

مقاله علمی-پژوهشی

برآورد بارش مؤثر با بکارگیری سنجش از دور و مدل سازی آن با متغیرهای هواشناسی تحت الگوریتم های یادگیری پر کاربرد و شبکه عصبی پیشخور

سهیلا محتشمی^۱ و زهرا آقاشریعتمداری^{۲*}

چکیده

بارش یکی از مهم ترین اجزای جریان های هیدرولوژیکی به حساب می آید که میزان مؤثر و قابل استفاده آن برای گیاه در بخش کشاورزی و به ویژه کشت دیم از اهمیت بالایی برخوردار است. در این پژوهش، باران مؤثر در اراضی تحت کشت گندم دیم شهرستان خمین با بکارگیری سنجش از دور و اجرای الگوریتم سبال بر روی ۲۸ تصویر موجود از لندست ۸ در سال های زراعی ۱۳۹۳-۱۳۹۴ تا ۱۴۰۱-۱۴۰۰ برآورد گردید. برای ارزیابی دقت الگوریتم سبال از روش پنمن مانیتیت استفاده شد. سپس، به منظور توسعه یک مدل از تخمین بارش مؤثر به کمک شبکه عصبی و داده های هواشناسی ابتدا، میزان هم بستگی میان متغیرهای هواشناسی و درجه حرارت رشد روزانه (GDD) با بارش مؤثر به روش هم بستگی پیرسون بررسی و با توجه به نتایج هم بستگی ها، این متغیرها از نظر میزان هم بستگی اولویت بندی شدند. از داده های هواشناسی سه ایستگاه از نزدیک ترین ایستگاه های هم دید به منطقه مورد مطالعه برای درون یابی متغیرهای هواشناسی منطقه مطالعاتی با روش عکس فاصله استفاده شد. با توجه به نتایج هم بستگی ها، متغیر دمای متوسط با هم بستگی ۰/۹۲ و متغیرهای GDD و حداکثر رطوبت نسبی به ترتیب با هم بستگی ۰/۸۶ و ۰/۷۷- به عنوان متغیرهای مؤثر در برآورد بارش مؤثر شناخته شدند. در مرحله بعد متغیرهای مؤثر تحت سناریوهای مختلف برای آموزش شبکه ها به کار گرفته شدند و عملکرد شبکه ها با استفاده از معیار خطای RMSE و MBE ارزیابی شد. نتایج نشان داد که می توان با بکارگیری الگوریتم یادگیری Bayesian regularization و با داشتن متغیرهای دمای روزانه و GDD با دقت بسیار خوبی میزان بارش مؤثر را برای منطقه مورد نظر پیش بینی نمود. مقدار RMSE این مدل ۰/۱۸۹۹ میلی متر و MBE آن ۰/۱۱۵- میلی متر برآورد شد. با استفاده از مدل ارائه شده می توان تنها با داشتن متغیرهای ساده ی هواشناسی، تبخیر تفرق واقعی و در نهایت بارش مؤثر منطقه دیم مورد نظر را بدون نیاز به حل الگوریتم های پیچیده (نظیر سبال) با دقت مناسبی تخمین زد.

واژه های کلیدی: الگوریتم سبال، الگوریتم های یادگیری، بارش مؤثر، تبخیر تفرق، شبکه عصبی

مقدمه

زمین و توازن آب است. برآورد تبخیر تفرق (ET) در زمینه های مختلف علوم همچون هیدرولوژی، کشاورزی، مدیریت جنگل و مرتع و مدیریت منابع آب مورد نیاز است (صحراگرد و همکاران، ۱۳۹۹). اغلب روش هایی که تاکنون برای محاسبه ET ارائه شده اند از اندازه گیری های نقطه ای برای تخمین آن استفاده می کنند، لذا فقط مناسب مناطق محلی بوده و به دلیل طبیعت پویا و تغییرات منطقه ای، ET قابل تعمیم به حوضه های بزرگ نمی باشند. سنجش از دور این قابلیت را دارد که مقدار ET را برآورد کرده و توزیع مکانی آن را بررسی کند (ثنایی نژاد و

تبخیر و تفرق واقعی^۲ یکی از عوامل مهم در چرخه هیدرولوژی و از عوامل تعیین کننده معادلات انرژی در سطح

^۱ گروه مهندسی آبیاری و آبادانی، دانشکده کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران

^۲ استادیار، گروه مهندسی آبیاری و آبادانی، دانشکده کشاورزی، دانشکده کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران (* نویسنده مسئول:

(E-mail: zagha@ut.ac.ir

تاریخ دریافت: ۱۴۰۱/۰۹/۳۰

تاریخ پذیرش: ۱۴۰۱/۱۱/۱۷

² Actual evapotranspiration

فauزی و همکاران، تبخیر تعرق روزانه را با استفاده از ۱۸ تصویر ماهواره‌ای لندست در سال‌های ۲۰۱۷ و ۲۰۱۸ با به-کارگیری الگوریتم سبال در منطقه کشت برنج دلتای نیل مصر برآورد کردند و برای ارزیابی عملکرد الگوریتم سبال از رابطه فائو پنمن مانیتیت استفاده نمودند. نتایج پژوهش آن‌ها نشان داد که الگوریتم سبال با RMSE ۰/۲۶۴ میلی‌متر در روز قادر است میزان ET را برآورد کند (Fawzy et al., 2021). میریعقوب-زاده و همکاران تبخیر تعرق حاصل از الگوریتم سبال را با روش استاندارد فائو پنمن مانیتیت در حوزه آبخیز تمر واقع در استان گلستان مورد ارزیابی و مقایسه قرار دادند. نتایج تحقیق حاکی از آن بود که الگوریتم سبال قابلیت تعیین میزان تبخیر تعرق واقعی در سطح وسیع بدون نیاز به داده‌های هواشناسی زیاد را دارد. هم‌چنین نتایج نشان داد که الگوریتم سبال میزان ET را بین ۰/۵ تا یک میلی‌متر در روز کمتر از روش پنمن مانیتیت برآورد می‌نماید (میر یعقوب زاده و همکاران، ۱۳۹۳).

عظیمی و همکاران به برآورد ET با استفاده از الگوریتم توازن انرژی سطحی برای زمین (سبال) و هم‌چنین به ارزیابی عملکرد شبکه‌های عصبی مصنوعی در برآورد ET پرداختند. در این تحقیق از چهار تصویر لندست استفاده شد که مقایسه نتایج به‌دست‌آمده از دو روش سنجنش از دور و معادله پنمن مانیتیت فائو نشان داد که میانگین مربعات خطا (MSE) ۱/۵۴ میلی‌متر در روز است. سپس، برای حل پیچیدگی فرآیند تبخیر، از شبکه‌های عصبی مصنوعی برای پیش‌بینی تبخیر از تشت بر اساس داده‌های هواشناسی استفاده کردند. نتایج این پژوهش، عملکرد بهتر شبکه‌های عصبی مصنوعی نسبت به روش سنجنش از دور در برآورد میزان ET را نشان داد (عظیمی و همکاران، ۱۳۹۴). ملک پور و همکاران ET را در دشت قزوین با استفاده از الگوریتم سبال برای پنج تصویر از ماهواره لندست محاسبه کردند و نتایج را با داده‌های لایسیمتر زهکش دار موجود در منطقه مورد ارزیابی قرار دادند. نتایج پژوهش نشان از دقت مناسب الگوریتم سبال در تخمین تبخیر تعرق دارد (ملک پور و همکاران، ۱۳۹۵). میر محمدصادقی و همکاران با استفاده از الگوریتم سبال به تخمین تبخیر آب از دریاچه سد زاینده‌رود

همکاران، ۱۳۹۰). برآورد تبخیر تعرق با روش‌های سنجنش از دور به دلیل دقت بالا، پوشش زمانی مناسب و در دسترس بودن آسان و ارزان داده‌های سنجنش از دور گزینه مناسبی است (Zamani Losgedaragh, 2018).

الگوریتم سبال (SEBAL)^۳ یکی از الگوریتم‌های بیلان انرژی در سطح موجود سنجنش از دور است که با استفاده از معادله بیلان انرژی و برآورد تمامی مؤلفه‌های انرژی در سطح زمین قادر به برآورد تبخیر تعرق می‌باشد. تحقیقات وسیع و گوناگونی در زمینه استفاده از الگوریتم سبال در سطح جهان انجام شده است. در مطالعه‌ای که توسط تاسومی و همکاران در آیداهو انجام شد، دو مدل تعادل انرژی از جمله سبال و متریک^۴ در برآورد ET مقایسه شدند. نتایج پژوهش آن‌ها نشان داد که هر دو مدل تعادل انرژی با نتایج، انطباق خوبی دارند و نتایج این تحقیق کارایی استفاده از مدل‌های تعادل انرژی برای محاسبه مقادیر واقعی ET را اثبات کرد (Tasumi et al., 2003). در پژوهشی، پاول و همکاران مقادیر برآورد شده تبخیر تعرق از الگوریتم سبال را با مقادیر اندازه‌گیری شده به‌صورت میدانی توسط چهار لایسیمتر دقیق وزنی در دو سطح کشت آبی و دیم مقایسه و به نتایج مطلوبی در استفاده از الگوریتم سبال رسیدند (Paul et al., 2013).

