

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

زینب نیاستی^۱ و 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 مانیت 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=۱۴/۱٪ و R2=۷۶/۴٪) داشت؛ درحالی‌که با استفاده از همه باندهای لندست (RMSE=۱۱/۷٪ و R2=۸۴/۱٪) 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 به‌تهایی 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. عبادی، ح. و کیانی، ع. ۱۴۰۰. برآورد تبخیر و تعرق مرجع با استفاده از داده‌های سنجش‌ازدور در دشت همدان - بهار. مجله پژوهش آب ایران. ۱۵: ۴۳، ۴۵-۵۸.

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

مقدمه

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 جمع‌آوری شده به دلیل توپوگرافی پیچیده زمین، برای تعیین مقدار تبخیر و تعرق مرجع کافی نباشند. در نتیجه دستیابی به وضعیت مطلوب برای مدیریت آبیاری در چنین مناطقی دشوار است و خطر کمبود آب را افزایش می‌دهد (ماندا و همکاران، ۲۰۱۱).

روش‌های مرسوم به اندازه‌گیری تبخیر و تعرق (نسبت باون، همبستگی ادی و لایسیمتری) پرهزینه و وقت‌گیر هستند و قابل تعمیم 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؛ به طوری که 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 دمای 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. به‌طور کلی 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 (ماندا و همکاران، ۲۰۱۱). تبخیر و تعرق، به‌طور کلی 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 مانیتث 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 مانیتث دارای محدودیت‌هایی است، زیرا این روش نیازمند تعداد نسبتاً زیاد داده‌های هواشناسی ذخیره‌شده از ایستگاه‌های زمینی می‌باشد (گایولان 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 مانیتث به دمای هوا،

1- Reference Evapotranspiration

2- Crop coefficient

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 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 ۲۵۰ 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. الگوریتم‌های یادگیری ماشین، زیرمجموعه‌ای از هوش

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؛ درحالی‌که مدل‌های دو منبعی خاک و گیاه را جدا از هم و از چندین مقاومت آبرودینامیکی 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 (باستیانسین و همکاران، ۱۹۹۸)، ساده‌شده شاخص توازن انرژی سطحی زمین^۲ (روپرینک و همکاران، ۲۰۰۰)، سیستم توازن انرژی سطحی^۳ (سو و همکاران، ۲۰۰۲)، نقشه تبخیر و تعرق با واسنجی درونی^۴ (آلن و همکاران، ۲۰۰۷) اشاره کرد. هارونی و همکاران (۱۳۹۴)، تلاش کرده‌اند تا مدل SEBAL در حوزه‌های آبریزاریابی کنند، بدین منظور با استفاده از تصاویر 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).

ثنایی‌نژاد 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 طالقان با استفاده از تصاویر مودیس و مدل سبال را

1- Surface Energy Balance Algorithm for Land (SEBAL)

2- Simplified Surface Energy Balance Index (S-SEBI)

3- Surface Energy Balance System (SEBS)

4- Mapping Evapotranspiration at high Resolution with Internalized Calibration (METRIC)

5- Moderate Resolution Imaging Spectroradiometer (MODIS)

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° و عرض شمالی ۴۹°، ۳۴° تا ۰۲°، 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 به برآورد تبخیر و تعرق واقعی و پتانسیل با استفاده از

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، شبکه‌های عصبی مصنوعی بهینه‌سازی شده توسط الگوریتم ژنتیک^۲، شبکه‌های عصبی موجک^۳ 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 خاک را دارند. علی و همکاران (۲۰۱۵) یک

