

تخمین تبخیر-تعرق سطوح گیاهی مرجع با روش شبکه های عصبی مصنوعی

احسان دایر^۱، علیرضا سعادت^۲، سیروس نظری^۳، رضا علی پور^۴

۱- گروه آبیاری و زهکشی، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران

۲- واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران

۳- گروه عمران، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران

۴- گروه آبیاری و زهکشی، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران

تاریخ پذیرش: ۱۳۹۲/۹/۲۰

تاریخ دریافت: ۱۳۹۲/۸/۶

چکیده

در حال حاضر کشاورزی تکیه گاه مهم امنیت و حیات اقتصادی کشور می باشد. در این میان نهاده آب بعنوان مهمترین و محدودترین عامل تولید از اهمیت زیادی برخوردار است. امروزه علاوه بر اندازه گیری مستقیم نیاز آبی گیاهان، استفاده از فرمولهای مختلف جهت برآورد نیاز آبی پتانسیل کاربرد وسیعی دارد. این امر با گسترش نرم افزارهای مختلف از توانایی و قدرت زیادی برخوردار شده است. یکی از روشهایی که در خصوص نیاز آبی به شکل وسیعی از فرمولهای برآورد نیاز آبی استفاده کرده استفاده از شبکه های عصبی مصنوعی می باشد. ابتدا مدل با ۶ پارامتر ورودی و ۵ پارامتر و سپس با ۴ پارامتر ورودی آزمایش شد. لازم به ذکر است که در شبکه با ۵ پارامتر ورودی مدل ۲ بار آزمایش شده که در هر مرحله یکی از پارامترهای درجه حرارت حداقل و رطوبت نسبی حداقل حذف شدند. توابع محرک در این شبکه ها سگموئید، تانژانت هایپربولیک، سکانت هایپربولیک می باشد. در تمام این مراحل نتایج نزدیکی حاصل شد که نشان می دهد همه این پارامترها به طریقی در میزان تبخیر و تعرق مؤثر می باشند. اما در نهایت شبکه ۳ لایه با تابع محرک سیگموئید، با ۵ عنصر در لایه ورودی و ۶ عنصر در لایه پنهان و ۱ عنصر در لایه خروجی نسبت به سایر نتایج، نتیجه خوبی را بدست آورد. این الگو دارای بیشترین ضریب همبستگی برابر $0/92429$ و کمترین مقدار خطا برابر $0/26324$ در مرحله صحت سنجی می باشد. لازم به ذکر است که در این پژوهش بیشترین و کمترین ضریب همبستگی به ترتیب $0/92429$ و $0/77428$ که نوع آرایش آنها ۱-۶-۵ و ۱-۸-۵ و مربوط به توابع محرک سیگموئید و تانژانت هایپربولیک می باشد.

واژه های کلیدی: تبخیر-تعرق، شبکه های عصبی مصنوعی، نیاز آبی گیاهان، توابع محرک

مقدمه

و مخازن آب مهمترین مرحله مطالعاتی را در یک طرح آبیاری و زهکشی تشکیل می دهد، اما اکثراً مسأله تخمین نیاز آبی گیاهان که در طرحهای آبیاری گنجانده می شود، چندان جدی گرفته نمی شود. این امر باعث می شود که وقتی طرح به اجرا درآمد یا آب کافی برای آبیاری زمینهای زیر کشت وجود نداشته باشد و یا آنکه مقدار آب بیش از نیاز زراعتی موجود باشد.

در حال حاضر کشاورزی تکیه گاه مهم امنیت و حیات اقتصادی کشور می باشد. در این میان نهاده آب بعنوان مهمترین و محدودترین عامل تولید از اهمیت زیادی برخوردار است. هر چند تعیین میزان آب مورد نیاز گیاه و برنامه ریزی آبیاری به منظور تأمین حداکثر رشد و تحویل حداکثر محصول و همچنین اطلاع از مقدار کل آب مصرفی و در نتیجه تعیین ظرفیت کانالها

