

بهبود برآورد تبخیر-تعرق پتانسیل با استفاده از ضریب اصلاحی به کمک مدل درخت تصمیم M5

حسین شریفان^{۱*}، خلیل قربانی^۲

تاریخ دریافت: ۱۳۹۲/۶/۴ تاریخ پذیرش: ۱۳۹۲/۱۲/۷

چکیده

تبخیر و تعرق از اساسی‌ترین اجزای چرخه‌ی هیدرولوژی است که تعیین صحیح آن در علوم آب از قبیل مطالعات توازن هیدرولوژیکی، طراحی و مدیریت سیستم‌های آبیاری از اهمیت بالایی برخوردار است. پژوهش حاضر امکان بهبود دقت برآورد تبخیر-تعرق به روش هارگریوز-سامانی را بر اساس ضریب اصلاحی k بررسی می‌کند. این ضریب که نسبت برآورد تبخیر-تعرق با دو روش فائو پنمن-مانتیت (F-P-M) و هارگریوز-سامانی می‌باشد بر اساس متغیرهای هواشناسی مانند دمای هوا، رطوبت نسبی و دمای نقطه شبنم با استفاده از مدل درختی M5 و شبکه عصبی مصنوعی در سه ایستگاه هواشناسی آستارا، بندرانزلی و رشت برآورد گردید. برای انجام این کار، یک دوره آماری ۳۰ ساله (۱۳۶۰-۱۳۹۰) در نظر گرفته شد و داده‌ها برای هر ایستگاه بر اساس نسبت ۸۰ به ۲۰ درصد به داده‌های آموزش و آزمون تقسیم‌بندی شدند. سپس مقدار k محاسبه شده در تبخیر-تعرق برآورد شده به روش هارگریوز سامانی ضرب شد. نتایج نشان داد که مدل درختی M5 نسبت به شبکه عصبی مقدار k را بهتر برآورد می‌کند و با این روش میانگین اختلاف بین مقدار برآورد شده به روش هارگریوز-سامانی و پنمن-مانتیت به ترتیب برای ایستگاه‌های آستارا، بندرانزلی و رشت از ۰/۴۱، ۰/۵۵ و ۰/۷ به ۰/۳۱، ۰/۳۸ و ۰/۲۸ کاهش می‌یابد.

واژه‌های کلیدی: تبخیر-تعرق پتانسیل، ضریب اصلاحی، هارگریوز-سامانی، درخت تصمیم، M5

مقدمه

تبخیر-تعرق از اساسی‌ترین اجزای چرخه‌ی هیدرولوژی است که تعیین صحیح آن در علوم آب از قبیل مطالعات توازن هیدرولوژیکی، طراحی و مدیریت سیستم‌های آبیاری از اهمیت بالایی برخوردار است (Alen et al, 1998).
مطالعات تفصیلی و خیلی از تحقیقات دیگر، کار برجسته و فوق العاده پنمن-مانتیت را تأیید کرده‌اند. کمیته فنی نیازهای آبی بخش آبیاری و زهکشی در انجمن مهندسان راه و ساختمان آمریکا (ASCE) در کتابی تحت عنوان آب مصرفی گیاهان و آب مورد نیاز آبیاری، ۲۰ روش محاسبه ET_0 را بطور ماهانه در مناطق خشک و مرطوب بر اساس نتایج لایسیمتری مورد مقایسه قرار داد و در هر دو منطقه روش پنمن-مانتیت اصلاح شده توسط فائو در اولویت قرار گرفت (Jensen et al, 1990).

از بین روش‌های تجربی متعدد ارائه شده برای محاسبه ET_0 ، در سال ۱۹۹۰ از سوی کمیسیون بین‌المللی آبیاری و زهکشی (ICID)^۱ و سازمان خواروبار جهانی (FAO)، روش فائو-پنمن-مانتیت به‌عنوان تنها روش استاندارد برای محاسبه ET_0 و نیز جهت ارزیابی سایر روش‌ها پیشنهاد گردید (Hargreaves, 1994).

در تحقیقی روش‌های فائو پنمن-مانتیت (F-P-M) و هارگریوز-سامانی (H-S) در شش ایستگاه لایسی-متری واقع در اسپندال (Aspendal)، براولی (Brawley)، دیویس (Davise)، و کیمبرلی (Kimberly) با آب و هوای خشک (متوسط رطوبت نسبی روزانه در مرطوب‌ترین ماه کم‌تر از ۶۰ درصد) و لم پوک (lom poc)، و سیبروک (Seabrook) با آب و هوای مرطوب (متوسط رطوبت نسبی روزانه در مرطوب‌ترین ماه بیش‌تر از ۶۰ درصد) مورد مقایسه قرار گرفت. در این تحقیق نتیجه گرفته شد که روش F-P-M و روش H-S با هم تفاوت اندکی دارند (Jensen et al, 1997).