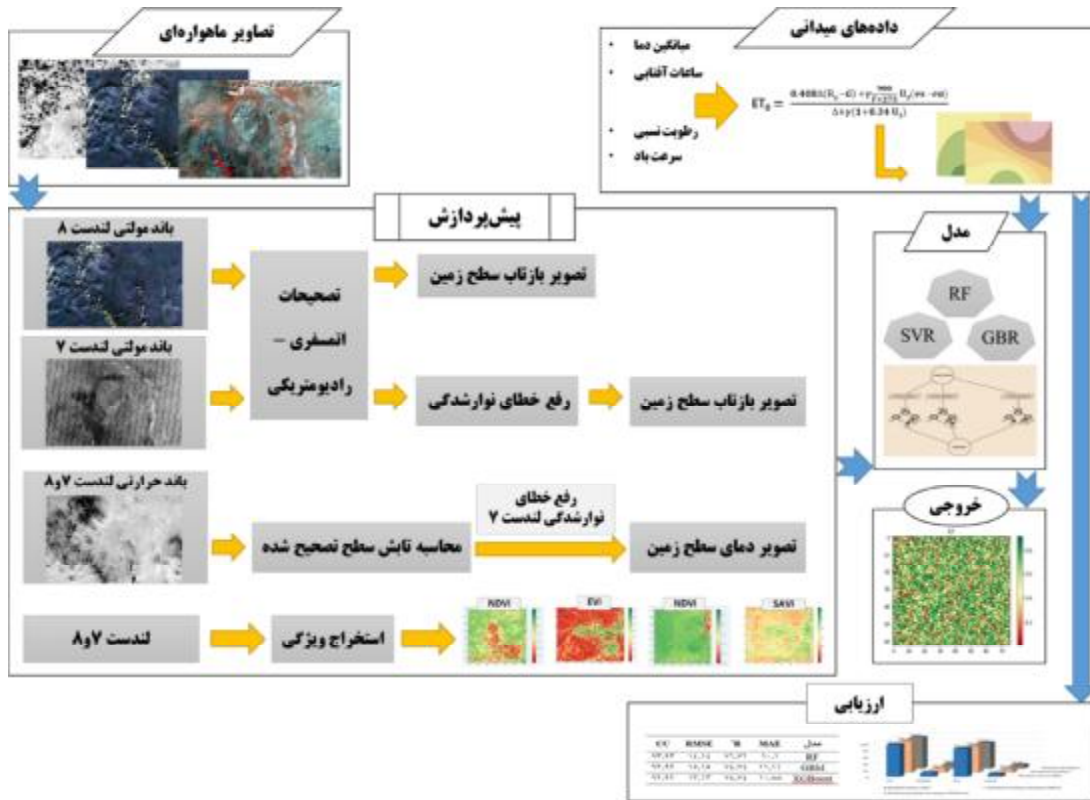
1- Extreme Learning Machine (ELM)

2- Genetic Algorithm Neural Networks (GANN)

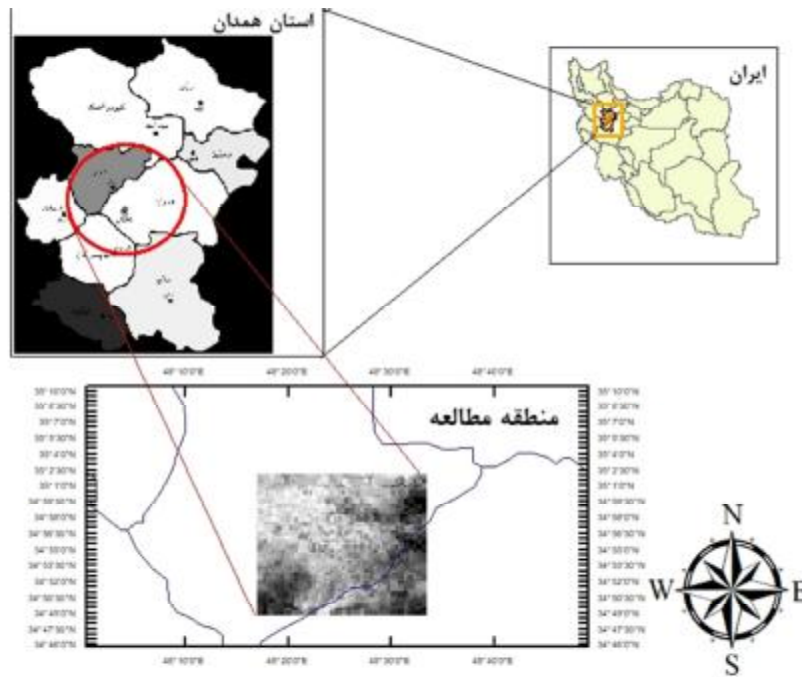
3- Wavelet Neural Networks (WNN)

تکنیک سنجش‌ازدور صورت گرفته است (امینی‌بازبانی و همکاران، ۱۳۹۱). موقعیت دشت همدان- بهار در استان

همدان در شکل ۲ مشخص شده است.