Santa Monia و Pomona در لوس آنجلس آمریکا برداشت شده و به عنوان ورودی به شبکه به کار رفته است. تبخیر - تعرق مرجع محاسبه شده از معادله پنمن - ماتنیت به عنوان خروجی هدف به شبکه اعمال شده است. نتایج شبکه با مدل های تجربی مانند CIMIS، پنمن (۱۹۸۵) و هارگریوز (۱۹۸۵) که به وسیله روش استاندارد پنمن - ماتنیت واسنجی شده اند، مقایسه گردیده است. نتایج نشان داد که شبکه عصبی می تواند به خوبی در فرآیند مدل کردن ET_0 به کار برده شود [۴]. رحیمی خوب (۲۰۰۸) در تحقیقی که در منطقه نیمه خشک خوزستان انجام داد؛ روش های شبکه عصبی مصنوعی و هارگریوز - سامانی (۱۹۸۵) را برای تخمین تبخیر - تعرق ماهانه گیاه مرجع مقایسه کرد. نتایج نشان داد که روش شبکه عصبی تبخیر - تعرق ماهانه گیاه مرجع را بهتر از روش هارگریوز - سامانی تخمین می زند [۵]. برتن و همکاران با استفاده از شبکه های عصبی مصنوعی، تبخیر روزانه از تشتک را مورد بررسی قرار دادند بارندگی، درجه حرارت، رطوبت نسبی، تشعشعات خورشیدی و سرعت باد بعنوان ورودیهای شبکه و میزان تبخیر از تشتک بعنوان خروجی شبکه مورد استفاده قرار گرفتند. نتایج ایشان نشان داد که روش شبکه های عصبی مصنوعی دارای کمترین خطا نسبت به سایر روشها بوده و خطایی برابر ۱/۱۱ میلیمتر در روز داشته است [۶]. سیلوا و همکاران، نشان دادند که روش ANN می تواند ET_0 را حتی بهتر از روش پنمن ماتنیت پیش بینی کند [۷]. آرکا و همکاران شبکه عصبی پیشرو با الگوریتم آموزشی Quickprop را برای برآورد تبخیر تعرق مرجع استفاده کردند در این تحقیق از داده های هواشناسی چهار ساله استفاده شد که داده های سال ۱۹۹۲ برای آموزش، داده های سال ۱۹۹۳ برای آزمون و داده های سالهای ۱۹۹۴ و ۱۹۹۵ برای صحت یابی مدل طراحی شده در نظر گرفته شد. برای آموزش، آزمون و صحت یابی مدل از تبخیر تعرق پتانسیل محاسبه شده از روش پنمن فائو استفاده شده

امروزه علاوه بر اندازه گیری مستقیم نیاز آبی گیاهان، استفاده از فرمولهای مختلف جهت برآورد نیاز آبی پتانسیل کاربرد وسیعی دارد. این امر با گسترش نرم افزارهای مختلف از توانایی و قدرت زیادی برخوردار شده است. یکی از روشهایی که در خصوص نیاز آبی به شکل وسیعی از فرمولهای برآورد نیاز آبی استفاده کرده استفاده از شبکه های عصبی مصنوعی می باشد. کومار و همکاران (۲۰۰۲) کاربرد شبکه عصبی مصنوعی ANN را برای تخمین تبخیر - تعرق ۲۴ ساعته گیاه مرجع بررسی کردند. بهترین ساختار شبکه را برای تخمین ET_0 با دو سری داده مختلف برای Davis در کالیفرنیا آمریکا به کار بردند. تابش خورشید، دمای بیشینه و کمینه، رطوبت نسبی بیشینه و کمینه و سرعت باد به عنوان ورودی و تبخیر - تعرق گیاه مرجع محاسبه شده از معادله پنمن - ماتنیت (آلن و همکاران، ۱۹۹۸) به عنوان خروجی هدف به کار برده شد. نتایج تحقیق نشان داد که شبکه عصبی می تواند ET_0 را بهتر از روش مرسوم پنمن - ماتنیت (آلن و همکاران، ۱۹۹۸) در منطقه Davis تخمین بزند [۲].

تراجکویس و همکاران (۲۰۰۳) یک شبکه عصبی مصنوعی مناسب را برای پیش بینی تبخیر - تعرق مرجع به کار بردند. ساختار بهینه شبکه، بر پایه معنی داری پارامترهای آماری تعیین شده است. داده های هواشناسی (دمای هوا، رطوبت نسبی، سرعت باد و ساعات آفتابی) در Nis, Serbia و Montenegro از ژانویه ۱۹۷۷ تا دسامبر ۱۹۹۶ در دسترس بوده است. داده های تبخیر - تعرق ماهانه به وسیله روش پنمن - ماتنیت (آلن و همکاران، ۱۹۹۸) تعیین شده است. نتایج نشان داد که ANN می تواند برای پیش بینی تبخیر - تعرق مرجع با دقت بالایی به کار رود [۳]. کی سی توانایی شبکه عصبی مصنوعی را در مدل کردن تبخیر - تعرق مرجع بررسی کردند. در این تحقیق داده های مختلف هواشناسی روزانه شامل تابش خورشید، دمای هوا، رطوبت نسبی و سرعت باد از دو ایستگاه

میلیمتر در روز در حالیکه میزان خطای پنمن مانیتث ۱/۲۰۶ میلیمتر در روز است [۱].

روش فائو - پنمن مانیتث

این روش به عنوان یکی از مهمترین روشها برای تخمین تبخیر و تعرق گیاه مرجع ET_0 مورد استفاده متخصصان قرار دارد. در روش مذکور گیاه مرجع یک پوشش چمن فرضی است که ارتفاع آن ۱۲ سانتی متر بازتاب تابش در آن ۲۲ درصد می باشد. بعبارت دیگر در روش پنمن مانیتث فرض می شود که سطح پوشش گیاهی یک برگ بزرگ با روزنه ای موجود در آن است. بهمین دلیل روش پنمن مانیتث برگ بزرگ (Big leaf) هم می گویند.

$$ET_0 = \frac{0.408 \Delta (R_n - G) + \gamma \left[\frac{890}{(T + 273)} \right] U_2 (e_s - e_d)}{\Delta + \gamma(1 + 0.34 U_2)} \quad (1)$$