از سال ۱۳۶۶ به مدت ۱۰ سال، فرشی و همکاران، تحقیقی در

۱- دانشیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان

۲- استادیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی

* - نویسنده مسئول: (Email: h_sharifan@yahoo.com)

صرف زمان کمتری در اثر کاهش لایه‌های پنهان تا یک حدی می‌توان به برآوردهای مناسب‌تری دست یافت. رحیمی‌خوب (۱۳۸۵) در تحقیقی در منطقه خوزستان، مقادیر تبخیر-تعرق برآورد شده از روش هارگریوز و شبکه عصبی را با مقادیر روش استاندارد مقایسه نمود. نتایج نشان داد که عملکرد روش هارگریوز برای مناطق مختلف استان خوزستان متفاوت است و تبخیر-تعرق گیاه مرجع را در نقاط مختلف استان کمتر و بیش‌تر از روش پنمن-مانتیت برآورد می‌کند. ولی مدل تدوین شده شبکه عصبی مصنوعی با دقت بهتری، تبخیر-تعرق گیاه مرجع را برآورد می‌کند.

طی سالیان اخیر شبکه‌های عصبی مصنوعی (ANN) به عنوان یکی از روش‌های هوشمند که با الهام از سلول عصبی زیستی طراحی شده‌اند توانایی عالی خود را در مدل‌سازی پدیده‌هایی با ماهیت غیرخطی و پیچیده در مسائل مهندسی آب نشان داده‌اند (Ahmad & Simonovic, 2005).

پال و دسوال از مدل درختی M5 برای مدل‌سازی تبخیر-تعرق پتانسیل در ایستگاه دایوس در کالیفرنیا استفاده کردند و پتانسیل این مدل را با روش‌های پنمن-مانتیت فائو ۵۶ و هارگریوز-سامانی کالیبره شده مقایسه نمودند. نتایج نشان می‌دهند که رویکرد مدل درختی M5 در پیش‌بینی تبخیر-تعرق مرجع در مقایسه با FAO56 و هارگریوز سامانی کالیبره شده به‌خوبی کار می‌کند، علاوه بر این، از این مطالعه نتیجه‌گیری نمودند که این رویکرد با مجموعه داده‌های مستقل گرفته شده از مناطق مختلف به‌خوبی کار می‌کند. آن‌ها هم-چنین دریافتند که تابش خورشید، متوسط درجه حرارت، متوسط رطوبت نسبی و متوسط سرعت باد از مهم‌ترین پارامترهای مؤثر بر پیش‌بینی تبخیر-تعرق مرجع با استفاده از مدل درختی M5 می‌باشند (Pall & Deswal, 2009). سامتی و همکاران (۱۳۹۰) نتایج برآورد تبخیر-تعرق در ایستگاه هواشناسی شیراز را به کمک مدل درختی M5 و هارگریوز سامانی با نتایج روش پنمن-مانتیت مقایسه کردند و نتیجه گرفتند که مدل درختی M5 با ضریب تبیین ۰/۹۷۵ نسبت به روش هارگریوز سامانی با ضریب تبیین ۰/۸۳۷ تطابق بهتری با روش پنمن-مانتیت دارد. در مطالعاتی که به آن‌ها اشاره شد بیش‌تر آنها تبخیر-تعرق را در مقیاس زمانی روزانه مورد مطالعه قرار دادند.

رحیمی‌خوب با استفاده از شبکه‌های عصبی مصنوعی تبخیر روزانه از تشت را برآورد نمود. او با استفاده از داده‌های مرکز تحقیقات صفی‌آباد واقع در دشت خوزستان در جنوب ایران به این نتیجه رسید که هر دو روش تجربی و شبکه عصبی مصنوعی توافق خوبی با مقادیر اندازه‌گیری شده دارند اما روش شبکه عصبی مصنوعی در مقایسه با روش هارگریوز کالیبره شده تخمین‌های بهتری ارائه می‌دهد (Rahimi khob, 2008). دیامانتوپولو و همکاران عملکرد شبکه‌های عصبی مصنوعی را در تخمین تبخیر-تعرق پتانسیل با حداقل داده هواشناسی بررسی نمودند. آن‌ها در بررسی خود از داده

