعرق مرجع محاسبه‌شده هستند.

هرچه مقدار RMSE کمتر باشد، عملکرد مدل بهتر بوده و در شرایطی که مقادیر برآوردشده با مقادیر واقعی برابر باشند، مقدار آن صفر خواهد شد. آماره MAE شاخصی است که از مقایسه مقادیر پیش‌بینی‌شده توسط مدل و مقادیر واقعی به دست می‌آید؛ به‌طوری‌که مقدار نزدیک به صفر بیان‌کننده آن است که متوسط مقادیر برآوردشده و واقعی مشابه هستند. ضریب تعیین R^2 بیان‌کننده مقادیر از واریانس موجود در مقادیر واقعی است که توسط مقادیر پیش‌بینی‌شده توضیح داده شد. مقادیر R^2 بالاتر نشان‌دهنده عملکرد بهتر مدل است. پارامترهای RMSE و MAE هم‌بند با پارامترهایی هستند که از آن‌ها به دست آمده‌اند و R^2 بدون‌بند است.

در بررسی و قیاس روش‌های مختلف رگرسیونی، یک رویکرد تحلیلی بررسی روشی است که برآوردها را با صحت بیشتری انتخاب می‌کند. با این‌وجود، هر اختلافی معنی‌دار نیست و از این‌رو آزمون‌های آماری درجهت سنجش معنی‌داری موردنیاز است. آزمون مک‌نمار ۴ یکی

مربوط به فصل زمستان است و در فصل زمستان با کاهش دما میزان پوشش گیاهی کم می‌شود، در نتیجه میزان تبخیر و تعرق نیز کاهش یافته است.

مدل‌های مورد استفاده

برای آموزش مدل‌ها از سه الگوریتم یادگیری ماشین، درخت‌های تصادفی^۱ (RF)، رگرسیون تقویت‌گرایان^۲ (GBR)، رگرسیون بردار پشتیبان^۳ (SVR) استفاده شد. درخت‌های تصادفی یکی از روش‌های یادگیری ماشین است که کلاسه‌بندی و رگرسیون را با استفاده از روش‌های خود راه‌انداز (Bootstrap) و بسته‌بندی کردن (Bagging) انجام می‌دهد (یقینی و همکاران، ۱۳۸۹). در روش درخت‌های تصادفی، درخت‌های تصمیم‌گیری زیادی با ورودی متفاوت از هم که به‌صورت تصادفی از میان داده‌های آموزشی انتخاب کرده‌اند، ساخته شده است. در صورت لزوم، برای دستیابی به توزیع مناسب نمونه‌های آموزشی، نمونه‌برداری مجدد به روش خود راه‌انداز (Bootstrap) انجام می‌شود. برای توسعه مدل درخت‌های تصادفی، مدل رگرسیون تقویت‌گرایان (GBR) می‌تواند جایگزین کرد که از روش بوستینگ به‌جای بگینگ استفاده می‌کند. روش بوستینگ، میزان کارایی و عملکرد پیش‌بینی هر نمونه را در طول دوره آموزش در نظر می‌گیرد.