مرتفع سازند. پروت (۱۹۷۵) داده های هواشناسی و تبخیر و تعرق گیاهان را در ۱۳ وضعیت آب و هوایی مختلف مورد بررسی قرار داده و سرانجام به این نتیجه رسیدند که روش بلانی کریدل می تواند نسبت به سایر پارامترهای هواشناسی مانند رطوبت هوا، ساعات آفتابی و سرعت باد اصلاح گردد. رابطه پیشنهادی پروت به شرح زیر می باشد.

$$ET_0 = a + b[p(0.46T + 8.10)] \quad (2)$$

ET_0 : تبخیر و تعرق گیاه مرجع چمن (میلی متر در روز)

p : ضریب مربوط به طول روز یا در صد سالانه تابش آفتاب در ماه مورد نظر

T : متوسط ماهانه درجه حرارت (درجه سانتی گراد).

a, b : ضرایب اقلیمی می باشند که به حداقل رطوبت هوا (RH_{min}) نسبت ساعات آفتابی واقعی (n) به حداکثر ساعات آفتابی (N) یعنی n/N و سرعت باد در روز U_2 در ارتفاع ۲ متری از سطح زمین بستگی دارد.

و با نتایج حاصل از روشهای تجربی هارگریوز، هارگریوز سامانی و بلانی کریدل مقایسه گردید. براساس نتایج، مدل حاصله از ترکیب پارامترهای سرعت باد، کمبود فشار بخار و تبخیر تعرق نتایج بهتری را نسبت به روش هارگریوز نشان داد. مقدار ریشه میانگین مربعات خطا، در روش شبکه عصبی و روش هارگریوز به ترتیب ۰/۲۷ و ۰/۴۳ میلیمتر در روز بود [۸]. شایان نژاد با استفاده از شبکه عصبی مصنوعی و داده های لایسیمتری استان همدان تبخیر تعرق پتانسیل را محاسبه نمود. نتایج نشان داد که دقت شبکه عصبی مصنوعی از روش پنمن مانیتث نیز بیشتر است، به طوری که میزان خطای شبکه عصبی ۰/۷۲۶

که در آن:

ET_0 : تبخیر و تعرق گیاه مرجع mm/day

R_n : تابش خالص در سطح پوشش گیاهی ($mJ d^{-1}m^{-2}$)

T_a : متوسط هوا در ارتفاع ۲ متری از سطح زمین ($^{\circ}C$)

U_2 : سرعت باد در سطح ۲ متری از زمین (m/Sec)

$e_s - e_d$: کمبود فشار بخار اشباع در ارتفاع ۲ متری (KPa)

Δ : شیب منفی بخار اشباع ($KPa^{\circ}C^{-1}$)

γ : ضریب رطوبتی ($KPa^{\circ}C^{-1}$)

G : شار گرما به داخل خاک ($mJ d^{-1}m^{-2}$) که معمولاً

$G=0$ در نظر گرفته می شود.

روش بلانی کریدل اصلاح شده FAO

با توجه به مشکلات رابطه اصلاح شده بلانی-کریدل توسط سازمان حفاظت خاک آمریکا (SCS)، متخصصین سازمان خواروبار و کشاورزی ملل متحد (FAO) در صدد برآمدند تا نارسایی های این روش را

a و b ضرایب اقلیمی هستند که مقادیر آنها از روابط زیر به دست می‌آید:

$$a = 0.0043(RH_{min}) - n/N - 1.41 \quad (۳)$$

$$b = 0.82 - 0.0041(RH_{min}) + 1.07(n/N) + 0.066(U_2) - 0.006(RH_{min})n/N - 0.0006(RH_{min})(U_2) \quad (۴)$$

نرونهاى زیستی، تعیین کننده تاثیر هر متغیر بر میزان عملکرد لایه ورودی است. هر نرون از دو بخش تشکیل شده است، در بخش نخست، مجموع وزنی مقادیر ورودی محاسبه می شود و در بخش دوم خروجی بخش نخست در یک تابع ریاضی قرار گرفته و خروجی نرون را محاسبه می نماید. بین هر لایه مقداری معادل واحد، تحت عنوان بایاس^۲ در نظر گرفته می شود که آن نیز در وزن مربوط به خود در ارتباط با لایه بعد ضرب شده و با مجموع حاصل ضرب جمع می گردد. این تابع ریاضی، تابع محرک یا آستانه نامیده می شود و دارای انواع مختلفی نظیر توابع تانژانت هیپربولیک، سیگموئید، خطی، باینری و گوسین می باشد. همه این توابع پیوسته و مشتق پذیرند و خروجی آنها در یک محدوده عددی خاصی (عموماً بین صفر و یک) قرار می گیرند.

گام نخست در بهره گیری از شبکه های عصبی مصنوعی آموزش شبکه می باشد. منظور از آموزش شبکه عصبی مصنوعی محاسبه وزن اتصالات مختلف است. بطور کلی آموزش شبکه های عصبی به دو طریق صورت می گیرد، آموزش تحت نظارت (سرپرستی) که در آن خروجی مشخصی به هر ورودی اختصاص داده می شود. (همانند آرایش مورد استفاده در این پژوهش) و آموزش بدون نظارت (بدون سرپرستی) که خروجی از قبل تعیین شده ای ندارد.