باره تهیه یک برنامه کامپیوتری جهت تعیین تبخیر-تعرق سطح مرجع چمن بر اساس روش پنمن-مانتیت برای ایستگاه‌های سینوپتیک ایران انجام دادند. ایشان برای نقاطی که از نظر آماری فاقد یک سری اطلاعات هواشناسی بود (حدود ۳۰٪ نقاط ایران) از روش‌های فائو-بلانی-کریدل و H-S استفاده نمودند (فرشی و همکاران، ۱۳۷۶). در طی سالیان اخیر مطالعات ارزنده‌ای توسط محققان بر روی تبخیر-تعرق با استفاده از روش‌های هوشمند انجام شده است. از جمله این مطالعات می‌توان به براتون و همکاران و همچنین کسکین و ترزی و پرسمن و همکاران اشاره کرد (Bruten et al, 2000)، (Keskin & Terzi, 2006)، (Parasuraman et al, 2007). اوزگور کیسی برای مدل‌سازی تبخیر ماهانه در سه ناحیه از ایالت کالیفرنیا، با استفاده از پارامترهای هواشناسی (دمای هوا، سرعت باد، رطوبت، فشار و تابش خورشیدی) و روش شبکه عصبی مصنوعی به برآورد تبخیر پرداخت. نتایج ایشان نشان داد که شبکه‌های عصبی مصنوعی (RBF, MLP) را در مقایسه با روش‌های (رگرسیون خطی چندمتغیره و -Stephens Stewart) با معیارهای سنجش آماری مختلف، از کارایی و دقت بالاتری برخوردار بودند (Ozgur Kisi, 2007). همچنین جابین و همکاران تبخیر-تعرق را با استفاده از شبکه‌های عصبی محاسبه نمودند آن‌ها ضمن تأیید کارایی شبکه‌های عصبی در تخمین این پدیده، همچنین نشان دادند شبکه‌های عصبی قادرند با استفاده از داده‌های محدود آب و هوایی نیز این پدیده را با دقت مناسبی برآورد نمایند (Jain et al, 2008). دیامبو و همکاران با استفاده از شبکه‌های عصبی فازی تبخیر-تعرق گیاه مرجع چمن را تخمین زدند (Diamantopoulou et al, 2010). تراچکوپولوس (۲۰۰۹) برای محاسبه تبخیر-تعرق در منطقه‌ی پولیکارو (ایتالیا) از شبکه‌ی تابع پایه شعاعی (RBF) و روش‌های کریستیانسن^۱، پنمن و پنمن-مانتیت فائو استفاده نمود. نتایج حاصل نشان داد که شبکه‌ی تابع پایه شعاعی نسبت به بقیه روش‌ها در مقایسه با نتایج حاصل از لایسی‌متر وزنی از خطای کمتری برخوردار است.

شایان نژاد (۱۳۸۵) با استفاده از اطلاعات اقلیمی و لایسی‌متری ۵ ساله در ایستگاه هواشناسی اکباتان همدان، تبخیر-تعرق را با دو روش شبکه عصبی مصنوعی و پنمن-مانتیس محاسبه نمود. نتایج نشان داد مقدار خطای به‌دست آمده از شبکه عصبی و پنمن-مانتیت به ترتیب برابر ۰/۷ و ۱/۲ میلی‌متر بر روز بوده است. همچنین قاسمی و همکاران (۱۳۸۶) برای منطقه همدان، مقدار تبخیر-تعرق گیاه مرجع را با استفاده از شبکه عصبی مصنوعی پیش‌بینی نموده و این مقادیر را با روش‌های بلانی-کریدل و پنمن-مانتیت مقایسه نمودند. بررسی ایشان نشان از برتری شبکه عصبی مصنوعی نسبت روش بلانی-کریدل داشت. همچنین تحقیق ایشان نشان داد که با

روش‌های برآورد معادلات ضریب اصلاحی

برای برآورد معادلات مناسب ضریب اصلاحی ابتدا این ضریب به روش نسبی (تقسیم مقادیر روش پنمن-مانتیت بر مقادیر روش هارگریوز-سامانی) محاسبه شد. داده‌ها نیز به دو گروه آموزش یا واسنجی (۸۰ درصد داده‌ها) و آزمون یا صحت‌سنجی (۲۰ درصد داده‌ها) تقسیم شدند. سپس با در نظر گرفتن مقادیر ضریب k به عنوان متغیر وابسته و پارامترهای دمای حداکثر، دمای حداقل، دمای متوسط، تفاضل دمای حداکثر و حداقل و رطوبت نسبی به عنوان متغیرهای مستقل معادلات ضریب اصلاحی محاسبه شد (رابطه ۳).

$$k = \frac{P.M.F.}{H.S.} \quad (3)$$

همچنین از پارامترهای ترکیبی که از پارامترهای فوق محاسبه شده، در برآورد معادلات ضریب اصلاحی استفاده شده است. روش-های برآورد معادلات ضریب اصلاحی به شرح زیر است.

مدل درخت تصمیم M5

درخت‌های تصمیم روشی برای نمایش یک سری از قوانین هستند که منتهی به یک رده یا مقدار می‌شوند. درخت‌های تصمیم به کمک جداسازی متوالی داده‌ها به یک سری گروه مجزا تشکیل شده و سعی می‌شود در فرآیند جداسازی، فاصله بین گروه‌ها افزایش یابد. ساختار یک مدل درختی شامل ریشه، گره‌های داخلی و برگ می‌باشد. از مدل‌های درخت تصمیم در حل بسیاری از مسائل طبقه‌بندی و رگرسیون استفاده شده است. برای اولین بار کوینلان (Quinlan, 1992) مدل درخت تصمیم موسوم به M5 را برای پیش‌بینی داده‌های پیوسته ارائه نمود. این مدل، بر خلاف مدل‌های درخت تصمیم معمول که کلاس یا رده‌های گسسته را به عنوان خروجی ارائه می‌نمایند، یک مدل خطی چندمتغیره را برای داده‌ها در هر گره از مدل درختی می‌سازد. تشکیل ساختار مدل‌های درخت تصمیم‌گیری شامل مراحل ایجاد درخت و هرس کردن آن است (Quinlan, 1992, Witten & Frank, 2005). در مرحله ساختن درخت، از یک الگوریتم استنتاجی یا معیار تقسیم (انشعاب) برای تولید یک درخت تصمیم استفاده می‌شود. معیار تقسیم برای الگوریتم مدل M5، ارزیابی انحراف معیار مقادیر کلاسی است که به عنوان کمیتی از خطا به یک گره می‌رسد و کاهش مورد انتظار در این خطا را به عنوان نتیجه‌ی آزمون هر صفت در آن گره محاسبه می‌نماید. کاهش انحراف معیار^۱ (SDR) از رابطه ۴ بدست می‌آید:

$$SDR = sd(T) - \sum \frac{|T_i|}{|T|} sd(T_i) \quad (4)$$

ایستگاه خودکار هواشناسی واقع در ایستگاه پیریا در شمال یونان استفاده نمودند و نتیجه گرفتند با در نظر گرفتن متوسط، ماکزیمم و مینیمم دما، مدل‌های انتخابی شبکه عصبی مصنوعی تخمین‌های روزانه تبخیر-تعرق پتانسیل را در مقایسه با معادله‌ی هارگریوز اصلاح شده به صورت قابل توجهی بهبود می‌دهند (Diamantopoulou et al., 2010).

از آنجا که بسیاری از ایستگاه‌های هواشناسی فاقد پارامترهای مورد نیاز برای برآورد تبخیر-تعرق با روش‌های گروه پنمن می‌باشند لذا هدف از انجام این تحقیق پیشنهاد و بررسی یک ضریب اصلاحی بر اساس نسبت پنمن به هارگریوز-سامانی می‌باشد که این مهم براساس پارامترهای هواشناسی به کمک مدل درخت تصمیم M5 انجام و نتایج آن با شبکه عصبی مصنوعی مقایسه می‌شود.

مواد و روش‌ها

این پژوهش بر اساس داده‌های ایستگاه‌های هواشناسی آستارا، بندرانزلی و رشت که به صورت روزانه طی دوره آماری ۱۳۶۰-۱۳۹۰ از سازمان هواشناسی کشور اخذ گردید انجام شده است. داده‌های هواشناسی مورد نیاز برای ضریب اصلاحی k شامل دمای حداکثر، دمای حداقل و رطوبت نسبی می‌باشد ولی برای برآورد تبخیر-تعرق به روش پنمن-مانتیت علاوه بر این داده‌ها از تابش خالص خورشیدی، ساعات آفتابی، سرعت باد نیز استفاده شد. با توجه به هدف اصلی در این تحقیق که ارائه مناسب‌ترین ضریب اصلاحی برای تصحیح معادله هارگریوز-سامانی بود، لذا برای ارزیابی معادله اصلاحیه آن از معادله (F-P-M) به عنوان روش استاندارد استفاده شد (رابطه ۱).

$$ET_0 = \frac{0.408 \Delta (R_n - G) + \gamma \frac{900}{T + 273.15} u_2 (e_s - e_a)}{\Delta + \gamma (1 + 0.34 u_2)} \quad (1)$$

و در روش هارگریوز-سامانی که فقط به دو پارامتر دمای حداکثر و حداقل نیاز است (رابطه ۲)

$$ET_0 = 0.0023 R_n (T + 17.8) (T_{max} - T_{min})^{0.5} \quad (2)$$

که در آن‌ها ET_0 تبخیر-تعرق گیاه مرجع (R_n , mm/day) تابش خالص در سطح پوشش گیاهی (G , MJ/m².day) شار گرما به داخل خاک (T , MJ/m².day) متوسط دمای هوا در ارتفاع دو متری از سطح زمین (U_2 , °C) سرعت باد در ارتفاع دو متری از سطح زمین (e_a , m/s) فشار بخار واقعی (e_s , kPa) فشار بخار اشباع (Δ , kPa) شیب منحنی فشار بخار اشباع برحسب دما (γ , kPa/°C) ضریب رطوبتی (ثابت سایکرومتری) (R_n , kPa/°C) میانگین تشعشع فرازمینی بر حسب میلی‌متر در روز، T میانگین دمای روزانه هوا، T_{max} میانگین حداکثر دمای روزانه هوا و T_{min} میانگین حداقل دمای روزانه هوا همگی بر حسب درجه سانتی‌گراد می‌باشد.

دیده می‌تواند برای پیش‌بینی خروجی‌های متناسب با مجموعه جدید داده‌ها به کار رود (Dayhoff, 1990).