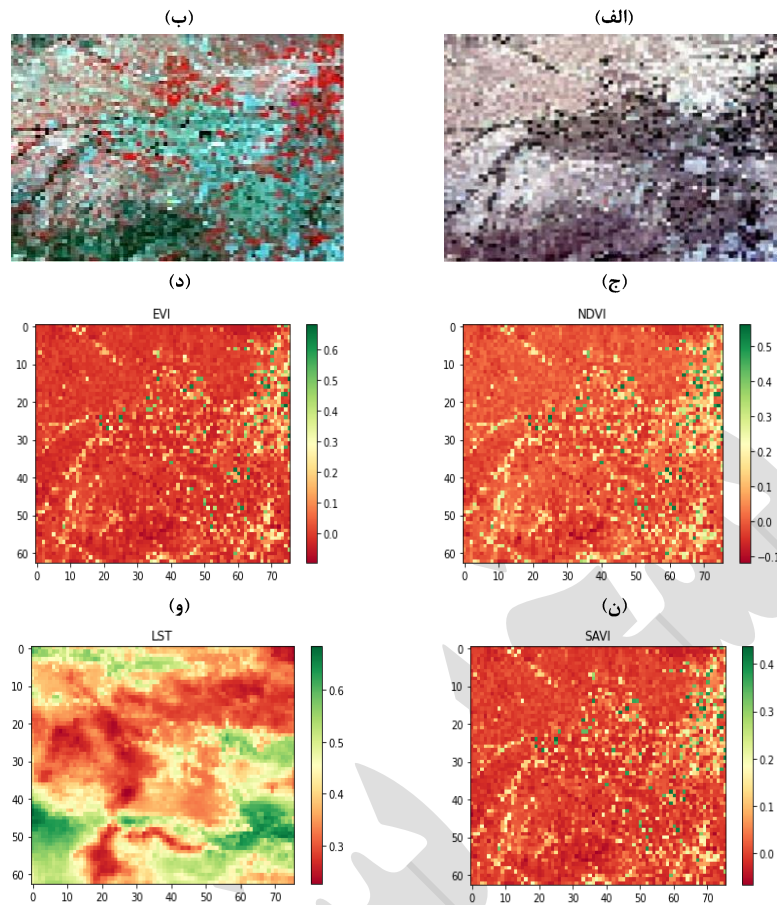
الگوریتم یادگیری ماشین اولین‌بار توسط وپنیک (۲۰۱۳) برای طبقه‌بندی استفاده شده و در حل مسائل پیش‌بینی در سال‌های اخیر به‌طور قابل‌توجهی با عنوان رگرسیون بردار پشتیبان کاربرد داشته است (هاروی، ۲۰۱۴). رگرسیون بردار پشتیبان جز روش‌های یادگیری نظارت شده است که روابط غیرخطی بین داده‌های ورودی و خروجی را در یک بُعد بالاتر آموزش‌دیده و در نهایت مدل‌سازی می‌کند.

در این پژوهش از سه الگوریتم یادگیری ماشین استفاده و پس از بررسی نتایج، مناسب‌ترین مدل مشخص شده است. تعداد درختان تصمیم‌گیری، نوع کرنل و تعداد متغیرهای لازم برای جداسازی شاخه درختان، ابر پارامترهای مهم برای بهینه‌سازی مدل‌ها هستند.

1- Random Forest

2- Gradient Boosting Regressor

3- Support Vector Regression



شکل ۵- نمایش منطقه مطالعه و شاخص‌های پوشش گیاهی مختلف مربوط به فصل زمستان

تصویر رنگ حقیقی از منطقه (شکل الف) تصویر رنگ کاذب از منطقه (ب) تصویر شاخص نرمال شده تفاوت پوشش گیاهی (شکل ج) تصویر شاخص پیشرفته پوشش گیاهی (شکل د) تصویر شاخص گیاهی تعدیل کننده اثر خاک (شکل ن) تصویر دمای سطح زمین (کلونین) (شکل و)

نتایج و بحث

برآورد تبخیر و تعرق مرجع با شاخص‌های پوشش گیاهی

پس از آموزش مدل‌های یادگیری ماشین توانایی پیش‌بینی دارند. ابتدا از شاخص‌های پوشش گیاهی برای مقایسه بین تبخیر و تعرق مرجع برآورد شده با روش‌های رگرسیونی و روش پنمن مانیتث فائو استفاده شده است. مدل‌های رگرسیونی با داده‌های شاخص پوشش گیاهی

از این پس به ترتیب RFV، GBRV و SVRV نامیده می‌شوند. با توجه به جدول ۲، CC مربوط به مدل RFV نسبت به دو مدل دیگر بیشتر است؛ در حالی که دارای RMSE کمتری نسبت به دو مدل دیگر است. در نتیجه این مدل با توجه به داده‌های ورودی و در ایستگاه‌های استان همدان دقت بیشتری داشته و برآورد دقیق‌تری نسبت به دو مدل دیگر برای تبخیر و تعرق مرجع دارد.