در ایستگاه های هواشناسی RH_{min} ، بوسیله رطوبت نگار، ساعات واقعی آفتابی روزانه (n) توسط آفتاب نگار، مقدار N با استفاده از جدول هوا شناسی و سرعت باد در ارتفاع ۲ متری از سطح زمین بوسیله بادسنج به دست می‌آید.

که U_2 : سرعت باد در ارتفاع ۲ متری از سطح زمین بر حسب متر بر ثانیه می‌باشد. در رابطه فوق می‌بایست سرعت باد در طول روز منظور شود نه سرعت باد در طول شبانه روز، زیرا سرعت باد در روز بیشتر از سرعت باد در شب بوده و حدوداً دو برابر آن می‌باشد. مقایسه نتایج حاصل از فرمول بلانی کریدل اصلاح شده به روش FAO با نتایج لایسیمتری نشان داده است که این روش در عین سادگی بسیار دقیق می‌باشد.

شبکه های عصبی مصنوعی

شبکه های عصبی مصنوعی مدلی ریاضی است که توانایی مدل سازی و ایجاد روابط غیر خطی برای درون یابی را دارا می باشد. یک مدل با ساختار پرسپترون چند لایه از سه لایه ورودی، پنهان و خروجی تشکیل شده است. در هر لایه یک یا چند نرون وجود دارد، بطوریکه عملکرد این نرون ها شبیه به عملکرد نرونهاى مغز انسان می باشد. در یک ساختار شبکه عصبی، مجموعه ای از نرونها دخالت دارند که هر نرون با همه نرونهاى لایه بعدی مرتبط است. تعداد نرونهاى لایه ورودی برابر تعداد متغیرهای مستقل سیستم مورد نظر (در این تحقیق، پارامترهای کیفیت آب) می‌باشد. هر یک از نرونهاى لایه ورودی در وزنی ضرب می شوند، مقدار این وزن همانند تقاطعات سیناپتیک در

1 - Multilayer preceptron
2- Bias

مطلوب انجام شود، آموزش شبکه عصبی به طور مؤثرتری انجام خواهد شد .

$$DATA_{normal} = \frac{data_i - data_{min}}{data_{max} - data_{min}} \quad (5)$$

مواد و روش‌ها

کشت و صنعت امیر کبیر یکی از کشت و صنعت‌های هفتگانه شرکت توسعه نیشکر و صنایع جانبی است که در ۴۵ کیلومتری جنوب اهواز در حد فاصل شهرهای اهواز و خرمشهر قرار گرفته است. این واحد در قسمت غربی رودخانه کارون و در امتداد حاشیه ۳ کیلومتری این رودخانه قرار دارد. حد جنوبی اراضی به فاصله حدود ۶۰ کیلومتری خرمشهر و در شمال کشت و صنعت میرزا کوچک خان قرار گرفته است. از نظر جغرافیایی این ناحیه بین عرضهای شمالی ۱۵' ۳۰° تا ۴۵' ۳۰° قرار دارد. در این تحقیق از لایسیمترهایی که در مزرعه ARC 2-4 امیر کبیر واقع هستند، استفاده شد. این لایسیمترها دارای دیواره‌های بتنی و از نوع زهکش دار بوده و ابعاد هر کدام از آنها ۲ متر در ۶ متر و به مساحت ۱۲ متر مربع می‌باشد. کف آن شیب دار و عمق آن ۲ متر است.

در این تحقیق ابتدا با استفاده از داده های لایسیمتری موجود در کشت و صنعت امیر کبیر، مقادیر تبخیر و تعرق پتانسیل از فروردین لغایت مهر ماه سال ۱۳۸۵ جمع آوری گردید و بعنوان خروجی مدل شبکه های عصبی مصنوعی در نظر گرفته شد. از طرفی داده های ایستگاه هواشناسی این کشت و صنعت، شامل درجه حرارت کمینه و بیشینه، رطوبت نسبی کمینه و بیشینه، ساعات آفتابی و سرعت باد در ۲ متری در بازه زمانی مذکور نیز جهت ورودی مدل انتخاب گردید. در مجموع از میان سالهای آماری تعداد ۱۶۷ الگو قابل اعتماد هواشناسی و لایسیمتری انتخاب گردید که ۷۰٪ درصد الگوها جهت آموزش مدل و ۳۰٪ درصد