سیلوا و همکاران به تخمین تبخیر تعرق واقعی با به-کارگیری الگوریتم سبال در جنوب غربی پارانا، با استفاده از تصاویر لندست و داده‌های تکمیلی هواشناسی پرداختند. سپس، برآوردهای تبخیر تعرق از مدل سبال را با نتایج معادله پنمن مانیتیت فائو مقایسه کردند که نتایج مقایسه‌های آن‌ها کمتر یا مساوی یک میلی‌متر در روز محاسبه شد (Silva et al., 2018). ترزا نیاز آبی محصولات را با استفاده از الگوریتم بیلان انرژی سبال در آیداهو برآورد کرد. در این پژوهش از داده‌های ماهواره لندست استفاده و دقت مدل سبال با داده‌های لایسیمتری موسسه تحقیقات کشاورزی کیمبرلی آیداهو مقایسه شد. نتایج نشان داد که روش سبال اختلاف کمتر از ۵٪ را با داده‌های لایسیمتری دارا است (Trezza, 2002).

³ Surface Energy Balance Algorithm

⁴ Metric

مقایسه می‌شود. علاوه بر این، توسعه یک مدل از تخمین بارش مؤثر در منطقه موردنظر به کمک شبکه عصبی و داده‌های هواشناسی نیز مطلوب این تحقیق است. به کارگیری یک مدل هوشمند و جامع و آموزش آن به کمک متغیرهای بهینه موجب می‌گردد؛ تنها با داشتن متغیرهای ساده‌ی هواشناسی، تبخیر تعرق واقعی و در نهایت بارش مؤثر را برآورد کرد.

مواد و روش‌ها

منطقه مطالعاتی


منطقه مطالعاتی این تحقیق، دشت کشت گندم دیم واقع در شهرستان خمین است. شهرستان خمین یکی از شهرستان‌های استان مرکزی به حساب می‌آید. متوسط بارندگی سالانه در این شهرستان ۲۹۶ میلی‌متر و میانگین سالانه دما ۱۳/۶ درجه سانتی‌گراد است. این منطقه از نظر اقلیمی بر اساس طبقه‌بندی دومارتن، خشک محسوب می‌شود. مختصات دقیق زمین کشاورزی گندم دیم در دشت خمین به وسعت ۱۰۰۰ هکتار با استفاده از دستگاه GPS برداشت شد. موقعیت منطقه مطالعاتی در شکل (۱) نشان داده شده است. بر اساس پرسش‌های محلی از سال زراعی ۱۳۴۳-۱۳۴۴ تا ۱۴۰۱-۱۴۰۰ در این منطقه، محصول گندم به صورت دیم کشت شده و تاریخ کشت در سال‌های زراعی اخیر (که موردنظر این پژوهش است) از ۷ مهر تا اول تیرماه بوده است.

جمع‌آوری داده‌های هواشناسی

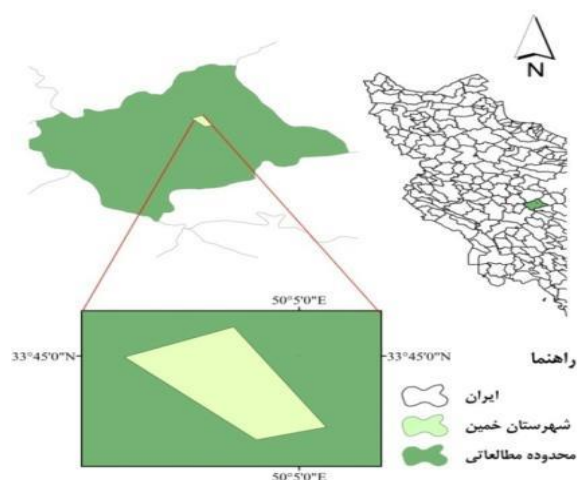
داده‌های روزانه هواشناسی ایستگاه‌های همدیدی مجاور دشت کشت گندم دیم همچون ایستگاه‌های خمین، محلات و گلپایگان از سازمان هواشناسی برای سال‌های زراعی ۱۳۹۴-۱۳۹۳ تا ۱۴۰۱-۱۴۰۰ و در طول دوره رشد محصول گندم دیم دریافت شد. از این داده‌ها برای درون‌یابی متغیرهای هواشناسی در موقعیت دشت کشت گندم دیم موردنظر به روش وزنی عکس فاصله^۱ (IDW) استفاده شد. روش IDW در ادامه شرح داده شده است. مشخصات و موقعیت جغرافیایی ایستگاه‌های همدید مذکور در جدول (۱) و شکل (۲) نشان داده شده است.

پرداختند. در این پژوهش روش‌های مختلف تجربی مورد استفاده قرار گرفتند و همچنین، الگوریتم بیلان انرژی سطحی سبال روی هشت تصویر ماهواره لندست برای برآورد تبخیر از دریاچه سد پیاده‌سازی شد. به منظور ارزیابی دقت روش‌های مختلف، نتایج به دست آمده در هر روش با اندازه‌گیری‌های تشت تبخیر در محوطه سد مقایسه شد. نتایج حاصل نشان داد که هیچ‌یک از روش‌های تجربی، همبستگی مناسب و قابل قبولی با اندازه‌گیری‌های تبخیر در محل ندارند. در مقابل، روش سبال دارای ضریب تبیین ۰/۸۹ بوده که نشان‌دهنده دقت بالای این روش در تخمین تبخیر آب نسبت به فرمول‌های تجربی در برآورد حجم تبخیر سطحی آب از مخازن است (میر محمد صادقی و همکاران، ۱۳۹۸).

مرور بر مطالعات انجام شده، حاکی از آن است که برآورد تبخیر تعرق با به کارگیری الگوریتم سبال نتایج مطلوبی در سطح جهان داشته است. همچنین، تحقیقات انجام گرفته در نقاط مختلف جهان مبین این نکته است که رابطه پنمن مانیتث فائو، در شرایطی که داده‌های لایسیمیتری در دسترس نباشد، به عنوان یک رابطه استاندارد برای برآورد تبخیر تعرق توصیه می‌شود (هژبر، ۱۳۹۱; kisi and Öztürk, 2007). علاوه بر این، در اکثر تحقیقات انجام شده به ارزیابی دقت الگوریتم سبال پرداخته شده و تحقیقات کمی در زمینه کارآمدی آن صورت گرفته است. بارش یکی از مهم‌ترین اجزای جریان‌های هیدرولوژیکی به حساب می‌آید که میزان مؤثر و قابل استفاده آن برای گیاه در بخش کشاورزی و به ویژه کشت دیم که در آن تمام نیاز آبی گیاه از طریق میزان بارش مؤثر تأمین می‌شود، از اهمیت بالایی برخوردار است. از آنجایی که در مناطق دیم، باران مؤثر همگی صرف تبخیر تعرق شده، با داشتن میزان تبخیر تعرق واقعی می‌توان به میزان باران مؤثر دست‌یافت (پورغلام آمیجی و همکاران، ۱۳۹۸). از این رو، در این پژوهش با به کارگیری سنجش از دور و اجرای الگوریتم سبال بر کشت دیم، تبخیر تعرق واقعی محصول گندم دیم و در نهایت میزان بارش مؤثر محاسبه می‌شود. سپس، نتایج تبخیر تعرق حاصل از سبال با نتایج تبخیر تعرق حاصل از رابطه پنمن مانیتث فائو



شکل ۲- موقعیت ایستگاه‌های همدید مجاور



شکل ۱- موقعیت جغرافیایی دشت کشت گندم دیم شهرستان خمین

جدول ۱- مشخصات ایستگاه‌های همدید مورد استفاده جهت درون‌یابی اطلاعات هواشناسی منطقه مورد نظر