جدول ۲- مقادیر معیارهای ارزیابی الگوریتم یادگیری ماشین با استفاده از شاخص‌های پوشش گیاهی

مدل	MAE	R ²	RMSE	CC
RFV	۰/۱۰۴۴	۰/۷۶۴۲	۰/۱۴۱۴	۰/۹۴۵۰
GBRV	۰/۱۱۲۳	۰/۷۴۱۹	۰/۱۴۸۰	۰/۹۲۸۱
SVRV	۰/۱۲۲۷	۰/۶۹۵۵	۰/۱۶۰۷	۰/۹۱۳۵

برآورد تبخیر و تعرق مرجع با داده‌های لندست

در این قسمت از همه مقادیر باندهای تصاویر لندست ۷ و ۸ به عنوان ورودی مدل مورد نظر برای برآورد تبخیر و

تغرق مرجع استفاده شد. بعد از آموزش، مدل‌ها به ترتیب SVRL، GBRL و RFL نام‌گذاری شده‌اند. سپس اعتبارسنجی برای ارزیابی مدل‌های آموزش دیده انجام شد.

برآورد خیلی نزدیکی با داده‌های حاصل از پنمن مانیتث فائو دارد و درنهایت با توجه به نتایج به‌دست‌آمده از دو رویکرد مورد استفاده در این پژوهش، با به‌کارگیری مقادیر همه باند‌های لندست، تبخیر و تعرق مرجع را می‌توان بادقت بالاتری برآورد کرد.

دقت ارزیابی سه مدل به هم خیلی نزدیک بود؛ درحالی‌که درخت‌های تصادفی نسبت به دو مدل باقی‌مانده، مقداری عملکرد بهتر داشت (جدول ۳). در شکل ۶ با توجه به دقت مدل RFL می‌توان دریافت که این مدل با داشتن، R^2 برابر با ۰/۸۴۱، MAE برابر با ۰/۰۸۴، RMSE برابر با ۰/۱۱۶۹ و CC برابر با ۰/۹۵۷،

جدول ۳- مقادیر معیارهای ارزیابی الگوریتم یادگیری ماشین با استفاده از باند‌های تصاویر لندست

مدل	MAE	R^2	RMSE	CC
RFV	۰/۰۸۴۳	۰/۸۴۱۴	۰/۱۱۶۹	۰/۹۵۷۷
GBRV	۰/۱۰۸۷	۰/۷۷۱۲	۰/۱۳۹۳	۰/۹۳۷۳
SVRV	۰/۱۰۰۶	۰/۷۹۶۹	۰/۱۳۱۳	۰/۹۴۴۸

به تفاوت صحت برآوردهای حاصل از مدل‌ها اطمینان حاصل کرد.

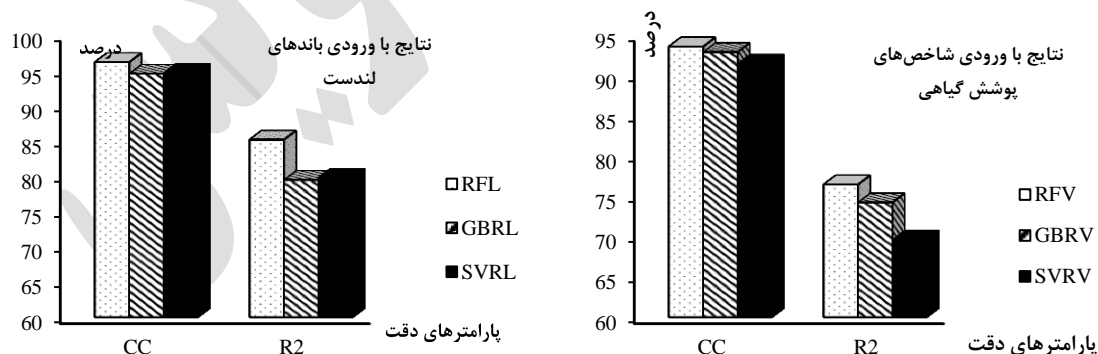
در جدول ۴ و ۵ وابستگی آماری بین مدل‌های رگرسیونی ارائه شده است. با توجه به نتایج ارائه‌شده در جداول ۴ و ۵ می‌توان وابسته‌نبودن مدل‌ها نسبت به هم را نتیجه گرفت و

جدول ۴- وابستگی آماری بین مدل‌ها با شاخص پوشش گیاهی

وابستگی آماری	الگوریتم‌ها
۶/۷۲	GBRV و RFV
۵/۵۹	SVRV و GBRV
۶/۳۲	RFV و SVRV

جدول ۵- وابستگی آماری بین مدل‌ها با داده‌های تصویر لندست

وابستگی آماری	الگوریتم‌ها
۸/۳۷	GBRL و RFL
۶/۶۴	SVRL و GBRL
۷/۴۸	RFL و SVRL




شکل ۶- دقت مدل‌های رگرسیون با مقادیر مختلف

می‌شود- دارند؛ در نتیجه می‌توان به داشتن پتانسیل و کارایی داده‌های سنجنش‌ازدور در برآورد تبخیر و تعرق مرجع پی برد. در پژوهشی از مدلی که براساس داده‌های دمای سطح زمین حاصل از تصاویر مودیس است، برای