برای آموزش شبکه های عصبی مصنوعی از الگوریتمهای یادگیری متفاوتی مانند الگوریتم پس انتشار خطا، الگوریتم پس انتشار گرادیان مزدوج و الگوریتم مارکوات لورنبرگ استفاده می شود. انتخاب هر الگوریتم بر سرعت یادگیری و دقت شبکه موثر است. الگوریتم پس انتشار خطا از دو مسیر اصلی تشکیل می شود. مسیر اول، به مسیر رفت 'موسوم می باشد که در این مسیر بردار ورودی به شبکه MLP اعمال شده و تاثیراتش از طریق لایه های میانی به لایه خروجی انتشار می یابد. بردار خروجی تشکیل یافته در لایه خروجی پاسخ واقعی شبکه MLP را تشکیل می دهد. در این مسیر پارامترهای شبکه ثابت و بدون تغییر در نظر گرفته می شوند. مسیر دوم، به مسیر برگشت 'موسوم می باشد که در این مسیر، برعکس مسیر رفت پارامترهای شبکه متغییر و تنظیم می گردند که این تنظیم مطابق با قوانین اصلاح خطا انجام می گیرد و سیگنال خطا در لایه خروجی شبکه تشکیل می گردد. بردار خطا برابر اختلاف بین پاسخ مطلوب و پاسخ واقعی شبکه می باشد. مقدار خطا پس از محاسبه در مسیر برگشت از لایه خروجی و از طریق لایه های شبکه، در کل شبکه توزیع می گردد. چون توزیع اخیر در خلاف مسیر ارتباطی وزنی نرونها قرار می گیرد، کلمه پس انتشار خطا جهت توضیح اصلاح رفتاری شبکه انتخاب شده است.

تمامی شبکه های عصبی ورودی های عددی را گرفته و خروجی عددی تولید می کنند. تابع محرک یک واحد معمولاً طوری انتخاب می شود که تنها به ورودی های موجود در یک محدوده خاص ح ساس است. بنابراین ابتدا داده های ورودی اصطلاحاً نرمال شده و در یک محدوده خاص قرار می گیرند. مقادیر خروجی شبکه نیز در یک محدوده خاص می باشد که باید به محدوده واقعی خود برگردد. اگر پیش پردازش روی داده های ورودی و مقادیر

که در هر مرحله یکی از پارامترهای درجه حرارت حداقل و رطوبت نسبی حداقل حذف شدند. توابع محرک در این شبکه ها سگموئید، تانژانت هایپربولیک، سکانت هایپربولیک می‌باشد. در تمام این مراحل نتایج نزدیکی حاصل شد که نشان می‌دهد همه این پارامترها به طریقی در میزان تبخیر و تعرق مؤثر می‌باشند. اما در نهایت شبکه ۳ لایه با تابع محرک سیگموئید، با ۵ عنصر در لایه ورودی و ۶ عنصر در لایه پنهان و ۱ عنصر در لایه خروجی نسبت به سایر نتایج، نتیجه خوبی را بدست آورد. این الگو دارای بیشترین ضریب همبستگی برابر ۰/۹۲۴۲۹ و کمترین مقدار خطا برابر ۰/۲۶۳۲۴ در مرحله صحت سنجی می‌باشد. لازم به ذکر است که در این پژوهش بیشترین و کمترین ضریب همبستگی به ترتیب ۰/۹۲۴۲۹ و ۰/۷۷۴۲۸ که نوع آرایش آنها ۵-۱-۸ و ۵-۱-۶-۸ و مربوط به توابع محرک سیگموئید و تانژانت هایپربولیک می‌باشد. در صورتیکه بیشترین و کمترین مقدار خطا به ترتیب ۰/۵۰۶۱۱ و ۰/۲۶۳۲۴ که نوع آرایش در آنها ۵-۱-۸ و ۵-۱-۶-۸ که مربوط به توابع محرک تانژانت هایپربولیک و سیگموئید می‌باشند. به طور کلی خلاصه نتایج به شرح ذیل می‌باشد.

۱- در شبکه سه لایه با ۶ پارامتر ورودی شامل درجه حرارت حداکثر، درجه حرارت حداقل، رطوبت نسبی حداکثر، رطوبت نسبی حداقل، ساعات آفتابی و سرعت باد با تابع تانژانت هایپربولیک ابتدا درجه حرارت حداکثر و بعد از آن مقدار سرعت باد نقش مؤثری را در شبیه سازی اعمال می‌کند.

باقیمانده بعنوان آزمایش مدل در نظر گرفته شد. در بخش بعدی با استفاده از داده های هواشناسی و خروجیهای مرحله آزمایش مدل شبکه های عصبی (۳۰٪ درصد باقیمانده داده ها) تبخیر و تعرق پتانسیل از روشهای پنتمن مانتیت (FAO 56) و بلانی کریدل اصلاح شده بصورت جداگانه تعیین گردید. در نتیجه بعد از اتمام مراحل فوق چهار نتیجه تبخیر و تعرق پتانسیل از چهار روش لایسیمتری (بعنوان داده پایه و واقعی)، مدل شبکه های عصبی مصنوعی، پنتمن مانتیت و بلانی کریدل اصلاح شده، بدست آمد. جهت اعتبارسنجی نتایج بدست آمده، هر کدام از روشهای مدل شبکه های عصبی مصنوعی، پنتمن مانتیت و بلانی کریدل اصلاح شده بصورت جداگانه با داده های لایسیمتری (بعنوان داده پایه و واقعی) و نسبت به خط X, Y با استفاده از معیارهای آماری زیر مقایسه گردید.