نام ایستگاه	خمین	محلات	گلیپاگان
عرض جغرافیایی	۳۳/۶	۳۳/۸	۳۳/۴
طول جغرافیایی	۵۰/۰	۵۰/۴	۵۰/۲
ارتفاع از سطح دریا (متر)	۱۸۳۴/۶	۱۶۲۲	۱۸۷۰
میانگین سالانه دما (درجه سلسیوس)	۱۳/۶	۱۵/۹	۱۵/۶
مجموع بارش سالانه (میلی‌متر)	۲۹۶	۲۸۰	۲۵۵
اقلیم (طبقه‌بندی دومارتن)	خشک	نیمه‌خشک	خشک
فاصله تا منطقه مطالعاتی (کیلومتر)	۱۳	۴۱	۳۶/۶

d_i فاصله نقطه معلوم از نقطه مجهول تعریف و α نیز ضریبی است که برحسب نیاز یک یا دو قرار داده می‌شود. (David, 1997).

$$z_j = \sum_{i=1}^n \lambda_i \times z_i \quad (1)$$

$$\lambda_i = \frac{1}{\sum_{i=1}^n \frac{1}{d_i^\alpha}} \quad (2)$$

درون‌یابی وزنی عکس فاصله (IDW)

روش درون‌یابی وزنی عکس فاصله یک روش درون‌یابی غیر زمین آمار محسوب می‌شود که در این روش از معکوس فاصله به‌عنوان وزن نقاط معلوم در تخمین نقاط مجهول استفاده می‌شود. فرم کلی روش به‌صورت معادله (۱) است که در آن z_j و z_i مقدار متغیر در نقطه مجهول و نقاط معلوم و λ_i ضریب وزنی است. در این روش، λ_i از رابطه (۲) محاسبه می‌شود که در آن

¹ Inverse Distance Weighting

خروجی در همهی طول موجها، طبق رابطه (۴) محاسبه می شود. در رابطه (۴)، α آلبیدوی سطحی^۵، R_{SL} تابش موج کوتاه ورودی^۶ برحسب $\frac{W}{m^2}$ ، $R_{L\downarrow}$ تابش موج بلند ورودی^۷ برحسب $\frac{W}{m^2}$ و $R_{L\uparrow}$ تابش موج بلند خروجی^۸ برحسب $\frac{W}{m^2}$ و ϵ_0 گسیلمندی (تابش) حرارتی سطح^۹ (بدون بعد) است (waters et al., 2002).

$$R_n = (1-\alpha)R_{SL} + R_{L\downarrow} - R_{L\uparrow} - (1-\epsilon_0)R_{L\downarrow} \quad (4)$$

تابش موج کوتاه ورودی، شار تابش خورشیدی مستقیم و پراکنده است که به زمین می رسد و طبق رابطه (۵) محاسبه می شود. در رابطه (۵)، G_{sc} ثابت خورشیدی ($1367 \frac{W}{m^2}$)، θ زاویه تابش خورشیدی، d_r معکوس مربع فاصله نسبی زمین تا خورشید و τ_{ws} شفافیت جوی است (waters et al., 2002).

$$R_{SL} = G_{sc} \cos(\theta) d_r^2 \tau_{ws} \quad (5)$$

$R_{L\downarrow}$ تابش موج بلندی ورودی، است و طبق رابطه (۶) محاسبه می شود. در این رابطه ϵ_α گسیلمندی جو، σ ثابت استفان بولتزمن (معادل 5.67×10^{-8} وات بر مترمربع بر توان چهارم کلوین) و T_α دمای هوای نزدیک سطح (کلوین) است (waters et al., 2002).

$$R_{L\downarrow} = \epsilon_\alpha \times \sigma \times T_\alpha^4 \quad (6)$$

$R_{L\uparrow}$ شار تابش موج بلند گسیل شده از سطح زمین به جو است که طبق رابطه (۷) محاسبه می شود. در این رابطه، ϵ_α گسیلمندی سطحی عریض باند، σ ثابت استفان بولتزمن (معادل 5.67×10^{-8} وات بر مترمربع بر توان چهارم کلوین) و T_α دمای سطحی (برحسب کلوین) است (waters et al., 2002).

$$R_{L\uparrow} = \epsilon_\alpha \times \sigma \times T_\alpha^4 \quad (7)$$

برآورد بارش مؤثر با به کارگیری الگوریتم بیلان

انرژی

بخشی از آب باران در خاک نفوذ می کند و بخشی از آن به صورت رواناب بر روی سطح خاک جریان می یابد که قابل استفاده توسط گیاهان نیست. قسمت نفوذ یافته در ناحیه ریشه ذخیره شده و می تواند توسط گیاهان استفاده شود، این بخش باقیمانده به اصطلاح باران مؤثر است (Brouwer & Heibloem, 1986). از کل آب جذب شده توسط گیاه در طول یک فصل رشد، حدود ۹۹ درصد به صورت بخار آب در جو از بین می رود و تنها یک درصد توسط گیاه حفظ می شود (Kochhar and Gujral, 2020). بنابراین، در مناطق دیم خیزی که تنها منبع تأمین نیاز آبی گیاهان آب باران است، میزان تبخیر تعرق معادل میزان بارش مؤثر است. در ادامه، به شرح محاسبه تبخیر تعرق در منطقه کشت گندم دیم مورد نظر با به کارگیری سنجش از دور پرداخته می شود. الگوریتم سبال یک الگوریتم مبتنی بر بیلان انرژی است که در آن با استفاده از معادلات بیلان انرژی می توان مقدار تبخیر تعرق را محاسبه نمود. در این روش، تبخیر تعرق واقعی به عنوان باقیمانده بیلان انرژی زمین، طبق رابطه (۳) محاسبه می شود. در رابطه (۳)، λET نشانگر شار گرمای نهان^۱ است که در واقع میزان هدررفت گرما از سطح به علت فرآیند تبخیر تعرق است، R_n شار تابش خالص در سطح^۲، G شار حرارتی خاک^۳ و H شار حرارتی محسوس هوا^۴ است. تمامی مؤلفه ها در این رابطه برحسب $\frac{W}{m^2}$ می باشند (waters et al., 2002) در ادامه به نحوه محاسبه هر یک از مؤلفه های رابطه (۳) پرداخته شده است.

$$\lambda ET = R_n - H - G \quad (3)$$

شار تابش خالص در سطح

شار تابش خالص در سطح (R_n)، انرژی تابشی واقعی موجود در سطح را نشان می دهد و از اختلاف بین تابش ورودی و

⁵ Surface albedo

⁶ Incoming shortwave radiation

⁷ Incoming long wave radiation

⁸ Outgoing long wave radiation

⁹ Surface thermal emissivity

¹ Latent heat flux

² Net radiation flux

³ Soil heat flux

⁴ Sensible heat flux

$$ET_{inst} = 3600 \times \frac{\lambda ET}{\lambda} \quad (10)$$

$$\lambda = (2.501 - 0.00236(T_s - 273)) \times 10^6 \quad (11)$$

پس از برآورد تبخیر تعرق لحظه‌ای، مقدار تبخیر تعرق روزانه از طریق رابطه ارائه‌شده توسط جکسون محاسبه شد (رابطه ۱۲) (Jakson et al., 1983). که در آن N بازه زمانی بین طلوع و غروب خورشید و t زمان در روز (از طلوع خورشید) است.

$$\frac{ET_{daily}}{ET_{inst}} = \frac{2N}{\pi \sin(\frac{\pi t}{N})} \quad (12)$$

فلوچارت الگوریتم سبال و مسیر محاسبات تبخیر تعرق لحظه‌ای در شکل (۳) نمایش داده شده است.

صحت سنجی الگوریتم سبال در برآورد تبخیر

تعرق روزانه

با توجه به عدم وجود داده‌های لایسیمیتری در منطقه مطالعاتی، برای صحت سنجی تبخیر تعرق واقعی برآورد شده به روش سبال، از روش پنمن مانیتث فائو استفاده شد (رابطه ۱۳). در این رابطه، ET_0 تبخیر تعرق گیاه مرجع برحسب میلی‌متر بر روز، R_n تشعشع خالص از سطح محصول، G شار حرارتی خاک، T میانگین دمای هوا برحسب درجه سلسیوس، u_2 سرعت باد در ارتفاع ۲ متری (متر بر ثانیه)، e_s فشار بخار اشباع (کیلو پاسکال)، e_a فشار بخار واقعی (کیلو پاسکال)، Δ شیب منحنی فشار بخار اشباع و γ ضریب سایکرومتری می‌باشد (Allen et al., 1998). سپس طبق رابطه (۱۴)، با اعمال ضریب گیاهی (K_c) و ضریب تنش K_s بر تبخیر تعرق گیاه مرجع (ET_0)، تبخیر تعرق گیاه (ET_c) محاسبه شد (Allen et al., 1998). مقدار K_c از جداول ضرایب گیاهی ارائه‌شده توسط فائو برای محصول گندم استخراج شد. مقدار K_s در شرایطی که تنش آبی وجود داشته باشد کمتر از یک و در صورتی که گیاه دچار تنش آبی نباشد برابر با یک قرار