باتوجه به نتایجی که در این پژوهش ارائه شد، مدل‌های برآورد تبخیر و تعرق مرجع با استفاده از مقادیر همه باند‌های تصاویر لندست، برآورد دقیق‌تری نسبت به شاخص‌های پوشش گیاهی - که فقط شامل چند باند

تبخیر و تعرق مرجع را در نظر نگرفته و ضریب همبستگی حدود ۰/۶۷ را به دست آوردند (مائدا و همکاران، ۲۰۱۱). همان‌طور که مشخص است، به‌کارگیری مقادیر همه باندهای تصاویر لندست برآورد دقیق‌تری نسبت به سایر روش‌ها دارد.

برآورد تبخیر و تعرق مرجع استفاده کردند. هدف این پژوهش، به‌کاربردن دمای سطح زمین حاصل از تصاویر ماهواره‌ای به جای متغیر دمای هوا بوده و روشی مناسب برای تخمین تبخیر و تعرق مرجع بدون استفاده از داده‌های هواشناسی شناخته شد. درحالی‌که این مدل، رابطه پیچیده بین دمای هوا و دمای سطح زمین و حتی



شکل ۷- خطا مدل‌های رگرسیون با مقادیر مختلف

مناطق در مقیاس بسیار کوچک هستند و به دلیل طبیعت پویا و تغییرات مکانی تبخیر و تعرق قابل‌تعمیم به حوزه‌های آبریز بزرگ نیستند. درحال‌حاضر، روش‌های سنجش‌ازدور تنها راه غیرزمینی به‌دست‌آوردن متغیرهای مختلف در مقیاس‌های زمانی و مکانی موردنیاز به‌منظور برآورد تبخیر و تعرق مرجع هستند. با توجه به تغییرات پارامترهای هواشناسی و درنهایت تغییر تبخیر و تعرق مرجع، استفاده از روش‌هایی از جمله روش‌های مبتنی بر سنجش‌ازدور که این تغییرات را در نظر می‌گیرند، مطلوب است. به‌منظور کاهش وابستگی به داده‌های اقلیمی و تفکیک‌پذیری بهتر از روش‌های یادگیری ماشین برای محاسبه تبخیر و تعرق مرجع استفاده می‌شود. روش‌های یادگیری ماشین با ایجاد کردن نمایشی دیگر از داده‌ها، مناسب‌تر از سایر روش‌ها، کلاسه‌بندی و برآورد می‌کنند؛ بنابراین در این پژوهش از مدل‌های RF، GBR و SVR استفاده شده است. در پژوهش حاضر از دو رویکرد استفاده شده است؛ رویکرد اول، مقادیر همه باندهای تصاویر لندست به‌عنوان ورودی مدل هستند، درحالی‌که در رویکرد دوم، فقط با چند باند از تصاویر لندست، شاخص‌های پوشش گیاهی محاسبه شده و سپس به‌عنوان ورودی مدل معرفی شده‌اند. با کاربرد همه باندهای تصاویر، RF (RMSE=۰/۱۱۶۹ و $R^2=۰/۸۴۱۴$) نسبت به مدل GBR (RMSE=۰/۱۳۹۳ و $R^2=۰/۷۷۱۲$) و مدل

دقت مدل مورد استفاده در این پژوهش، وابسته به تعداد و توزیع ایستگاه‌های هواشناسی و کیفیت داده‌های سنجش‌ازدور است. ابرها بر کیفیت تصاویر ماهواره‌ای تأثیر گذاشته و بنابراین با وجود آسمان صاف و بدون ابر، مدل مورد نظر با دقت بیشتری برآورد می‌کند. تعداد و توزیع ایستگاه‌های هواشناسی در پروسه آموزش و درنهایت دقت مدل، تأثیر می‌گذارد. کمبود ایستگاه‌های هواشناسی، تعداد و توزیع داده‌ها را محدود می‌کند و در نتیجه با افزایش ایستگاه‌های هواشناسی، دقت مدل نیز افزایش می‌یابد. قابل توجه است که در این پژوهش با تعداد هفت ایستگاه هواشناسی در منطقه کل استان همدان مدل دقت مناسبی داشته که نشان می‌دهد الگوریتم‌های یادگیری ماشین می‌توانند از داده‌های ایستگاه هواشناسی موجود حداکثر استفاده را ببرند. با توجه به موارد تأثیرگذار بر دقت، میزان خطا مربوط به مدل‌های مورد استفاده در شکل ۷ ارائه شده است.