معیارهای ارزیابی مدل

در این تحقیق از پارامترهای آماری ضریب همبستگی (R) برای تعیین همبستگی بین مقادیر پیش‌بینی شده و اندازه‌گیری شده، ریشه دوم میانگین مربعات خطا (RMSE) و متوسط خطای مطلق (MAE) برای نشان دادن بزرگی خطا و میانگین خطای اریب (MBE) برای نشان دادن بیش برآورد (مقادیر مثبت) و کم برآورد مدل (مقادیر منفی) به عنوان معیارهای ارزیابی مورد استفاده قرار گرفتند (روابط ۵ تا ۸).

$$R = \left(\frac{\sum xy}{\sqrt{\sum x^2 \sum y^2}} \right) \quad (۵)$$

$$RMSE = \sqrt{\frac{\sum (X - Y)^2}{n}} \quad (۶)$$

$$MAE = \frac{\sum |X - Y|}{n} \quad (۷)$$

$$MBE = \frac{\sum (X - Y)}{n} \quad (۸)$$

که $x = X - \bar{X}$ ، $y = Y - \bar{Y}$ ، X مقدار مشاهداتی، Y مقدار محاسباتی، \bar{X} میانگین مقادیر مشاهداتی، \bar{Y} میانگین مقادیر محاسباتی و n تعداد داده‌ها است.

نتایج و بحث

بعد از تفکیک داده‌ها به دو بخش آموزش و آزمون، مدل درختی M5 بر روی داده‌های آموزش برازش داده شد. در این مرحله داده‌ها به گروه‌هایی دسته‌بندی شدند و برای هر دسته یک مدل رگرسیون چند متغیره خطی (LM) ارائه شد. نمونه‌ای از این دسته‌بندی و معادلات رگرسیونی برای ایستگاه بندرانزلی به صورت زیر می‌باشد:

$$\begin{aligned} & RH \leq 82.85 : \\ & | \quad TD \leq 3.85 : \\ & | \quad | \quad TD \leq 2.55 : LM1 \\ & | \quad | \quad TD > 2.55 : LM2 \\ & | \quad TD > 3.85 : \\ & | \quad | \quad Tave \leq 24.45 : \\ & | \quad | \quad | \quad RH \leq 72.85 : \\ & | \quad | \quad | \quad | \quad RH \leq 58.15 : LM3 \\ & | \quad | \quad | \quad | \quad RH > 58.15 : LM4 \\ & | \quad | \quad | \quad RH > 72.85 : \end{aligned}$$

که T_i بیانگر یک سری نمونه‌هایی است که به گره می‌رسد، بیانگر نمونه‌هایی است که i امین خروجی سری پتانسیلی را دارند و sd بیانگر انحراف معیار است. به دلیل فرآیند انشعاب، داده‌های قرار گرفته در گره‌های فرزند، انحراف معیار کم‌تری نسبت به گره مادر داشته و بنابراین خالص‌تر هستند. پس از حداکثرسازی تمامی انشعاب‌های ممکن، M5 صفتی را انتخاب می‌کند که کاهش مورد انتظار را بیشینه نماید. این تقسیم اغلب ساختار شبه‌درختی بزرگی را تشکیل می‌دهد که باعث بیش‌برازش می‌گردد. برای غلبه بر مسئله‌ی بیش‌برازش، درخت تشکیل شده بایستی هرس شود. این کار با جایگزینی یک درخت فرعی با یک برگ انجام می‌شود. بنابراین، مرحله دوم در طراحی مدل درختی شامل هرس نمودن درخت رشد یافته و جایگزینی درختان فرعی با توابع رگرسیونی خطی است. این تکنیک تولید مدل درختی، فضای پارامترهای ورودی را به نواحی یا زیر فضاهای کوچک‌تر تقسیم نموده و در هر کدام از آن‌ها، یک مدل رگرسیونی خطی برازش می‌دهد. بعد از اینکه مدل خطی به دست آمد برای کمینه کردن خطای تخمین با حذف کردن پارامترها، ساده‌سازی مدل انجام می‌شود. در مدل M5 از یک جستجوی حریصانه برای حذف متغیرهایی که مشارکت کمی در مدل دارند، استفاده می‌شود البته گاهی اوقات همه متغیرها حذف شده و فقط یک مقدار ثابت باقی می‌ماند.