شار تابش گرمای خاک

شار گرمای خاک، میزان انتقال گرما در خاک و پوشش گیاهی در اثر هدایت مولکولی است. در مدل سبال G را از نسبت $\frac{G}{R_n}$ از رابطه (۸) تعیین می‌گردد. در رابطه (۸)، T_s دمای سطحی (برحسب درجه سانتی‌گراد)، NDVI^۱ شاخص تفاضل نرمال شده پوشش گیاهی و α آلبیدوی سطحی است (waters et al., 2002).

$$\frac{G}{R_n} = \frac{T_s}{\alpha} \times (0.0032 \times \alpha + 0.0062 \times \alpha^2) \times (1 - 0.978 \times NDVI^4) \quad (8)$$

شار گرمای محسوس

در روش سبال برای برآورد شار گرمای محسوس، ابتدا دو پیکسل سرد و گرم شاخص انتخاب می‌شوند و مقدار شار گرمای محسوس طبق رابطه (۹) محاسبه می‌گردد. در رابطه (۹)، ρ_{air} چگالی هوا، C_{air} گرمای ویژه هوا، dT اختلاف دمای بین دو ارتفاع z1 و z2 (کلوین) و r_{ah} مقاومت ائروپنایمیک برای انتقال گرما (برحسب ثانیه بر متر) است (waters et al., 2002). پیکسل سرد مربوط به منطقه‌ای کاملاً پوشیده از گیاه و آبیاری شده است که مقدار NDVI در آن بیشتر از ۰/۷ و دمای سطح زمین در این پیکسل نزدیک به دمای هوا و کمتر از دمای سطح زمین در پیکسل گرم است. پیکسل گرم زمین کشاورزی بدون پوشش گیاهی و خشک است که مقدار NDVI در آن کمتر از ۰/۲۸ و بیشتر از ۰/۱ است (Jamshidi, 2020).

$$H = \frac{\rho_{air} \times C_{air} \times dT}{r_{ah}} \quad (9)$$

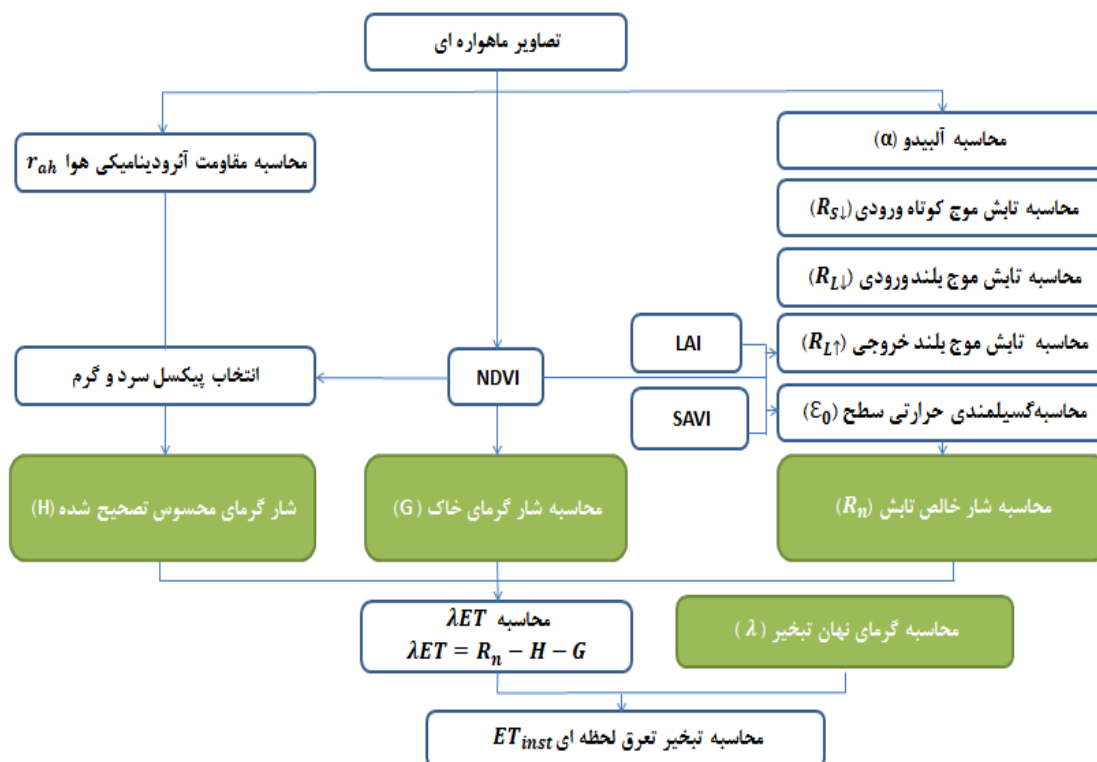
پس از آنکه مقدار شار گرمای محسوس بر اساس شرایط جوی تصحیح گردید، مقدار شار گرمای نهان تبخیر برای هر پیکسل محاسبه می‌گردد. سپس، با استفاده از رابطه (۱۰) تبخیر و تعرق لحظه‌ای (ET_{inst}) برآورد می‌شود. در رابطه (۱۰)، λ گرمای نهان تبخیر بوده که از رابطه (۱۱) محاسبه می‌شود (Allen et al., 2011).

¹ Normalized Difference Vegetation Index

می‌گیرد (Allen et al., 1998). در این پژوهش، مقدار K_S با فرض بر عدم وجود تنش آبی برابر با یک قرار گرفت.

$$ET_c = K_c \times K_s \times ET_0 \quad (14)$$

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)} \quad (13)$$



شکل ۳- فلوجارت الگوریتم سیال

همبستگی متغیرهای هواشناسی با بارش مؤثر

به منظور بررسی تأثیر متغیرهای مختلف هواشناسی بر بارش مؤثر برای ارائه یک مدل به منظور تخمین دقیق بارش مؤثر، از داده‌های هواشناسی منطقه مطالعاتی استفاده شد. همبستگی میان بارش مؤثر برآورد شده از الگوریتم سیال و متغیرهای هواشناسی همچون حداقل دمای روزانه و حداکثر دمای روزانه، رطوبت نسبی، بارش، تبخیر، فشار بخار، ساعات آفتابی و سرعت باد به روش همبستگی پیرسون^۱ بررسی شد و همچنین متغیر درجه حرارت رشد روزانه (GDD)^۲، به عنوان یکی از متغیرهای مورد بررسی محاسبه شد.

مدل‌سازی بارش مؤثر با به‌کارگیری شبکه عصبی

با به‌کارگیری شبکه عصبی مصنوعی^۳ می‌توان سیستمی را بر اساس ورودی و خروجی‌های موجود آموزش داد تا قادر باشد به ازای هر ورودی خارج از مجموعه‌ی موجود، یک خروجی با حداقل خطای ممکن ارائه نماید. با توجه به مشخص شدن میزان همبستگی هر یک از متغیرهای هواشناسی بر بارش مؤثر، متغیرهای هواشناسی از نظر میزان همخوانی اولویت‌بندی شدند. سپس، شبکه‌هایی با یک لایه مخفی و دو نورون تحت سناریوهای مختلف (ورودی‌های مختلف) و الگوریتم‌های مختلف یادگیری آموزش داده شدند. از ۲۸ مجموعه داده موجود، ۲۲ داده

^۱ Pearson

^۲ Growing Degree Days

^۳ Artificial Neural Networks



به‌عنوان مجموعه داده‌های آموزش و ۶ داده به‌عنوان مجموعه داده‌های تست (داده‌های تاریخ ۱۴۰۰/۰۲/۱۸ تا ۱۴۰۱/۰۳/۲۲) انتخاب شدند. سپس، عملکرد شبکه‌ها در تخمین داده‌های تست با معیار ارزیابی خطای RMSE و MBE مورد ارزیابی قرار گرفت. در ادامه، شبکه عصبی مورد استفاده در این پژوهش معرفی و در قسمت نتایج و بحث، نتایج مدل‌سازی مورد بررسی و تحلیل قرار خواهند گرفت.

شبکه‌های عصبی پیشخور چندلایه پرسپترون^۱

شبکه‌های عصبی پیشخور برای یادگیری رابطه بین متغیرهای مستقل که به‌عنوان ورودی شبکه عمل می‌کنند و متغیرهای وابسته که به‌عنوان خروجی شبکه تعیین می‌شوند، استفاده می‌شود. متغیرهای ورودی غالباً از متغیرهای قابل مشاهده انتخاب می‌شوند. یادگیری زمانی اتفاق می‌افتد که مجموعه‌ای از نمونه‌های «مجموعه آموزشی»^۲ به شبکه ارائه شود و وزن شبکه برای به حداقل رساندن تفاوت بین خروجی‌های شبکه و خروجی‌های واقعی تنظیم شود. هنگامی که وزن‌ها با استفاده از نمونه‌های مجموعه آموزشی تنظیم شدند، می‌توان از شبکه برای پیش‌بینی نمونه‌های ناشناخته استفاده کرد (Lavine and Blank, 2009).