نتیجه‌گیری

پیش‌بینی دقیق تبخیر و تعرق مرجع برای برآورد نیاز آبیاری و به‌طور کلی برای مدیریت دقیق منابع آب ضروری است. روش‌های مرسوم اندازه‌گیری تبخیر و تعرق مرجع با استفاده از داده‌های هواشناسی هستند که این اندازه‌گیری‌ها به‌صورت نقطه‌ای است؛ بنابراین فقط مناسب

SVR ($R^2=0/7969$ و $RMSE=0/1313$) عملکرد بهتری دارد. همچنین در رویکرد دوم، با کاربرد شاخص‌های پوشش گیاهی، RF ($R^2=0/7642$ و $RMSE=0/1414$) نیز نسبت به مدل GBR ($R^2=0/7419$ و $RMSE=0/148$) و مدل SVR ($R^2=0/6955$ و $RMSE=0/1607$) بهترین عملکرد آماری را ارائه داده و برای برآورد تبخیر و تعرق مرجع در منطقه مورد مطالعه مناسب‌ترین است. با بررسی می‌توان دریافت که اطلاعات حاصل از باندهای تصاویر لندست، مربوط به رفتار فنولوژیکی محصولات هستند و همچنین می‌توان اطلاعات بسیار مرتبطی با محصولات کشاورزی که به صورت زمانی و مکانی مورد بررسی قرار می‌گیرند، ارائه داد. از عوامل تأثیرگذار بر دقت برآورد تبخیر و تعرق مرجع، می‌توان به استفاده از سایر باندهای لندست علاوه بر باندهای مربوط به شاخص‌های پوشش گیاهی اشاره کرد. پیشنهاد می‌شود در پژوهش‌های آتی با توجه به محدود بودن تصاویر لندست به دلیل پوشش ابر، تلفیقی از تصاویر مودیس استفاده شود.