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 مانتیث فائو برآورد شده، به ترتیب 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 مانتیث فائو استفاده شد. روش پنمن مانتیث 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 مانتیث 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 مانتیث فائو را با روش لایسیمتری مقایسه کردند و روش پنمن مانتیث 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 بلنمدت 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 مانتیث به‌صورت شکل ۳ است:

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} U_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34 U_2)}$$

$x = \frac{\text{کوچکترین دما} + \text{بیشترین دما}}{2}$

شکل ۳- معادله پنمن مانتیث و متغیرهای آن

که در آن ET_0 : تبخیر و تعرق گیاه مرجع (mm/d)، R_n : تابش خالص در سطح پوشش گیاهی ($\text{Mj m}^{-2} \text{d}^{-1}$)، 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^{-1})، γ : ضریب رطوبتی (KPa^{-1}) و G : شار گرما به داخل خاک ($\text{Mj m}^{-2} \text{d}^{-1}$) 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 مانتیث است؛ بنابراین تبخیر و تعرق مرجع محاسبه‌شده از داده‌های سنجش‌ازدور و هواشناسی به ترتیب 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

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

پیش‌پردازش

برای تحقیق موردنظر، ۱۷۲ تصویر از محصولات لندست ۷ و ۸ دانلود شد. ماهواره‌های لندست توسط سازمان ملی هوانوردی و فضانوردی 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 ادامه یافت. نسل جدید سری ماهواره‌های لندست، ماهواره لندست ۸ است که با استفاده از دو سنجنده، یکی سنجنده تصویربردار عملیاتی زمین^۲ و دیگری سنجنده مادون قرمز حرارتی^۳ داده‌ها را دریافت می‌کند.

تصاویر مربوط به لندست ۷ و ۸ از سایت سازمان زمین‌شناسی ایالت متحده^۴ 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. به طور 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 NDVI^۵، EVI^۶ 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 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.

1- Enhanced Thematic Mapper Plus (ETM+)

2- Operational Land Imager (OLI)

3- Thermal Infrared Sensor (TIRS)

4- United States Geological Survey (USGS)

5- Normalized Difference Vegetation Index

6- Enhanced Vegetation Index

7- Soil Adjusted Vegetation Index

مدل‌های مورد استفاده

برای آموزش مدل‌ها از سه الگوریتم یادگیری ماشین، درخت‌های تصادفی^۱، رگرسیون تقویت گرادیان^۲، رگرسیون بردار پشتیبان^۳ 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 به صورت 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 تقویت گرادیان (GBR) می‌توان جایگزین کرد که از روش بوستینگ به جای بگینگ استفاده می‌کند. روش بوستینگ، میزان کارایی و عملکرد پیش‌بینی هر نمونه را در طول دوره آموزش در نظر می‌گیرد.

الگوریتم یادگیری ماشین اولین بار توسط وینیک (۲۰۱۳) برای طبقه‌بندی استفاده شده و در حل مسائل پیش‌بینی در سال‌های اخیر به طور قابل توجهی 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 آموزش دیده 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.

ارزیابی نتایج

شاخص‌های ارزیابی عملکرد مدل‌ها به منظور 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) به صورت زیر تعریف می‌شوند:

$$RMSE = \left(\frac{1}{N} \sum_{i=1}^N (\rho_i - O_i)^2 \right)^{0.5} \quad (۴)$$

$$\frac{1}{N} \sum_{i=1}^N |\rho_i - O_i| = MAE \quad (۵)$$

$$R^2 = \frac{\left[\sum_{i=1}^N (\rho_i - \bar{\rho})(O_i - \bar{O}) \right]^2}{\sum_{i=1}^N (\rho_i - \bar{\rho})^2 \sum_{i=1}^N (O_i - \bar{O})^2} \quad (۶)$$

$$CC = \frac{\sum_{i=1}^N (O_i - \bar{O})(\rho_i - \bar{\rho})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^N (\rho_i - \bar{\rho})^2}} \quad (۷)$$

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

هرچه مقدار RMSE کمتر باشد، عملکرد مدل بهتر بوده و در شرایطی که مقادیر برآورد شده با مقادیر واقعی برابر باشند، مقدار آن صفر خواهد شد. آماره MAE شاخصی است که از مقایسه مقادیر پیش‌بینی شده توسط مدل و مقادیر واقعی به دست می‌آید؛ به طوری که مقدار نزدیک به صفر بیان‌کننده آن است که متوسط مقادیر برآورد شده و واقعی مشابه هستند. ضریب تعیین R^2 بیان‌کننده مقداری از واریانس موجود در مقادیر واقعی است که توسط مقادیر پیش‌بینی شده 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 بدون بُعد است.