شبکه عصبی پیشخور که در این پژوهش مورد استفاده قرار گرفته، از محبوب‌ترین و پرکاربردترین الگوهای شبکه عصبی مصنوعی است. شکل (۳) ساختار یک شبکه عصبی پیشخور را نشان می‌دهد که در آن هر عنصر ورودی ($p_1, p_2, p_3, \dots, p_i$) در وزن مربوط به خود ($IW_{1,1}, IW_{1,2}, IW_{1,3}, \dots, IW_{1,i}$) ضرب می‌شوند و مقادیر وزنی در محل اتصال جمع می‌شوند. مجموع آن‌ها IWp است، حاصل ضرب نقطه‌ای ماتریس (تک سطر) IW و بردار p . نورون دارای یک بایاس (b) است که با ورودی‌های وزن‌دار جمع می‌شود تا ورودی خالص (n) را تشکیل دهد. این مجموع، n (رابطه ۱۵)، آرگومان تابع انتقال f است (Puig-Arnavat and Bruno, 2015).

$$n = IW_{1,1} \times p_1 + IW_{1,2} \times p_2 + \dots + b \quad (15)$$



شکل ۳- ساختار یک شبکه Feedforwardnet

در این پژوهش به‌منظور تنظیم وزن‌ها در شبکه پیشخور به‌کار گرفته شده، از الگوریتم‌های مختلف یادگیری همچون LM^۳، BR^۴، GD^۵ و GDM^۱ استفاده شد. نحوه تنظیم وزن-

^۳ Levenberg Marquardt

^۴ Bayesian Regularization

^۵ Gradient Descent

^۱ Multi layer perceptron feedforward neural networks

^۲ Data set

ها توسط الگوریتم‌های مذکور در جدول (۱) به صورت مختصر شرح داده شده است.

جدول ۲- نحوه کاهش خطا توسط الگوریتم‌ها

الگوریتم	نحوه تنظیم وزن‌ها
BR	قانون بیز برای به‌روزرسانی وزن و بایاس شبکه عصبی استفاده می‌شود (Okut, 2016)
LM	برای تنظیم وزن‌ها از ترکیب روش نزول گرادینان و گاوس-نیوتن استفاده می‌کند. این الگوریتم قابلیت هر دو روش را درحالی‌که از اشکالات آن‌ها اجتناب می‌کند، ترکیب می‌کند (Puig-Arnavat and Bruno, 2015).
GD	از روش کاهش گرادینان برای به‌روزرسانی وزن استفاده می‌شود. گرادینان تابع خطا نسبت به هر وزن محاسبه می‌شود و وزن‌ها در جهت کاهش گرادینان به‌منظور کاهش خطا اصلاح می‌شوند (Qian, 1999).
GDM	از روش کاهش گرادینان مومنتوم برای به‌روزرسانی وزن استفاده می‌شود. عبارت مومنتوم می‌تواند سرعت یادگیری را بهبود بخشد (Qian, 1999).

نتایج و بحث


نتایج سبال و صحت سنجی

با اجرای الگوریتم سبال بر روی ۲۸ تصویر موجود از لندست ۸ در سال‌های زراعی ۱۳۹۴-۱۳۹۳ تا ۱۴۰۱-۱۴۰۰ و در طول دوره رشد گندم دیم، مقادیر تبخیر تعرق روزانه برآورد شد. سپس، نتایج تبخیر تعرق روزانه حاصل از سبال با نتایج تبخیر تعرق روزانه حاصل از روش پنمن مانیتیت جهت صحت سنجی سبال، با معیار ارزیابی خطای مجذور میانگین مربعات خطا (RMSE) مقایسه گردید. شکل (۴) نمودار میله‌ای تبخیر تعرق روزانه حاصل از مدل سبال و معادله پنمن مانیتیت را در تاریخ‌های موجود نشان می‌دهد. با توجه به شکل (۴)، در تمامی تاریخ‌ها، رابطه پنمن مانیتیت مقادیر بیشتری از تبخیر تعرق روزانه را نسبت به روش سبال برآورد کرده است. از آنجایی‌که منطقه مطالعاتی تحت کشت دیم بوده، ممکن است محصولات دیم در طی دوره


رشد خود با تنش‌هایی از قبیل تنش آبی روبرو باشند. در محاسبه تبخیر تعرق محصول (رابطه ۱۴) مقدار ضریب تنش به دلیل عدم امکان محاسبه آن برابر با یک قرار داده شد؛ بنابراین اختلاف میان تبخیر تعرق برآورد شده از رابطه پنمن مانیتیت با سبال را می‌توان وجود تنش‌هایی دانست که در طول رشد به محصول موردنظر وارد شده که موجب کاهش تبخیر تعرق واقعی می‌شوند. هم‌چنین، مجذور میانگین مربعات خطا (RMSE) روش سبال و پنمن مانیتیت ۳/۲ میلی‌متر برآورد شد. با توجه به شکل (۴)، بیشترین میزان تبخیر تعرق در میان آمارهای موجود مربوط به تاریخ ۱۳۹۵/۰۳/۲۲ در هر دو روش سبال و پنمن مانیتیت است. نقشه پهنه‌بندی ET حاصل از اجرای الگوریتم سبال در منطقه مطالعاتی در تاریخ ۱۳۹۵/۰۳/۲۲ در شکل (۵) نشان داده شده است. کمترین میزان تبخیر تعرق با روش سبال مربوط به تاریخ ۱۳۹۶/۰۲/۰۷ است (شکل ۶).



شکل ۴- نمودار میله‌ای تبخیر تعرق روزانه حاصل از سبال و پنمن مانیتیت



شکل ۵- پهنه‌بندی تبخیر تعرق در تاریخ ۲۰۱۶/۱۱/۰۶ میلادی (۱۳۹۵/۰۳/۲۲ شمسی)



شکل ۶- پهنه‌بندی تبخیر تعرق در تاریخ ۲۰۱۷/۲۷/۰۴ میلادی (۱۳۹۶/۰۲/۰۷ شمسی)

تأثیر مثبت و مؤثر دمای هوا بر تبخیر تعرق و در نهایت بارش مؤثر است. پس از دمای متوسط، مقادیر همبستگی‌ها با بارش مؤثر به ترتیب مربوط به متغیرهای دمای حداکثر، GDD، حداکثر رطوبت نسبی، دمای حداقل، میانگین رطوبت نسبی، تبخیر، حداقل رطوبت نسبی، میانگین فشار بخار، ساعات آفتابی، بارش و متوسط سرعت باد است. مطابق جدول (۳) متغیرهای دمایی، GDD، ساعات آفتابی و تبخیر همبستگی مثبت با بارش مؤثر را نشان دادند و با افزایش مقادیر متغیرهای مذکور مقدار بارش مؤثر نیز افزایش می‌یابد و بالعکس. همچنین، متغیرهای سرعت باد، فشار بخار، بارش و رطوبت نسبی همبستگی منفی با بارش مؤثر نشان داده‌اند. درحالی‌که تأمین انرژی از خورشید و

نتایج بررسی همبستگی بارش مؤثر با متغیرهای هواشناسی

نتایج حاصل از میزان همبستگی میان متغیرهای هواشناسی با بارش مؤثر به روش همبستگی پیرسون در جدول (۳) نمایش داده شده است. با توجه به نتایج همبستگی‌ها، متغیر دمای میانگین روزانه بیشترین همبستگی را با بارش مؤثر دارد. تابش خورشیدی جذب‌شده توسط جو و گرمای ساطع‌شده از زمین باعث افزایش دمای هوا شده و گرمای محسوس هوای اطراف، انرژی را به محصول منتقل می‌کند؛ بنابراین، دمای هوا یک کنترل‌گر بر سرعت تبخیر و تعرق محسوب می‌شود (FAO 56). نتایج حاصل از بررسی میزان همبستگی‌ها نیز، نشانگر

جدول ۳- نتایج همبستگی متغیرهای هواشناسی با بارش مؤثر

میزان همبستگی	متغیرهای هواشناسی
-۰/۰۴۲۵	میانگین سرعت باد
۰/۸۷۱۷	حداکثر دما
۰/۷۶۱۳	حداقل دما
۰/۹۲۴۶	دمای متوسط
-۰/۴۳۶	میانگین فشار بخار
-۰/۳۳۹۴	بارش
-۰/۷۷۱۹	حداکثر رطوبت نسبی
-۰/۶۴۵۷	حداقل رطوبت نسبی
-۰/۷۳۹	متوسط رطوبت نسبی
۰/۳۷۰۲	ساعات آفتابی
۰/۷۲۹	تبخیر
۰/۸۶۷۱	GDD