منابع

۱. اسمعیلی س. ۱۳۹۵. برآورد تبخیر و تعرق با استفاده از تصاویر ماهواره‌ای تحت شرایط مختلفی از موجودیت داده‌های زمینی. پایان‌نامه کارشناسی ارشد. دانشگاه کردستان. ۱۳۱ ص.
۲. امینی باستانی س. ۱۳۹۱. برآورد تبخیر و تعرق واقعی و پتانسیل در دشت همدان- بهار با استفاده از تکنیک سنجش‌ازدور. پایان‌نامه کارشناسی ارشد. دانشگاه بوعلی‌سینا. ۹۸ ص.
۳. ثنائی‌نژاد ح. نوری س. هاشمی‌نیا م. ۱۳۹۰. برآورد تبخیر و تعرق واقعی با استفاده از تصاویر ماهواره‌ای در منطقه مشهد. نشریه آب و خاک. ۲۵(۳): ۵۴۰-۵۴۲.
۴. سیاسر ه. دیندارلو ع. ۱۳۹۹. تخمین تبخیر و تعرق مرجع روزانه به کمک مدل یادگیری عمیق، جنگل تصادفی و درخت تصمیم (مطالعه موردی: دشت سیستان). نشریه پژوهش آب ایران. ۶۷(۲): ۹۹-۱۰۸.
۵. طباطبایی س. ۱۳۹۳. کاربرد سنجش‌ازدور در برآورد تبخیر- تعرق واقعی به روش سبال (مطالعه موردی: دشت مغان). پایان‌نامه کارشناسی ارشد. دانشگاه تبریز. ۱۲۲ ص.
۶. کرباسی م. مقدم م. نیکبخت ج. کاویانی ع. ۱۳۹۵. تخمین تبخیر تعرق واقعی گیاه با استفاده از الگوریتم سبال (مطالعه موردی: منطقه خرم‌دره در استان زنجان). نشریه آکو هیدرولوژی. ۳(۳): ۴۲۷-۴۳۷.
۷. مرشدی ع. طباطبائی ح. و نادری م. ۱۳۹۴. صحت‌سنجی برآورد تبخیر و تعرق از مدل‌های سبال و هارگریوز- سامانی با استفاده از داده‌های لایسیمتر. نشریه آب و خاک. ۳۰(۲): ۳۶۷-۳۷۶.
۸. نصرتی ک. محسنی س. احمدی ح. و عقیقی ح. ۱۳۹۴. برآورد تبخیر و تعرق در حوضه آبخیز طالقان با استفاده از تصاویر مودیس و مدل سبال. نشریه مرتع و آبخیزداری. ۶۸(۲): ۳۸۵-۳۹۸.
۹. هارونی م. ح. مرید س. و ارشد ص. ۱۳۹۴. ارزیابی الگوریتم سنجش‌ازدور سبال در برآورد تبخیر و تعرق واقعی در کاربری‌های مختلف (مطالعه موردی: حوضه دریاچه ارومیه). نشریه پژوهش آب ایران. ۶۸(۲): ۱۰۱-۱۰۲.
۱۰. یقینی ف. ۱۳۸۹. بررسی تأثیر نسبی عوامل آگرو اقلیمی در میزان تبخیر و تعرق واقعی گندم با استفاده از شبکه‌های عصبی در شهرستان خاتم یزد. پایان‌نامه کارشناسی ارشد. دانشگاه یزد. ۱۱۴ ص.
11. Ali I. Greifeneder F. Stamenkovic J. Neumann M. and Notarnicola C. 2015. Review of machine learning approaches for biomass and soil moisture retrievals from remote sensing data. *Remote Sensing*. 7(12): 16398-16421.
12. Allen RG. Tasumi M. and Trezza R. 2007. Satellite-based energy balance for mapping evapotranspiration with internalized calibration (METRIC)—Model. *Journal of irrigation and drainage engineering* 133(4): 380-394.
13. Bastiaansen W. Menenti M. Feddes R. A. and Holtslag A. A. M. 1998. A remote sensing surface energy balance algorithm for land (SEBAL). *Journal of Hydrology*. 64: 198-213.
14. Cai J. Liu Y. Lei T. and Pereira LS. 2007. Estimating reference evapotranspiration with the FAO Penman-Monteith equation using daily weather forecast messages. *Agricultural and forest meteorology*. 145(1-2): 22-35.
15. Djaman K. Balde AB. Sow A. and Muller B. 2015. Evaluation of sixteen reference evapotranspiration methods under sahelian conditions in the Senegal River Valley. *Journal of Hydrology: regional studies*. 3: 139-159.
16. Droogers P. and Allen RG. 2002. Estimating reference evapotranspiration under inaccurate data conditions. *Irrigation and drainage systems*. 16(1): 33-45.