در بررسی و قیاس روش‌های مختلف رگرسیونی، یک رویکرد تحلیلی بررسی روشی است که برآوردها را با صحت بیشتری انتخاب می‌کند. با این وجود، هر اختلافی معنی‌دار نیست و از این رو آزمون‌های آماری در جهت سنجش معنی‌داری مورد نیاز است. آزمون مک‌نمار^۴ یکی از بهترین روش برای مقایسه دقیق کلاسه‌بندی و برآوردهای حاصل از مدل‌ها است که براساس یک تفاوت باینری بین تخصیص کلاسه‌بندی و برآوردهای درست و نادرست است (فودی، ۲۰۰۴). براساس این تست می‌توان نتایج برآوردهای مدل رگرسیون را با دو روش مختلف به صورت

1- Random Forest (RF)

2- Gradient Boosting Regressor (GBR)

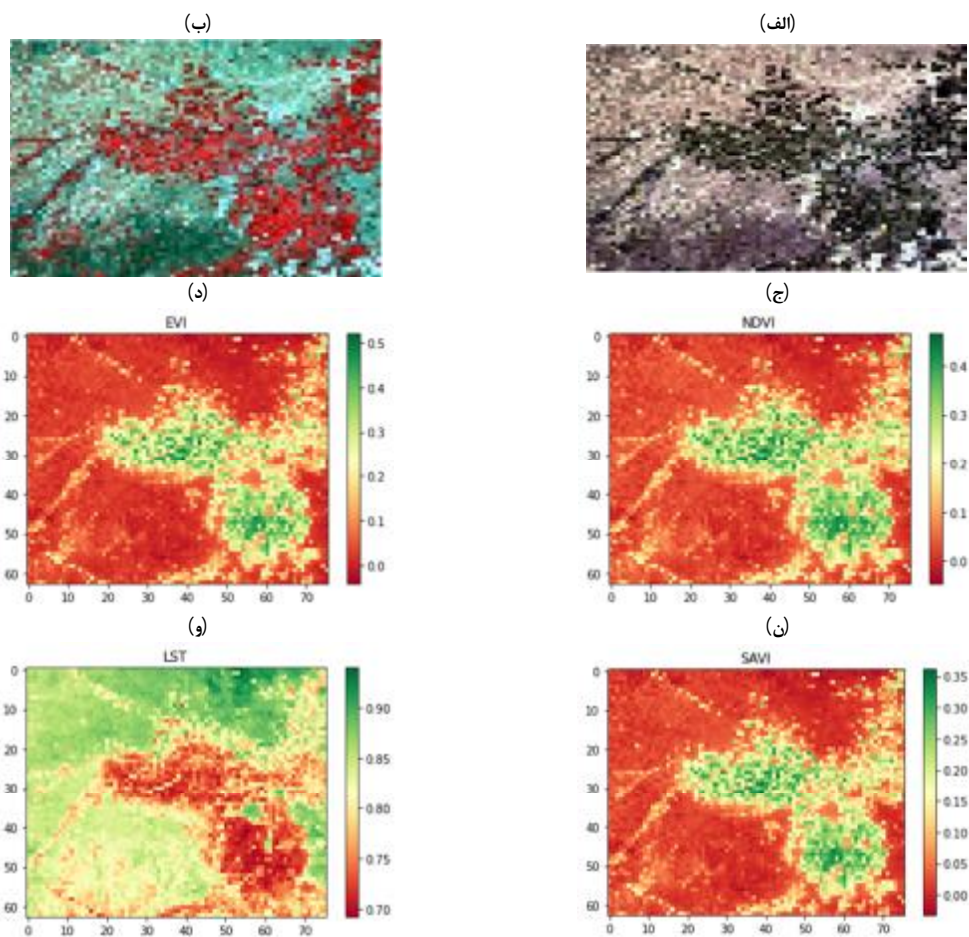
3- Support Vector Regression (SVR)