جزر میانگین مربعات خطا: (RMSE): (Root Mean Square Error)

$$RMSE = \sqrt{\frac{\sum(x-y)^2}{n}} \quad (6)$$

$$R^2 = \frac{(\sum xy)^2}{\sum y^2 \cdot \sum x^2} \quad (7)$$


X مقادیر بدست آمده از لایسیمتر و Y مقادیر بدست آمده از سه روش ANN و پنمن مانتیت و بلانی کریدل اصلاح شده می‌باشد.

بحث و نتیجه گیری

ابتدا مدل با ۶ پارامتر ورودی و ۵ پارامتر و سپس با ۴ پارامتر ورودی آزمایش شد. لازم به ذکر است که در شبکه با ۵ پارامتر ورودی مدل ۲ بار آزمایش شده

جدول ۱- تعداد پارامترهای ورودی و درصد سهم آنها به ازای تابع انتقال تانژانت ها پربویک

پارامترهای ورودی	درجه حرارت حداکثر	درجه حرارت حداقل	رطوبت نسبی حداکثر	رطوبت نسبی حداقل	ساعات آفتابی	سرعت باد
درصد سهم	۲۵/۴۷	۷/۲۲	۱۱/۰۶	۱۳/۱۸	۱۴/۵۹	۲۵/۴۷




شکل ۱- همبستگی مدل با داده های لایسیمتری با ۶ پارامتر ورودی


خطا و بیشترین ضریب همبستگی بهترین ساختار است. توابع محرک مطلوب به کار رفته بین لایه ورودی و لایه پنهان تابع سکانت هایپربولیک در حالت Random و بین لایه پنهان و خروجی تابع سیگموئید انتخاب گردید. درصد سهم هر یک از پارامترهای ورودی در شکل (۲) نشان داده شده است.

۲- در شبکه سه لایه با ۵ پارامتر ورودی بدون دخالت درجه حرارت حداقل شامل درجه حرارت حداکثر، رطوبت نسبی حداکثر، رطوبت نسبی حداقل، ساعات آفتابی و سرعت باد تابع سیگموئید ابتدا درجه حرارت حداکثر و بعد از آن سرعت باد بیشترین تأثیر را در شبیه سازی دارا می باشد.

شبکه سه لایه با پنج پارامتر ورودی و تعداد ۶ گره در لایه پنهان از حیث دارا بودن کمترین مقدار حداکثر




شکل ۲- درصد اثر گذاری ۵ پارامتر ورودی در بهترین ساختار




شکل ۳- مقایسه مقادیر اندازه گیری شده و خروجی مدل بدون در نظر گرفتن مقدار درجه حرارت حداقل

گره در لایه پنهان و ۵ پارامتر ورودی و تابع تانژانت هایپربولیک در حالت Random بین لایه های ورودی و پنهان و بین لایه پنهان و خروجی بهترین نتیجه را می دهد. درصد سهم پارامترهای ورودی در شکل (۴) و چگونگی تطابق مقادیر خروجی مدل شبکه عصبی مصنوعی با مقادیر اندازه گیری شده در شکل (۵) نشان داده شده است.

۳- در شبکه سه لایه با ۵ پارامتر ورودی بدون دخالت رطوبت نسبی حداقل شامل درجه حرارت حداکثر، درجه حرارت حداقل، رطوبت نسبی حداکثر، ساعات آفتابی و سرعت باد با تابع تانژانت هایپربولیک ابتدا مقدار سرعت باد و بعد از آن ساعات آفتابی و دست آخر درجه حرارت حداکثر نقش تعیین کننده در شبیه سازی دارا می باشد. نتایج نشان داد شبکه با تعداد ۷




شکل ۴- درصد اثرگذاری پارامترهای ورودی در ساختارهایی بدون رطوبت نسبی حداقل




شکل ۵- مقایسه مقادیر اندازه گیری شده و خروجی مدل بدون در نظر گرفتن مقدار رطوبت نسبی حداقل

و پنهان و خروجی سکانت هایپربولیک در حالت Beginning دارای ضریب همبستگی و خطای حداکثر خوبی می باشد. شکل (۶) درصد سهم پارامترهای ورودی و شکل (۷) چگونگی تطابق مقادیر خروجی مدل شبکه عصبی مصنوعی با مقادیر اندازه گیری شده نشان داده شده است.

۴- در شبکه سه لایه با ۴ پارامتر ورودی شامل درجه حرارت حداکثر، رطوبت نسبی حداکثر، ساعات آفتابی و سرعت باد با تابع سیگموئید ابتدا مقدار درجه حرارت حداکثر و بعد از آن مقدار سرعت باد نقش بسیار مؤثری دارند. نتایج نشان داد ساختار شبکه ۳ لایه ای با ۵ گره در لایه ورودی و ۶ گره در لایه پنهان قابل قبول است. تابع انتقالی بین لایه های ورودی و پنهان




شکل ۶- درصد سهم پارامترهای ورودی ساختار نهایی



شکل ۷- مقایسه مقادیر اندازه گیری شده و خروجی مدل بدون در نظر گرفتن مقدار درجه حرارت حداقل و رطوبت نسبی حداقل

تبخیر و تعرق مرجع، با استفاده از داده های هواشناسی روزانه ۴۰ تاریخ مشخص که در صحت سنجی مدل از آنها استفاده شده بود، تبخیر و تعرق پتانسیل از دو روش پنمن و مانتیث و بلانی کریدل (مطابق آنچه قبلا گفته شد) بدست آمد.