- image interpretation via knowledge based system capabilities. *Multimedia Tools and Applications*. 80(16): 24901-24924.
30. Maeda E. Wiberg D. and Pellikka P. 2011. Estimating reference evapotranspiration using remote sensing and empirical models in a region with limited ground data availability in Kenya. *Applied Geography*. 31(1): 251-258.
 31. Mu Q. Zhao M. and Running S. 2011. Improvements to a MODIS global terrestrial evapotranspiration algorithm. *Remote Sensing of Environment*. 115(8): 1781-1800.
 32. Oliveira T. Ferreira E. Dantas A. 2016. Temporal variation of normalized difference vegetation index (NDVI) and calculation of the crop coefficient (Kc) from NDVI in areas cultivated with irrigated soybean. *Ciência Rural*. 46(9): 1683-1688.
 33. Roerink G. Su Z. and Menenti M. 2000. S-SEBI: A simple remote sensing algorithm to estimate the surface energy balance. *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*. 25(2): 147-157.
 34. Rouse J. Haas R. and Schell J. 1974. Monitoring vegetation systems in the Great Plains with ERTS. NASA special publication. 351pp.
 35. Strong C. Khatri K. and Kochanski A. 2017. Reference evapotranspiration from coarse-scale and dynamically downscaled data in complex terrain: Sensitivity to interpolation and resolution. *Journal of Hydrology*. 548(1): 406-418.
 36. Su Z. 2002. The Surface Energy Balance System (SEBS) for estimation of turbulent heat fluxes. *Hydrology and earth system sciences*. 6(1): 85-99.
 37. Teixeira A. Bastiaanssen W. and Ahmad M. 2009. Reviewing SEBAL input parameters for assessing evapotranspiration and water productivity for the Low-Middle Sao Francisco River basin, Brazil: Part A: Calibration and validation. *Agricultural and forest meteorology*. 149(3-4): 462-476.
 38. Tomas-Burguera M. Sergio M. Vicente-Serrano M. and Beguería S. 2017. Accuracy of reference evapotranspiration (ET_o) estimates under data scarcity scenarios in the Iberian Peninsula. *Agricultural water management*. 182(1): 103-116.
 39. Yamac SS. and Todorovic M. 2020. Estimation of daily potato crop evapotranspiration using three different machine learning algorithms and four scenarios of available meteorological data. *Agricultural Water Management*. 228(1): 1-12.
 40. Zhang Z. Gong Y. and Wang Z. 2018. Accessible remote sensing data based reference evapotranspiration estimation modelling. *Agricultural Water Management*. 210(1): 59-69.
 17. Douna V. Barraza V. Grings F. and Huete A. 2021. Towards a remote sensing data based evapotranspiration estimation in Northern Australia using a simple random forest approach. *Journal of Arid Environments*. 191(1):1-15.
 18. Du T. Kang S. Sun J. Zhang X. and Zhang J. 2010. An improved water use efficiency of cereals under temporal and spatial deficit irrigation in north China. *Agricultural water management*. 97(1): 66-74.
 19. Falamarzi Y. Palizdan N. Huang YF. and Lee TS. 2014. Estimating evapotranspiration from temperature and wind speed data using artificial and wavelet neural networks (WNNs). *Agricultural Water Management*. 140: 26-36.
 20. Feng Y. Cui N. Zhao L. Hu X. and Gong D. 2016. Comparison of ELM, GANN, WNN and empirical models for estimating reference evapotranspiration in humid region of Southwest China. *Journal of Hydrology*. 536: 376-383.
 21. Foody G. M. 2004. Thematic map comparison. *Photogrammetric Engineering Remote Sensing*. 70(5): 627-633.
 22. Garcia M. Raes D. Allen R. and Herbas C. 2004. Dynamics of reference evapotranspiration in the Bolivian highlands (Altiplano). *Agricultural and forest meteorology*. 125(1-2): 67-82.
 23. Gavilán P. Lorite I. Tornero S. and Berengena J. 2006. Regional calibration of Hargreaves equation for estimating reference ET in a semiarid environment. *Agricultural water management*. 81(3): 257-281.
 24. Glenn E. Nagler P. and Huete A. 2010. Vegetation index methods for estimating evapotranspiration by remote sensing. *Surveys in Geophysics*. 31(6): 531-555.
 25. Harvey R. and McBean E. 2014. Comparing the utility of decision trees and support vector machines when planning inspections of linear sewer infrastructure. *Journal of Hydroinformatics*. 16(6): 1265-1279.
 26. Hijmans R. Cameron S. Parra P. G. Jones and Jarvis A. 2005. Very high resolution interpolated climate surfaces for global land areas, *International Journal of Climatology: A Journal of the Royal Meteorological Society*. 25(15): 1965-1978.
 27. Huete, A. R. 1988. A soil-adjusted vegetation index (SAVI). *Remote sensing of environment* 25(3): 295-309.
 28. Jiang Z. Huete A. Didan K. and Miura T. 2008. Development of a two-band enhanced vegetation index without a blue band. *Remote sensing of environment*. 112(10): 3833-3845.
 29. Kiani A. Ahmadi F. and Ebadi H. 2021. Correction of training process in object-based

Research paper

Estimation of reference evapotranspiration using remote sensing data in Hamedan-Bahar Plain