4- McNemar Test

$$z_b = \frac{|f_{12} - f_{21}|}{\sqrt{f_{12} + f_{21}}} \quad (۸)$$


در معادله فوق، f_{ij} بیانگر تعداد پیکسل‌هایی است که در روش نخست درست برآورد شده‌اند و در روش دوم اشتباه برآورد شده‌اند. f_{ij} و f_{ji} به ترتیب برابر با تعداد پیکسل‌هایی که در هر دو روش به درستی و اشتباه برآورد شده‌اند. اگر Z بزرگ‌تر از $1/96$ باشد، یعنی وابستگی آماری بین نتایج وجود ندارد و آنگاه اختلاف معناداری میان دو روش وجود دارد (کیانی و همکاران، ۲۰۲۱).

دودویی با هم قیاس کرد و میزان سطح وابستگی آماری بین آن دو را مورد تحلیل قرار داد. براین اساس به منظور بررسی معنی‌داری اختلاف‌های ذکر شده در نتایج، به بررسی موردی هر یک از روش‌های مورد قیاس با روش پیشنهادی در سطح معنی‌داری ۹۵٪ پرداخته خواهد شد. اختلاف عدم‌دقت در سطح معنی‌داری ۹۵ درصد مورد آزمایش قرار می‌گیرد و اگر Z_b از $1/96$ بیشتر باشد؛ بدین معنی است که این دو روش به طور قابل توجهی با یکدیگر متفاوت هستند و دو روش به یکدیگر وابسته نیستند. Z_b مطابق با معادله (۸) محاسبه می‌شود.



شکل ۴- نمایش منطقه مطالعه و شاخص‌های پوشش گیاهی مختلف مربوط به فصل تابستان

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 (کلوین) (شکل و)



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 (کلوین) (شکل و)

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.

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 مانیتیت فائو استفاده شده است. مدل‌های رگرسیونی با داده‌های شاخص پوشش گیاهی

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	۰/۹۳۵۰
GBRV	۰/۱۱۲۳	۰/۷۴۱۹	۰/۱۴۸۰	۰/۹۲۸۱
SVRV	۰/۱۲۲۷	۰/۶۹۵۵	۰/۱۶۰۷	۰/۹۱۳۵

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

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

برآورد خیلی نزدیکی با داده‌های حاصل از پنمن مانیتیت فائو دارد و درنهایت با توجه به نتایج به‌دست‌آمده از دو رویکرد مورد استفاده در این پژوهش، با به‌کارگیری مقادیر همهٔ 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.

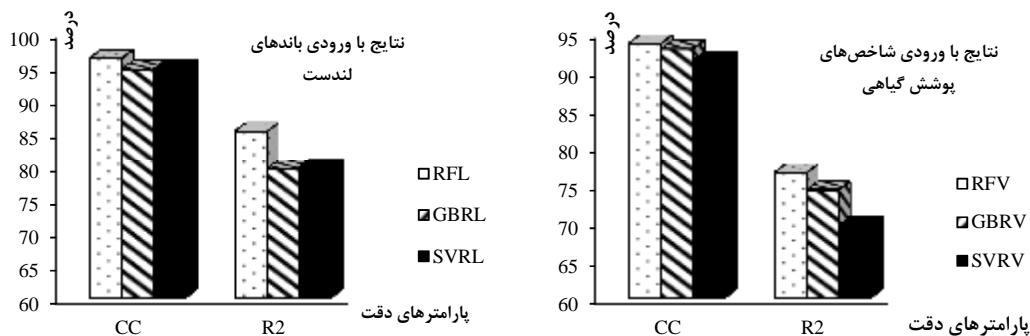
در جدول ۴ و ۵ وابستگی آماری بین مدل‌های رگرسیونی ارائه شده است. با توجه به نتایج ارائه شده در جداول ۴ و ۵ می‌توان وابسته نبودن مدل‌ها نسبت به هم را نتیجه گرفت و

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 سنجش‌ازدور 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 همهٔ 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 (ماندا 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. درحال حاضر، 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 درنتیجه 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

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 اکو 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.

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 بازیانی 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. ثنایی‌نژاد 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.

- 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