نتایج شبکه عصبی

با توجه به نتایج همبستگی‌ها، متغیر دمای متوسط روزانه و GDD به‌عنوان دو متغیر دمایی و هم‌چنین متغیر حداکثر رطوبت نسبی به‌عنوان یک متغیر رطوبتی برای مدل‌سازی انتخاب شدند. سپس، شبکه‌هایی تحت سه سناریو (با متغیرهای مختلف ورودی) مطابق جدول (۴) و با الگوریتم‌های مختلف یادگیری همچون BR، GD.LM و GDM آموزش داده شد. ارزیابی عملکرد شبکه‌ها در تخمین بارش مؤثر با معیارهای ارزیابی خطای مجذور میانگین مربعات خطا (RMSE) و معیار خطای بایاس (MBE) صورت گرفت. نتایج ارزیابی عملکرد شبکه‌ها در تخمین بارش مؤثر در جدول (۴) نشان داده شده است. با توجه به نتایج جدول (۴)، خطای جذر میانگین مربعات خطا به ترتیب مربوط به الگوریتم‌های BR تحت سناریوی ۲ و ۳ و ۱، LM تحت سناریوی ۳ و ۲، GDM تحت سناریوی ۳ و ۱، GD تحت سناریوی ۱ و ۲ و ۳، LM تحت سناریوی ۱ و ۲ و ۳، GDM تحت سناریوی ۲ است. الگوریتم BR تحت سناریوی ۲ کمترین RMSE و الگوریتم GDM تحت سناریوی ۲، بیشترین RMSE را به خود اختصاص داده‌اند. با توجه به نتایج MBE در جدول (۴)، مقادیر تخمینی شبکه با الگوریتم BR تحت سناریوی ۲ کم برآورد و مقادیر تخمینی شبکه با الگوریتم BR


هوای اطراف نیروی محرکه اصلی برای تبخیر آب است، تفاوت بین فشار بخار آب در سطح تبخیر و هوای اطراف عامل تعیین‌کننده برای حذف بخار است. مزارع پرآب در مناطق گرم و خشک به دلیل انرژی فراوان و قدرت خشک‌کنندگی جو، مقادیر زیادی آب مصرف می‌کنند. در مناطق گرمسیری مرطوب، در چنین محیطی رطوبت هوا نزدیک به اشباع است و باوجود انرژی ورودی بالا، رطوبت زیاد هوا باعث کاهش تقاضای تبخیر تفرق می‌شود. از این رو، میزان تبخیر و تفرق در مناطق مرطوب کمتر از مناطق خشک است (FAO 56). نتایج حاصل از بررسی میزان همبستگی‌ها نیز، نشان از تأثیر منفی و مؤثر رطوبت هوا بر میزان تبخیر تفرق یا همان بارش مؤثر دارد. فرآیند تبخیر تفرق با مقدار انرژی موجود برای تبخیر آب تعیین می‌شود. تابش خورشیدی بزرگ‌ترین منبع انرژی است که قادر است آب مایع را به بخار آب تبدیل کند. تابش واقعی خورشید که به سطح تبخیر می‌رسد بستگی به شفافیت جو و وجود ابرهایی دارد که بخش‌های عمده‌ای از تابش را منعکس و جذب می‌کنند. هنگام ارزیابی اثر تابش خورشید بر تبخیر و تفرق، باید در نظر داشت که تمام انرژی موجود برای تبخیر آب استفاده نمی‌شود و بخشی از انرژی خورشیدی برای گرم کردن جو و مشخصات خاک استفاده می‌شود (FAO 56). نتایج بررسی همبستگی تبخیر تفرق و ساعات آفتابی نیز، نشانگر تأثیر مثبت و مؤثر این متغیر بر میزان تبخیر تفرق است. نتایج بررسی تأثیر متغیرهای دما بر میزان تبخیر تفرق، هم‌راستا با مطالعه لابودی و همکاران (Laaboudi et al., 2011) و نتایج بررسی تأثیر متغیرهای دما و GDD بر میزان تبخیر تفرق هم‌راستا با مطالعه محتشمی و لیاقت (۱۴۰۱) و هم‌چنین نتایج بررسی تأثیر متغیرهای بارش، دما و رطوبت نسبی بر میزان تبخیر تفرق هم‌راستا با پژوهش‌جیانگ و لیو (Jiang and Liu, 2022) است. نتایج حاصل از بررسی میزان همبستگی‌ها به انتخاب ورودی‌های مدل برای آموزش شبکه عصبی کمک خواهد کرد. در ادامه با به‌کارگیری متغیرهای مؤثر بر بارش مؤثر، به آموزش شبکه‌هایی تحت سناریوهای مختلف به‌منظور تخمین بارش مؤثر پرداخته می‌شود.

(۱۲) و جدول (۴) شبکه BR تحت سناریوی ۲ (متغیر دمای متوسط روزانه و GDD)، الگوریتم و سناریوی بهینه برای تخمین بارش مؤثر در این پژوهش شناخته شد. به طور کلی در تمامی سناریوها، الگوریتم BR دقت بیشتری در تخمین بارش مؤثر نشان داد. علاوه بر این، الگوریتم BR سرعت بیشتری در فرآیند آموزش شبکه نسبت به الگوریتم‌های GD و GDM دارا است. در شکل (۱۹) ساختار شبکه عصبی پیشخور تحت الگوریتم و سناریوی بهینه (الگوریتم BR سناریو ۲) و نحوه تأثیر وزن‌ها بایاس‌ها را بر متغیرهای ورودی دمای متوسط روزانه (p_1) و GDD (p_2) نشان داده شده است.


تحت سناریوی ۱ با MBE کمتر و بیش برآورد می‌باشند. همان‌طور که بیان شد، از میان شبکه‌های موجود شبکه تحت الگوریتم یادگیری BR با ورودی‌های دمای متوسط و GDD شبکه بهینه در برآورد بارش مؤثر شناخته شد. شکل‌های (۷) تا (۱۸) رفتار شبکه را در تخمین بارش مؤثر تحت الگوریتم‌ها و سناریوهای مختلف نشان می‌دهد. با توجه به نمودارهای مذکور، الگوریتم BR تحت سناریوی ۲ مقادیر تخمینی شبکه در تاریخ‌های ۱۴۰۰/۰۲/۱۸ تا ۱۴۰۱/۰۳/۲۲ نزدیک‌تر به مقادیر مشاهداتی و نمودارهای مقادیر مشاهداتی و تخمینی شبکه، انطباق بیشتری با یکدیگر دارند (شکل ۱۲). با توجه به شکل

جدول ۴- ارزیابی شبکه‌ها تحت سناریوها و الگوریتم‌های مختلف یادگیری

الگوریتم	سناریو	ورودی	خروجی	RMSE	MBE
LM	۱	دمای متوسط، حداکثر رطوبت نسبی، GDD	بارش مؤثر	۰/۳۳۱۳	-۰/۰۸۱۳
	۲	دمای متوسط، GDD	بارش مؤثر	۰/۲۰۱۳	-۰/۰۳۳۲
	۳	دمای متوسط	بارش مؤثر	۰/۱۹۹۰	۰/۰۰۳۱
GD	۱	دمای متوسط، حداکثر رطوبت نسبی، GDD	بارش مؤثر	۰/۲۴۲۳	۰/۰۳۴۱
	۲	دمای متوسط، GDD	بارش مؤثر	۰/۲۷۶۷	۰/۰۴۰۵
	۳	دمای متوسط	بارش مؤثر	۰/۲۸۸۱	-۰/۰۷۵۹
BR	۱	دمای متوسط، حداکثر رطوبت نسبی، GDD	بارش مؤثر	۰/۱۹۴۳	۰/۰۰۱۳
	۲	دمای متوسط، GDD	بارش مؤثر	۰/۱۸۹۹	-۰/۰۱۱۵
	۳	دمای متوسط	بارش مؤثر	۰/۱۹۴۴	-۰/۰۰۶۷
GDM	۱	دمای متوسط، حداکثر رطوبت نسبی، GDD	بارش مؤثر	۰/۲۲۸۳	۰/۰۲۱۳
	۲	دمای متوسط، GDD	بارش مؤثر	۰/۴۵۳۰	-۰/۱۱۳۵
	۳	دمای متوسط	بارش مؤثر	۰/۲۰۶۸	-۰/۰۰۸۸