Z. Niasti¹, H. Ebadi² and A. Kiani^{3*}

Extended Abstract

Reference evapotranspiration (ET₀) is a major research area of both hydrology and water resources management. The most important and direct application of ET₀ is in the field of irrigation. One of the conventional methods for estimating reference evapotranspiration using meteorological data is the Penman-Monteith-FAO equation. This equation due to satisfactory results has been used in a variety of climates around the world. However, the lack of necessary meteorological data makes it difficult to estimate spatially distributed ET₀ using the FAO-PM method in the wider ungauged areas. Penman Monteith method requires the data of air temperature, wind speed, relative humidity, solar radiation and etc. To overcome the existing limits of the FAO-PM model, various attempts aiming to estimate ET₀ with limited observed data have been conducted. Remote sensing methods are already the only way to obtain the various variables at the temporal and spatial scales that needed to estimate evapotranspiration. In recent years, several algorithms have been proposed to estimate reference evapotranspiration using remote sensing data. Some of these models, which are based on the relationship of energy balance, are called surface energy balance methods. In addition to remote sensing, data analysis techniques based on machine learning (ML) are more frequently used in agricultural studies in recent years, especially in evapotranspiration. Therefore, analyses performed with ML algorithms, when coupled with remote sensing data, have the potential to predict the biophysical variables, mainly due to the adaptive capacity of the models to find patterns in nonlinear behavior variable, such as ET₀. Machine learning methods are well known and have been widely used in other engineering sciences. The purpose of this study is to estimate the reference evapotranspiration using machine learning algorithms and remote sensing data, and finally to analyze the algorithms used. In general, the final results of evapotranspiration estimation depend on factors such as the type of data and the method for estimating evapotranspiration.

In this study, the standard method of estimating ET₀ with meteorological data, Penman-Monteith FAO equation was used. The NDVI vegetation index indicates the amount of vegetation on the ground and is sensitive to the early stages of phenology. But the enhanced vegetation index (EVI) minimizes atmospheric effects and differences in blue and red reflections. The SAVI index is used to calculate the vegetation of the land surface that has moderated the effect of soil on it. Three machine learning algorithms were introduced to train the ET₀ models, including random forest (RF), gradient boosting regressor (GBR) and support vector regression (SVR). Random forest is one of the machine learning methods that performs classification and regression using Bootstrap and Bagging methods. In this research,

1- Master student of Remote Sensing, Department of Surveying, Khajeh Nasir Toosi University of Technology, Iran.

2- Professor, Department of Surveying Engineering, Member of the Scientific Center of Spatial Information Technology, Khajeh Nasir Toosi University of Technology, Iran.

3- Assistant Professor, Department of Geomatics Faculty of Civil Engineering, Noshirvani University of Technology, Babol, Iran.

* Corresponding Author: a.kiani@nit.ac.ir

Received: 2021/04/26

Accepted: 2021/09/18

three machine learning algorithms with different input data (vegetation indices and all bands of Landsat 7 and 8) were used and after comparing the results, the best model was selected. Performance Evaluation Indicators considered to compare and evaluate the performance of the studied models were the parameters of mean square error (RMSE), mean absolute error (MAE), coefficient of determination (R²) and correlation coefficient (CC). Finally, according to the results of the two approaches used in this study, using the values of all Landsat bands, the reference evapotranspiration can be estimated with more accuracy.

Accurate estimating of reference evapotranspiration is necessary to estimate irrigation needs and in general, to accurately manage water resources. Conventional methods of measuring evapotranspiration are reference using meteorological data. These measurements are point-based, so they are only suitable for very small scale areas. At present, remote sensing methods are the only non-terrestrial way to obtain the various variables at the temporal and spatial scales needed to estimate reference evapotranspiration. In order to reduce the dependence on climatic data and better resolution, machine learning methods are used to calculate the reference evapotranspiration. In this research, RF, GBR and SVR models were used. In the present study, two approaches were used. In the first approach, the values of all bands of Landsat images were as model input; while in the second approach, vegetation indices were calculated with only a few bands of Landsat images and then used as model inputs. By examining, it could be seen that the information obtained from the Landsat image bands is related to the phenological behavior of the products, and it is also possible to contract very relevant information related to agricultural products that are examined temporarily and spatially. One of the factors influencing the accuracy of estimating reference evapotranspiration is the use of other Landsat bands in addition to the bands related to vegetation indices.

Keywords: Evapotranspiration, Remote Sensing Vegetation indices, Water management, Machine learning.

Citation: Niasti Z. Ebadi H. and Kiani A. 2022. Estimation of reference evapotranspiration using remote sensing data in Hamedan-Bahar Plain. Iranian Water Research Journal.