۵- مقایسه تبخیر و تعرق محاسبه شده توسط مدل شبکه عصبی و مصنوعی با تبخیر و تعرق محاسبه شده توسط فرمول بلانی کریدل و فرمول پنمن مانتیس و تبخیر و تعرق اندازه گیری شده توسط لایسیمتر جهت مقایسه نتایج مدل با سایر روشهای مرسوم در تعیین



شکل ۸- نتایج تبخیر و تعرق پتانسیل بدست آمده از چهار روش

است که علت آن این است آموزش شبکه عصبی و مصنوعی بر اساس داده های لایسیمتر صورت گرفته است.

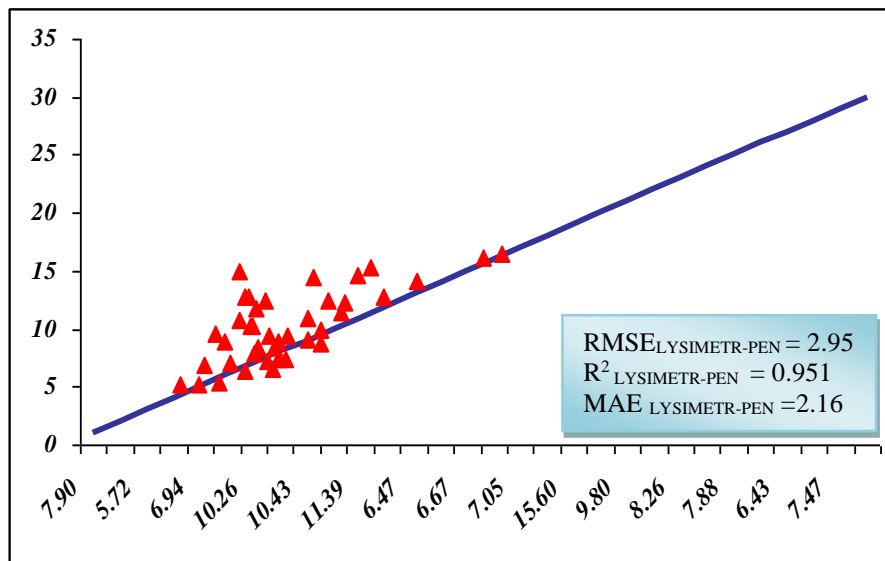
مشاهدات بدست آمده از شکل (۸) حاکی از آن است:
 ۱- که محاسبات شبکه عصبی و مصنوعی به مقادیر اندازه گیری شده توسط لایسیمتر بسیار نزدیک



شکل ۹- مقایسه نتایج مدل شبکه عصبی مصنوعی با لایسیمتر

شایان نژاد در همایش ملی آبیاری وزهکشی در سال ۱۳۸۵ ارائه شد نشان داد که فرمول پنمن مانیتیس مقادیر تبخیر و تعرق را، از حد معمول کمتر نشان می دهد که این امر را می توان دلیل اختلاف آنها در نمودار نسبت داد.

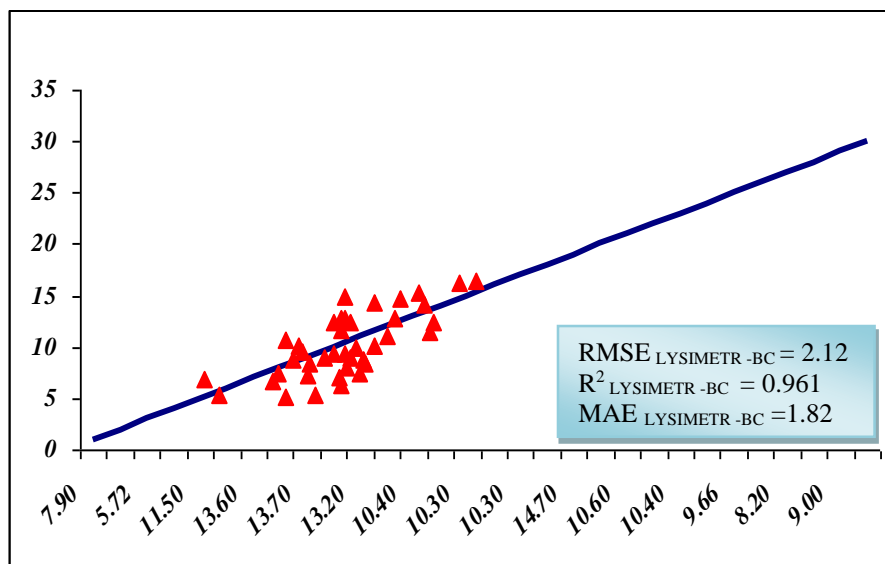
۲- همانطور که در شکل (۹) مشاهده می گردد داده هایی که توسط فرمول پنمن مانیتیس محاسبه می گردد تا حدودی از مقادیر پیش بینی شده توسط شبکه عصبی و مصنوعی کمتر است که دقیقاً این مسئله با مقاله ای در مورد مقادیر بدست آمده از فرمول پنمن مانیتیس صدق می کند. در تحقیقی که توسط