شکل ۷- نمودار رفتار شبکه تحت الگوریتم LM و سناریوی ۱




شکل ۸- نمودار رفتار شبکه تحت الگوریتم BR و سناریوی ۱




شکل ۹- نمودار رفتار شبکه تحت الگوریتم GD و سناریوی ۱




شکل ۱۰- نمودار رفتار شبکه تحت الگوریتم GDM و سناریوی ۱




شکل ۱۱- نمودار رفتار شبکه تحت الگوریتم LM و سناریوی ۲




شکل ۱۲- نمودار رفتار شبکه تحت الگوریتم BR و سناریوی ۲




شکل ۱۳- نمودار رفتار شبکه تحت الگوریتم GD و سناریوی ۲




شکل ۱۴- نمودار رفتار شبکه تحت الگوریتم GDM و سناریوی ۲




شکل ۱۵- نمودار رفتار شبکه تحت الگوریتم LM و سناریوی ۳



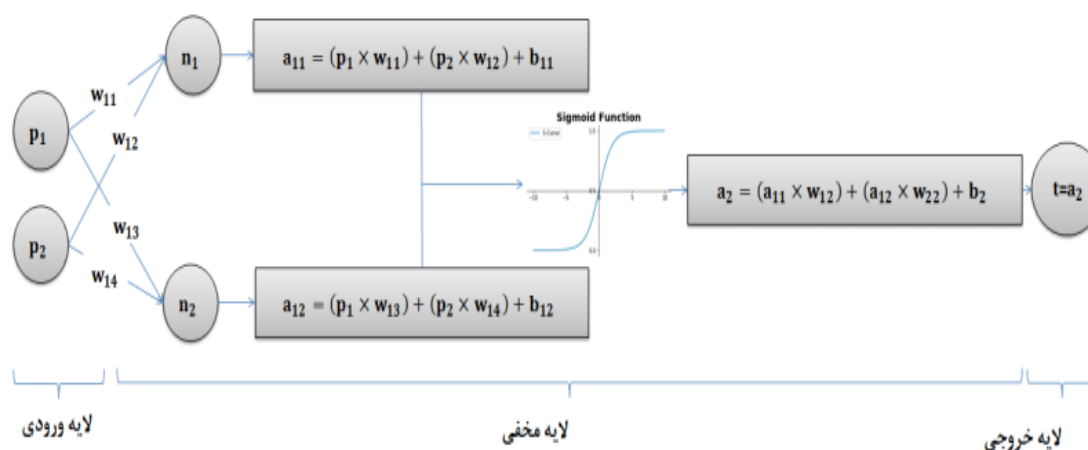
شکل ۱۶- نمودار رفتار شبکه تحت الگوریتم BR و سناریوی ۳



شکل ۱۷- نمودار رفتار شبکه تحت الگوریتم GD و سناریوی ۳



شکل ۱۸- نمودار رفتار شبکه تحت الگوریتم GDM و سناریوی ۳



شکل ۱۹- ساختار شبکه عصبی پیشخور تحت الگوریتم و سناریوی بهینه (الگوریتم BR سناریو ۲)

نتیجه‌گیری

به منظور استفاده بهینه آب در بخش کشاورزی و پروژه‌های زهکشی، شناخت و برآورد بارش مؤثر ضروری است. روش‌های تجربی متعددی برای برآورد بارش مؤثر ارائه شده‌اند؛ اما با توجه به اینکه روش‌های تجربی، خطای قابل توجهی برای برآورد بارش مؤثر دارند و بایستی متناسب با شرایط هر منطقه کالیبره شوند، در این پژوهش بارش مؤثر با اجرای الگوریتم بیلان انرژی سبال بر روی دشت کشت دیم شهرستان خمین برآورد و مدل مناسبی به منظور برآورد دقیق از بارش مؤثر در منطقه مورد نظر پیشنهاد شد. به این منظور ابتدا همبستگی میان بارش مؤثر و متغیرهای هواشناسی بررسی شد. بررسی میزان همبستگی‌ها نشان داد که بیشترین همبستگی متغیرهای هواشناسی با بارش مؤثر مربوط به متغیر دمای متوسط روزانه و سپس متغیرهای GDD و حداکثر رطوبت نسبی است؛ بنابراین، مدل‌هایی با ورودی‌های مختلف توأم دمای متوسط روزانه و GDD و حداکثر رطوبت نسبی و خروجی بارش مؤثر برآورد شده از الگوریتم سبال با استفاده از شبکه عصبی و با الگوریتم‌های مختلف یادگیری همچون GD, LM, BR و GDM توسعه داده شد. عملکرد این شبکه‌ها با استفاده از معیارهای میانگین مربعات خطا (RMSE) و میانگین خطای بایاس (MBE) مورد ارزیابی قرار گرفتند. نتایج نشان داد که الگوریتم BR با متغیرهای ورودی دمای متوسط و GDD با RMSE، $0/1944$ و MBE برابر با $0/115$ میلی‌متر قادر است بارش مؤثر را به صورت دقیق‌تری نسبت به الگوریتم‌ها و سناریوهای دیگر تخمین بزند. به طور کلی، شبکه‌هایی با الگوریتم‌های BR و LM عملکرد بهتری در برآورد بارش مؤثر و هم‌چنین سرعت بیشتری در عملیات و پردازش آموزش شبکه داشتند. نتایج نشان داد که مدل نهایی ارائه شده در این پژوهش با به کارگیری شبکه‌های عصبی و الگوریتم BR به کمک داده‌های هواشناسی که به سادگی قابل اندازه‌گیری می‌باشند، با دقت مناسبی می‌تواند تبخیر تفرق واقعی و در نهایت بارش مؤثر را برای محصول گندم در منطقه مورد نظر تخمین بزند. نتایج نشان داد، شبکه‌های عصبی که سازگار با طبیعت هستند، در پیش‌بینی بارش مؤثر

نتایج مطلوبی ارائه داده‌اند که این نتیجه هم‌راستا با مطالعات طاهری و همکاران (۱۳۸۹)، عظیمی و همکاران (۱۳۹۱) و محتشمی و لیاقت (۱۴۰۱) است.

منابع

- پورغلام آمیجی، م.، هوشمند، م.، رجا، ا. و لیاقت، م. ۱۳۹۸. پهنه‌بندی باران مؤثر در استان خوزستان تحت کشت گندم دیم پاییزه. مدیریت آب و آبیاری. ۹ (۲): ۲۳۰-۲۱۱.
- ثنایی نژاد، س. ح.، نوری، س. و هاشمی نیا، س. م. ۱۳۹۰. برآورد تبخیر و تفرق واقعی با استفاده از تصاویر ماهواره‌ای در منطقه مشهد. نشریه آب و خاک، ۲۵ (۳): ۵۴۷-۵۴۰.
- صحراگرد، س.، و ناصری، ع.، و الباجی، م.، و کابلی زاده، م. ۱۳۹۹. برآورد تبخیر و تفرق واقعی با الگوریتم توازن انرژی سطحی سبال و تصاویر تلفیق‌شده‌ی ماهواره‌ای لندست ۸ و سنتینل ۲ (مطالعه موردی: کشت و صنعت نیشکر میرزا کوچک خان). آبیاری و زهکشی ایران. ۱۴ (۱): ۱۶۷-۱۵۶.
- طاهری، پ.، افضل، ع. و طاهری، پ. ۱۳۸۹. مطالعه عملکرد شبکه‌های عصبی مصنوعی و رگرسیون نمایی در پیش‌بینی باران مؤثر. مهندسی آب. ۱ (۱): ۸۳-۷۵.
- عظیمی، ع.، رنگزن، ک.، کابلی زاده، م. و خرمیان، م. ۱۳۹۴. برآورد تبخیر و تفرق با استفاده از سنجش از دور، شبکه‌های عصبی مصنوعی و مقایسه نتایج آن با روش پنمن-مانتیث-فانو در باغات مرکبات شمال خوزستان. سنجش از دور و سامانه اطلاعات جغرافیایی در منابع طبیعی (کاربرد سنجش از دور و GIS در علوم منابع طبیعی). ۶ (۴): ۶۱-۷۵.
- عظیمی، و.، شبخعلیپور، ز. و طباطبایی، س. م. ۱۳۹۱. برآورد باران مؤثر با استفاده از سیستم استنتاج تطبیقی عصبی-فازی ANFIS. سومین همایش ملی مدیریت جامع منابع آب، ۲۰ و ۲۱ شهریور ماه ۱۳۹۱، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ساری.
- محتشمی، س. و لیاقت، ع. ۱۴۰۱. برآورد بارش مؤثر به روش حل معکوس و تخمین آن با به کارگیری هوش مصنوعی