شبکه عصبی مصنوعی

شبکه‌ی عصبی مصنوعی، یکی از روش‌های محاسباتی است که به کمک فرآیند یادگیری و با استفاده از پردازشگرهایی به نام نرون تلاش می‌کند با شناخت روابط ذاتی بین داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. لایه یا لایه‌های مخفی، اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهند. هر شبکه با دریافت مثال‌هایی آموزش می‌بیند. آموزش فرایندی است که در نهایت منجر به یادگیری می‌شود. یادگیری شبکه، زمانی انجام می‌شود که وزن‌های ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف بین مقادیر پیش‌بینی شده و محاسبه شده در حد قابل قبولی باشد. با دست‌یابی به این شرایط فرایند یادگیری محقق شده است. شبکه عصبی آموزش

```

| | | | TD <= 6.35 :
| | | | | Tave <= 18.35 : LM5
| | | | | Tave > 18.35 :
| | | | | TD <= 4.55 : LM6
| | | | | TD > 4.55 : LM7
| | | | | TD > 6.35 : LM8
| | | | | Tave > 24.45 : LM9
RH > 82.85 :
| TD <= 2.35 :
| | RH <= 90.35 :
| | | TD <= 1.55 :
| | | | TD <= 1.05 : LM10
| | | | TD > 1.05 :
| | | | | Tave <= 8.05 : LM11
| | | | | Tave > 8.05 : LM12
| | | | | TD > 1.55 : LM13
| | | | | RH > 90.35 :
| | | | | TD <= 1.25 : LM14
| | | | | TD > 1.25 : LM15
| | | | | TD > 2.35 :
| | | | | Tave <= 21.75 :
| | | | | TD <= 5.35 : LM16
| | | | | TD > 5.35 :
| | | | | Tave <= 14.85 : LM17
| | | | | Tave > 14.85 : LM18
| | | | | Tave > 21.75 : LM19
LM 1: K= 0.0007 * Tave - 0.6496 * TD - 0.053 * RH + 7.1116
LM 2: K= 0.0056 * Tave - 0.1395 * TD - 0.0248 * RH + 3.6444
LM 3: K= 0.0323 * Tave - 0.0974 * TD - 0.0396 * RH + 4.203
LM 4: K= 0.0082 * Tave - 0.0196 * TD - 0.0238 * RH + 2.8922
LM 5: K= 0.0011 * Tave - 0.0723 * TD - 0.0187 * RH + 2.9471
LM 6: K= -0.0013 * Tave + 0.2459 * TD - 0.0016 * RH + 0.4228
LM 7: K= 0.0001 * Tave - 0.0085 * TD - 0.0016 * RH + 1.3574
LM 8: K= 0.0124 * Tave - 0.0271 * TD - 0.0086 * RH + 1.7074
LM 9: K= 0.0323 * Tave - 0.0416 * TD - 0.0038 * RH + 0.969
LM 10: K= 0.0002 * Tave - 1.4283 * TD - 0.0184 * RH + 4.7663
LM 11: K= -0.003 * Tave - 0.2872 * TD - 0.022 * RH + 3.9029
LM 12: K= -0.0021 * Tave - 0.2872 * TD - 0.0296 * RH + 4.4965
LM 13: K= 0.0002 * Tave - 0.3752 * TD - 0.0369 * RH + 5.2683
LM 14: K= -0.0001 * Tave - 0.7236 * TD - 0.0589 * RH + 7.6326
LM 15: K= -0.0024 * Tave - 0.2588 * TD - 0.0466 * RH + 5.9454
LM 16: K= 0.0045 * Tave - 0.0627 * TD - 0.0262 * RH + 3.5338
LM 17: K= 0.0007 * Tave - 0.0154 * TD - 0.0127 * RH + 2.0398
LM 18: K= 0.0108 * Tave - 0.028 * TD - 0.0275 * RH + 3.3642
LM 19: K= 0.0476 * Tave - 0.0345 * TD - 0.0265 * RH + 2.4778

```

۱). بر اساس این داده‌ها با استفاده از شبکه عصبی مصنوعی نیز مقدار K برآورد و نتایج آن در جدول ۲ ارائه شد. مقایسه نتایج حاصل از این دو روش نشان داد که در تمامی ایستگاه‌های مطالعاتی مدل درختی M5 مقادیری را که پیش‌بینی می‌کند با مقادیر مشاهداتی همبستگی بیشتری را دارند.

با توجه به اینکه مدل درختی M5 مقدار k را با دقت بالاتری نسبت به شبکه عصبی پیش‌بینی کرد از نتایج مدل M5 استفاده شد تا افزایش دقت برآورد تبخیر-تعرق با استفاده از روش هارگریوز-سامانی اصلاح شده نسبت به روش پنمن مانیت بررسی شود (جدول

الگوی درختی مربوط به ایستگاه انزلی یک الگوی درختی دو انشعابی است که ابتدا بر اساس رطوبت نسبی داده‌ها به دو دسته تقسیم می‌شوند سپس برای هر دسته دیگر انشعابات دودویی انجام می‌شود. بعد از ساخت مدل درختی برای هر ایستگاه، بر اساس معادلات مربوطه و با استفاده از داده‌های آموزش و آزمون، مقادیر پیش‌بینی شده توسط مدل محاسبه شد و بر اساس مقادیر مشاهده شده و پیش‌بینی شده، ضرایب همبستگی بین آن‌ها و همچنین معیارهای ارزیابی خطا شامل ریشه میانگین مربعات خطا و میانگین خطای مطلق که بزرگی خطا را نشان می‌دهند محاسبه شدند (جدول

۳). مقدار ضریب K برآورد شده توسط مدل درختی M5 در مقدار تبخیر-تعرق محاسبه شده به روش هارگریوز سامانی ضرب و مقدار آن با مقادیر محاسباتی روش پنمن مانیتیت با معیارهای ارزیابی خطا

جدول ۱- نتایج برآورد K به روش درخت تصمیم M5


ایستگاه	داده	ضریب همبستگی	ریشه میانگین مربعات خطا	میانگین خطای مطلق
بندر انزلی	آموزش	۰/۷۵	۰/۲	-۰/۱۶
	آزمون	۰/۷۱	۰/۲۲	-۰/۱۷
آستارا	آموزش	۰/۷۷	۰/۱۶۵	-۰/۱۱۹
	آزمون	۰/۷۲	-۰/۱۶۷	-۰/۱۲۳
رشت	آموزش	۰/۹	-۰/۱۴۷	-۰/۰۹
	آزمون	۰/۹۱	۰/۱۲۸	-۰/۰۸۵