شکل ۱۰- مقایسه نتایج روش پنمن مانیتیس با لایسیمتر

۳- مقایسه داده های پیش بینی شده توسط مدل شبکه عصبی و مصنوعی و داده های اندازه گیری شده توسط لایسیمتر نشان می دهد که قابلیت پیش بینی شبکه عصبی و مصنوعی در مقادیر بیشتر تبخیر و تعرق نسبت به مقادیر کمتر تبخیر و تعرق بهتر است یا به عبارت دیگر مقدار ماکزیمم تبخیر و تعرق را قابل قبول تر پیش بینی می کند. از طرفی به دلیل اینکه در آبیاری تحت فشار به خصوص آبیاری بارانی جهت بدست آوردن مقدار نیاز خالص آبیاری مبنای مقدار تبخیر و تعرق ماکزیمم قرار داده می شود، لذا می توان این روش را به عنوان یکی از روشهای پیش بینی تبخیر و تعرق مورد بررسی قرار داد.

۴- مشاهده مقادیر محاسبه شده توسط فرمول بلانی کریدل با مقادیر پیش بینی شده توسط مدل شبکه عصبی و مصنوعی نشان می دهد که نمودار فرمول بلانی کریدل تا حد زیادی نسبت به داده های لایسیمتری نزدیک می باشد. که دلیل این امر اینگونه توجیه کرد که در فرمول بلانی کریدل برای محاسبه مقدار تبخیر و تعرق از متوسط درجه حرارت استفاده شده است بدین علت در مناطق گرم و خشک مانند منطقه مورد مطالعه فرمول بلانی کریدل از اعتبار مطلوبی برخوردار می باشد.



شکل ۱۱- مقایسه نتایج بلانی کریدل با لایسیمتر

برای تشریح دقیق نتایج مقایسه مدل‌های مختلف با داده های لایسیمتری ابتدا داده های هر کدام از مدل‌های سه گانه مذکور را به همراه داده‌های لایسیمتری را بر روی یک محور مختصات رسم نموده و وضعیت آنها نسبت به خط $(x=y)$ نمایش می دهیم و سپس با تعیین پارامترهای R^2 ، $RMSE$ و MAE نزدیکی هر کدام از سه روش ANN، پنمن مانیتث و بلانی کریدل را نسبت به داده‌های

لایسیمتری بررسی می نماییم. نتایج نشان داد نزدیکترین روش به داده های لایسیمتری مدل شبکه های عصبی با $RMSE=1.54$ و $R^2=0.986$ می باشد ضمن اینکه داده های مربوط به بلانی کریدل به دلیل گرم و خشک بودن منطقه مورد مطالعه بعد از مدل شبکه های عصبی همبستگی بیشتری را با داده‌های لایسیمتری نشان می دهد.

منابع

۱. شایان نژاد، و . ۱۳۸۵ . مقایسه روشهای شبکه عصبی مصنوعی و پنمن مانتیس در محاسبه تبخیر تعرق پتانسیل همایش ملی مدیریت شبکه های آبیاری و زهکشی ۱۲ الی ۱۴ اردیبهشت ماه ۱۳۸۵
2. Kumar, M., N.S. Raghuvanshi, R. Singh, W.W. Wallender, W.O. Pruitt. 2002. Estimating evapotranspiration using artificial neural network. J. Irrig. Drain. Eng. 128(4): 224-232
3. Trajkovic S, Todorovic B, Stankovic M (2003) Orecasting of reference evapotranspiration by artificial neural networks. J Irrig Drain Eng 129(6):454-457
4. Kisi, O. 2007. The potential of different ANN techniques in evapotranspiration modeling. Hydrological Processes. 22(14): 2449-2460.
5. Rahimi – Khoob, A. 2008. Comparative study of Hargreaves's and artificial neural network's methodologies in estimating reference evapotranspiration in a semiarid environment. Irrig. Sci. 26: 253-259.
6. Bruton, J. M., R. W. McClendon and G. Hoogenboom. 2000. Estimating daily pan evaporation with artificial neural network. Trans. ASAE. 43(2):492-496
7. Silva AF (2002) Previsã o da evapotranspirac,ã o de referê ncia utilizando redes neurais. Dissertac,ã o de Mestrado, Univ. Federal de Vic,osa, Vic,osa, Minas Gerais, Brazil
8. Arca, B., Benincasa, F., and Vincenz, M.D.(2000). Evaluation of neural network techniques for estimating evapotranspiration. National Research Council – Research Institute for the Monitoring of Agroecosystems (IMAes), via Funtana di Lu Colbu 4/A, 07100 Sassari, Italy.8 p.