- Estimation in Agriculture Using SEBAL and METRIC." *Hydrological Processes* 25 (26): 4011–4027.
- Fawzy, H. E.-D., A. Sakr, M. El-Enany, and H. M. Moghazy. 2021. Spatiotemporal Assessment of Actual Evapotranspiration Using Satellite Remote Sensing Technique in the Nile Delta, Egypt. *Alexandria Engineering Journal*. 60 (1): 1421–1432.
- Jakson, R. D., Hatfield, J. L., Reginato, S. B. and Pinter, Jr. 1983. Estimation of daily evapotranspiration from one time-of-day measurements. *Agriculture water management*, 7: 351-362.
- Jamshidi, S., Zand-Parsa, Sh. and Niyogi, D. 2021. Assessing Crop Water Stress Index of Citrus Using In-Situ Measurements, Landsat, and Sentinel-2 Data. *International Journal of Remote Sensing*. 42 (5): 1893-1916.
- Jiang, Y. and Liu, Zh. 2022. Simulation of actual evapotranspiration and evaluation of three complementary relationships in three parallel river basins. *Research Square*. Doi: 10.21203/rs.3.rs-1641674/v1.
- Kiş, Ö. and Öztürk, Ö. 2007. Adaptive neurofuzzy computing technique for evapotranspiration estimation. *Journal of Irrigation and Drainage Engineering*. 133 (4): 368-379.
- Kochhar, S. and Gujral, S. 2020. *Transpiration. Plant Physiology: Theory and Applications*. Cambridge: Cambridge University Press. 75-99. doi:10.1017/9781108486392.006
- Laaboudi, A., Mouhouche, B. and Draoui, B. 2011. Neural network approach to reference evapotranspiration modeling from limited climatic data in arid regions. *International Journal of Biometeorology*. 56(5): 831–841.
- Lavine, B. K. and Blank, T. R. 2009. Feed-Forward Neural Networks. *Comprehensive Chemometrics*. 571–586. doi:10.1016/b978-044452701-1.00026-0.
- Okut, H. 2016. Bayesian Regularized Neural Networks for Small n Big p Data. *Artificial Neural Networks - Models and Applications*. doi:10.5772/63256
- Paul, G., Gowda, P., Prasad, V., Howel, T. and Staggenborg, S. 2013. Lysimetric evaluation of SEBAL using high resolution airborne imagery (مطالعه موردی: استان کرمانشاه). مدل‌سازی و مدیریت آب و خاک. ۳(۱): ۲۴۹–۲۶۱.
- ملک‌پور، م.، بابازاده، ح.، کاوه، ف. و ابراهیمی پاک، ن. ع. ۱۳۹۵. برآورد تبخیر تعرق واقعی بهره‌وری آب گندم با استفاده از الگوریتم سبال و تصاویر ماهواره‌ای لندست ۵ در دشت قزوین. نشریه پژوهش آب در کشاورزی. ۳۰ (۴): ۵۸۲–۵۷۰.
- میرمحمدصادقی، ا.، قبادی نیا، م. و رحیمیان، م. ۱۳۹۸. برآورد تبخیر از سطح آزاد دریاچه سد زاینده‌رود با استفاده از سبال و مقایسه با روش‌های تجربی. نشریه آب و خاک. ۴ (۳۳): ۵۴۸–۵۳۷.
- میریعقوب زاده، م.، سلیمانی، ک.، حبیب نژادروشن، م.، شاهی، ک.، عباس پور، ک. و اخوان، س. ۱۳۹۳. تعیین و ارزیابی تبخیر و تعرق واقعی با استفاده از داده‌های سنجش از دور؛ مطالعه موردی حوزه آبخیز تهر، گلستان. مهندسی آبیاری و آب ایران. ۴ (۱۵): ۱۰۲–۸۹.
- هژبر، ح. ۱۳۹۱. مقایسه تبخیر و تعرق پتانسیل با روش پنمن مانیتیت اصلاح‌شده، مدل‌سازی شبکه عصبی مصنوعی و سیستم فازی با داده‌های لایسیمتری. پایان‌نامه کارشناسی ارشد، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز.
- Allen, R., Irmak, A., Trezza, R., Hendrickx, J. M. H., Bastiaanssen, W., & Kjaersgaard, J. 2011. Satellite-based ET estimation in agriculture using SEBAL and METRIC. *Hydrological Processes*, 25(26): 4011–4027.
- Allen, R.G., Pereira, L.S., Raes, D. and Smith, M. 1998. *Crop Evapotranspiration-Guidelines for Computing Crop Water Requirements-FAO Irrigation and Drainage Paper 56*. FAO, Rome. 300 (9): D05109.
- Brouwer, C. and Heibloem, M. 1986. *Irrigation Water Management: Irrigation Water Needs. Training Manual*, Food and Agriculture Organization of the United Nations, Rome, 3.
- David, M. 1977. *Geostatistical Ore Reserve Estimation*, Elsevier Scientific Publishing Co.364 .

- from BEAREX08. *Advances in Water Resources*. 59 (1): 157-168.
- Puig-Arnabat, M. and Bruno, J. C. 2015. Artificial Neural Networks for Thermochemical Conversion of Biomass. *Recent Advances in Thermo-Chemical Conversion of Biomass*. 133–156. doi:10.1016/b978-0-444-63289-0.00005-3
- Qian, N. 1999. On the momentum term in gradient descent learning algorithms. *Neural Networks*. 12(1): 145–151. doi:10.1016/s0893-6080(98)00116-6
- Silva, B., Mercante, E., Vilas Boas, M. and Costa Wrublack, S. 2018. Satellite-based ET estimation using Landsat 8 images and SEBAL model. *Scientific Article*. 2(49): 221-227.
- Tasumi, M., Trezza, R., Allen, R.G. and Wright, J.L. 2003. US Validation Tests on the SEBAL Model for Evapotranspiration Via Satellite. *ICID Workshop on Remote Sensing of ET for Large Regions*.
- Trezza, R. 2002. *Evapotranspiration Using a Satellite-Based Surface Energy Balance with Standardized Ground Control*. All Graduate Theses and Dissertations. 715.
- Waters, R., Allen, R., Tasumi, M., Trezza, R. and Bastiaanssen, W. 2002. *Surface Energy Balance Algorithms for Land*. Idaho Implementation. Advanced Training and Users Manual. Idaho Department of Water Resources.
- Zamani Losgedaragh, S. and Rahimzadegan, M. 2018. Evaluation of SEBS, SEBAL, and METRIC models in estimation of the evaporation from the freshwater lakes (Case study: amirkabir dam, Iran). *Journal of Hydrology*. 561: 523–531.

Estimating Effective Precipitation Using Remote Sensing and its Modeling with Meteorological Variables under Commonly Used Learning Algorithms and FFNN

S. Mohtashami¹ and Z.Aghashariatmadari^{*2}

Abstract

Precipitation is considered one of the most important components of hydrological cycle, and its effective and usable amount for plants is of great importance in the agricultural sector, especially rainfed cultivation. In this research, the effective precipitation (EP) in dry wheat fields of Khomein city was estimated by using RS and SEBAL on 28 available images from Landsat8 in the crop years 2014 to 2022. Penman-Monteith-Fao method was used to evaluate the accuracy of SEBAL. Then, a model of EP estimation was developed with ANN and meteorological data. For this purpose, the correlation between meteorological data and Growin Degree Days (GDD) with EP was investigated by Pearson's correlation method. the meteorological data of three stations from the closest synoptic stations to the study area were used and the meteorological data of the study area were interpolated using the Inverse Distance Weighting method (IDW). According to the results of the correlations, the average temperature parameter with a correlation of 0.92 and the GDD and the maximum relative humidity respectively with a correlation of 0.86 and -0.77 as effective variables in estimating EP. In the next step, the most effective parameters were used for modeling. the networks were trained under different scenarios, and the performance of the networks was evaluated using the RMSE and MBE error criteria. The results showed that by using the BR learning algorithm and having the variables of daily temperature and GDD, it is possible to predict the amount of EP for the target area with very good accuracy. The RMSE value of this model was 0.1899 mm and MBE was estimated as -0.0115 mm. By using the presented model, with simple meteorological variables, the actual evapotranspiration and finally the EP of the desired area can be determined with appropriate accuracy without the need to solve complex algorithms.

Keywords: Effective precipitation, Evapotranspiration, Feedforward Neural network, Learning algorithm, SEBAL algorithm

¹ Department of Irrigation Engineering, Faculty of Agriculture, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran

² Department of Irrigation Engineering, Faculty of Agriculture, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran (* Corresponding Author Email: zagha@ut.ac.ir)

Received: 21 Dec 2022

Accepted: 6 Feb 2023