جدول ۲- نتایج برآورد K به روش شبکه عصبی مصنوعی


ایستگاه	داده	ضریب همبستگی	ریشه میانگین مربعات خطا	میانگین خطای مطلق
بندر انزلی	آموزش	۰/۶۷	۰/۲۴	-۰/۱۷۷
	آزمون	۰/۶۹	۰/۲۳	-۰/۱۷۸
آستارا	آموزش	۰/۶۶	-۰/۱۹۴	-۰/۱۴۳
	آزمون	۰/۶۹	-۰/۱۷۷	-۰/۱۴
رشت	آموزش	۰/۸۵	۰/۱۷۵	-۰/۱۱۶
	آزمون	۰/۸۷	-۰/۱۴۸	-۰/۱۰۶

جدول ۳- نتایج استفاده از ضریب اصلاحی k در برآورد تبخیر-تعرق به روش هارگریوز در مقایسه با روش پنمن مانیتیت


ایستگاه	روش	ضریب همبستگی	ریشه میانگین مربعات خطا	میانگین خطای مطلق	میانگین خطای اریب
بندر انزلی	بدون استفاده از K	۰/۹۱	۰/۷۸	۰/۵۵	-۰/۳۵
	با استفاده از K	۰/۹۴	۰/۵۶	۰/۳۸	-۰/۰۵
آستارا	بدون استفاده از K	۰/۹۲	۰/۶	۰/۴۱	-۰/۱۸
	با استفاده از K	۰/۹۵	۰/۴۸	۰/۳۱	-۰/۰۲
رشت	بدون استفاده از K	۰/۸۸	۰/۹۴	۰/۷	۰/۵۲
	با استفاده از K	۰/۹۶	۰/۴۷	۰/۲۸	-۰/۰۷



شکل ۱- نمودار پراکنش تبخیر-تعرق محاسبه شده به روش هارگریوز (سمت چپ) و هارگریوز با K اصلاحی (سمت راست) در مقابل روش فانو پنمن مانیتیت در ایستگاه رشت



شکل ۲- نمودار پراکنش تبخیر-تعرق محاسبه شده به روش هارگریوز (سمت چپ) و هارگریوز با K اصلاحی (سمت راست) در مقابل روش فانو پنمن مانتیت در ایستگاه بندرانزلی



شکل ۳- نمودار پراکنش تبخیر-تعرق محاسبه شده به روش هارگریوز (سمت چپ) و هارگریوز با K اصلاحی (سمت راست) در مقابل روش فانو پنمن مانتیت در ایستگاه آستارا

مانتیت را بیش از ۵۰٪ کاهش دهد.

منابع

رحیمی خوب، ع.، بهبهانی، س. م. ر. و نظری فر، م. ۱۳۸۵. بررسی استفاده از حداقل داده‌های هواشناسی در معادله پنمن-مانتیت (مطالعه موردی: استان خوزستان). مجله علمی پژوهشی علوم کشاورزی. ۳، ص: ۵۹۱-۵۶۰.

سامتی، م.، قهرمان، ن.، قربانی، خ. ۱۳۹۰. کاربرد مدل داده کاوی M5 در پیش‌بینی تبخیر-تعرق پتانسیل (مطالعه موردی: ایستگاه شیراز)- اولین کنفرانس ملی هواشناسی و مدیریت آب کشاورزی، کرج، ایران.

شایان نژاد، م. ۱۳۸۵. مقایسه‌ی دقت روش‌های شبکه‌های عصبی مصنوعی و پنمن - مانتیت در محاسبه تبخیر-تعرق پتانسیل. همایش ملی مدیریت شبکه‌های آبیاری و زهکشی. اهواز، ایران

فرشی، ع.، م. ر. شریفی، ر. جارااللهی، م. ر. قائمی، م. شهابی‌فر، م. تولائی، م. ۱۳۷۶. برآورد آب مورد نیاز گیاهان عمده زراعی و باغی کشور (جلد اول گیاهان زراعی). وزارت کشاورزی، سازمان تات،

نتایج این بررسی نشان داد که با استفاده از ضریب اصلاحی K، برآورد تبخیر-تعرق به روش هارگریوز سامانی به روش پنمن مانتیت نزدیک‌تر می‌شود و مقدار خطای بین این دو روش کم‌تر می‌شود (جدول ۳ و شکل‌های ۱، ۲ و ۳).

نتیجه‌گیری

در این پژوهش با تعریف ضریب اصلاحی به نام k که براساس نسبت برآورد تبخیر-تعرق به روش پنمن-مانتیت به روش هارگریوز-سامانی محاسبه می‌شود تلاش شد تا دقت برآورد تبخیر-تعرق به روش هارگریوز-سامانی نسبت به روش پنمن-مانتیت افزایش یابد. پارامتر k بر اساس متغیرهای هواشناسی مانند دمای حداکثر، دمای حداقل، دمای متوسط، تفاضل دمای حداکثر و حداقل و رطوبت نسبی با روش‌های شبکه عصبی مصنوعی و مدل درختی M5 برآورد شد. نتایج این پژوهش نشان داد که مدل درخت تصمیم M5 ضمن سادگی محاسبات و معادلات ارائه شده، نسبت به شبکه عصبی مصنوعی نتایج بهتری را ارائه کرد. همچنین استفاده از ضریب اصلاحی می‌تواند دقت برآورد تبخیر-تعرق را افزایش دهد و در برخی از مناطق اختلاف بین برآورد با روش-هارگریوز سامانی و پنمن-

- Hydrological Processes, 22(13).
- Jensen, M.E., Burman, R.D and Allen, R.G. 1990. Evapotranspiration and Irrigation Water Requirement. ASCE Manual, No.70, U.S.A.
- Jensen, D.T., Hargreaves, G.H., Temesgen, B., and Allen, R.G. 1997. Computation of ET₀ under non-ideal conditions. J. Irrig. Drain. Eng., ASCE, 123(5): 394-400.
- Keskin, M.E., Terzi, O. 2006. Artificial neural networks models of daily pan evaporation. J. Hydrol. Eng., ASCE 11 (1): 65- 70.
- Ozgun kisi. 2007. Modeling monthly evaporation using two different neural computing techniques Irrigation Science Volume 27(5): 417-430
- Pal, M., Deswal, S. 2009. M5 model tree based modeling of reference evapotranspiration. Hydrol. Process. 23:1437-1443.
- Quinlan, J.R. 1992. Learning with continuous classes. Proceedings of Fifth Australian joint conference on artificial intelligence, Singapore, pp: 343-348.
- Slavisa Trajkovic 2009. Comparison of radial basis function networks and empirical equations for converting from pan evaporation to reference evapotranspiration Hydrological Processes, 23(6): 874 - 880.
- Witten, I.H and Frank, E. 2005. Data mining: practical machine learning tools and techniques with Java implementations. Morgan Kaufmann: San Francisco, p: 664.
- موسسه تحقیقات خاک و آب، نشر آموزش کشاورزی، کرج.
- قاسمی، ع. و زارع ایبانه، ح. ۱۳۸۶. ارزیابی نرم افزار Ref-ET در تعیین تبخیر و تعرق گیاه مرجع. نهمین سمینار سراسری آبیاری و کاهش تبخیر.
- Ahmad, S., Simonovic, S.P. 2005. An artificial neural network model for generating hydrograph from hydro-meteorological parameters. Journal of hydrology, (315), 236-251.
- Allen, G.R., Pereira, S.L., Raes, D and Smith, M. 1998. Crop evapotranspiration. Guidelines for computing crop water requirement. FAO Irrigation and Drainage Paper 56, Rome, Italy.
- Bruton, J.M., McClendon, R.W., Hoogenboom, G. 2000. Estimating daily pan evaporation with artificial neural networks. Trans. ASAE., ASAE 43 (2), 491-496.
- Dayhoff, J.E. 1990. Neural Network Principles, Prentice-Hall International, U.S.A
- Diamantopoulou, M.J., Georgiou, P.E and Papamichail, D.M. 2010. Performance evaluation of artificial neural networks in estimating reference evapotranspiration with minimal meteorological data. Global nest Journal.
- Hargreaves, G.H. 1994. Defining and using reference evapotranspiration. Journal of Irrigation and Drainage Engineering, 120(6): 1132-1139.
- Jain, S.K., Nayak, P.C., Sudheer, K.P. 2008 Models for estimating evapotranspiration using artificial neural networks, and their physical interpretation,

Improvement of the Estimation of Potential Evapotranspiration Using Adjusted Coefficient by M5 Decision Tree Model

H.Sharifan^{1*}, Kh.Ghorbani²

Received: Aug.26,2013 Accepted: Feb.26,2014

Abstract

Evapotranspiration is one of the basic components in hydrologic balance that is important for the design and management of irrigation systems. This research investigates improvement of accuracy of ET estimation by H-S method based on adjusted coefficient of K. This coefficient, the ratio of evapotranspiration estimated by F-P-M method to that estimated by H-M method, is determined by M5 Decision Tree Model based on meteorological variables (air temperature, relative humidity, dew point) at three meteorological stations (including Astara, Rasht, Bandar-Anzali). Thirty years period (1360-1390) is used for this research. The data of each station is divided into two parts: eighty percent for training and twenty percent for validation. The estimated adjusted coefficient is multiplied by estimated evapotranspiration with H-S method. The results indicate higher performance of M5 Decision Tree Model relative to Neural Network model. In addition, mean difference between estimated evapotranspiration by two methods decreased from 0.41, 0.55, 0.7 to 0.31, 0.38, 0.28 for Astara, Bandar-Anzali and Rasht stations, respectively.

Key word: Evapotranspiration, correction Index , neural network, method tree M5.

1- Associate professor of Water Engineering Department, water and soil Engineering College, Gorgan Agriculture Science and Natural Resource University.

2- Assistant professor of Water Engineering Department, water and soil Engineering College, Gorgan Agriculture Science and Natural Resource University

(* - Corresponding Author Email: h_sharifan47@yahoo.com)