

مقایسه تبخیر و تعرق گیاه مرجع (ET₀) برآورده از روش‌های تجربی و شبکه‌های عصبی مصنوعی با داده‌های لایسیمتری

عادل قاسمی^۱، حمید زارع ابیانه^۲، رضا امیری چایجان^۳، کورش محمدی^۳، صفر معروفی^۲ و محمود احمدی^۴

چکیده

هدف از مطالعه حاضر انتخاب روش مناسب تعیین تبخیر و تعرق می‌باشد. بدین منظور با توجه به داده‌های اقلیمی منطقه همدان از روش‌های مختلف تجربی اقدام به برآورد تبخیر و تعرق گیاه مرجع شد. همچنین تبخیر و تعرق از شبکه عصبی مصنوعی نیز به عنوان ابزاری مناسب تعیین گردید. برای شبکه عصبی نتایج آرایش‌های مختلفی از تعداد لایه‌های پنهان، توابع محرک و قواعد آموزشی اجرا شد. مقایسه نتایج روش‌های تجربی و شبکه عصبی با نتایج دو ساله لایسیمتری نشان داد که روش پنمن-فائو و شبکه عصبی با آرایش ۶-۶-۱ از کارایی مناسبی در این خصوص برخوردار هستند. ارزیابی نتایج روش‌های تجربی و شبکه عصبی بر اساس پارامترهای آماری مختلف نظری خطای میانگین مربعات، میانگین خطای مطلق و ضریب همبستگی و انحراف معیار انجام گرفت. بدین ترتیب روش پنمن فائو به عنوان روش مطلوب در بین روش‌های تجربی رتبه دوم ضریب همبستگی، رتبه اول E_{RMS} و رتبه دوم SD_{EMA} را دارد. همچنین شبکه عصبی با آرایش ۶-۶-۱ دارای ضریب همبستگی ۰/۸۶، خطای میانگین مربعات ۰/۰۵۷ و میانگین خطای مطلق ۰/۰۶۹ و انحراف معیار ۰/۰۶۸ میلی‌متر در روز بود. مقایسه نتایج شبکه عصبی و روش پنمن فائو با داده‌های لایسیمتری نشان داد که دقت شبکه عصبی از روش پنمن فائو بیشتر است. لذا شبکه عصبی با توجه به نیاز اطلاعاتی کمتر در مقایسه با روش‌های تجربی و داشتن دقت و سرعت بیشتر در رسیدن به جواب‌های مطلوب قابل توصیه است. برآذش نتایج روش‌های تجربی و شبکه عصبی بهینه پیشنهادی در قالب مدل‌های خطی و چند جمله‌ای نشان داد که مدل چندجمله‌ای، ضریب همبستگی بالاتری نسبت به مدل خطی دارد. ضمن آن که شبکه عصبی نسبت به مدل‌های تجربی، برآوردهای بهتری را ارائه داد. لذا مدل چند جمله‌ای حاصل از برآذش نتایج شبکه عصبی به دلیل سادگی و ضریب همبستگی بیشتر، توانایی تخمین دقیق تری از تبخیر و تعرق را دارا می‌باشد و رابطه حاصل از آن کاراتر است.

واژه‌های کلیدی: تبخیر و تعرق مرجع، شبکه‌های عصبی مصنوعی، پرسپترون چند لایه، همدان

۱. دانشجوی کارشناسی ارشد آبیاری و زهکشی، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان

۲. استادیاران گروه آبیاری، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان

۳. دانشیار گروه آبیاری و زهکشی، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران

۴. کارشناس مرکز تحقیقات کشاورزی و منابع طبیعی همدان

مقدمه

مطالعات انجام یافته برای تبخیر و تعرق را می-
توان در قالب روش‌های مستقیم یعنی کشت گیاه مرجع
چمن در لایسیمتر و غیرمستقیم گروه‌بندی نمود. در
ایران پژوهشگرانی چون ضیاء تباراحمدی (۱۳۷۴)،
نیکبخت و همکاران (۱۳۸۰) تعدادی از روش‌های
ترکیبی مثل پنمن مانتیث و دمایی مانند بلانی- کریدل
را تحت آزمون قرار دادند. پژوهشگران فوق هر دو روش-
ترکیبی و دمایی را با توجه به میزان دسترسی به داده-
های هواشناسی و دقت مورد نیاز پیشنهاد نمودند
(شیرفان و همکاران، ۱۳۸۵).

رحیمزادگان (۱۳۷۰) طی مطالعه‌ای کاربردی
روش‌های جنسن- هیز، کریستیانسن- هارگریوز، بلانی-
کریدل اصلاح شده، پنمن و ترک را مناسب تعیین تبخیر
و تعرق پتانسیل در منطقه اصفهان دانست. مطالعات
نادیالو (۱۹۹۱)، اسماعیل (۱۹۹۳) و سانتوس و همکاران
(۱۹۹۴) حکایت از مناسب بودن روش جنسن- هیز
اصلاحی برای مناطق گرمسیری مانند نزوكای نیجریه،
القسیم عربستان و مناطقی از بزرگیل دارد. دهقانی سانیج
و همکاران (۲۰۰۴) برآوردهای روش پنمن- مانتیث-
فائق را از بین روش‌های پنمن، پنمن- رایت، بلانی-
کریدل، تراز انرژی و هارگریوز در مقایسه با نتایج
لایسیمتری برای منطقه کرج مناسب دانستند. مطالعات
شیرفان و همکاران (۱۳۸۵) نشان داد که نتایج روش-
های پنمن- مانتیس در مقایسه با داده‌های لایسیمتری و
هارگریوز- سامانی دارای اعتبار خوبی است. دین پژوه
(۲۰۰۶) طی مطالعه‌ای در سطح کشور ایران روش
تورنت- وايت اصلاحی را برای نواحی شمال و شمال
شرق، روش هارگریوز- سامانی را در نواحی غرب، شمال
غرب و جنوب غربی و روش لینیاکر را برای مناطق
مرکزی، شرق و جنوب شرقی کشور توصیه نمود. زارع
ابیانه و همکاران (۱۳۸۶) رابطه دمایی بلانی- کریدل را
برای منطقه همدان مناسب ارزیابی نمودند. معادلات
تجربی از پارامترهای اقلیمی متفاوتی در محاسبه تبخیر
و تعرق بهره می‌گیرند، لذا نتایج حتی در شرایط اقلیمی
یکسان مختلف هستند. بنابراین تبخیر و تعرق به عنوان
پدیده‌ای غیرخطی به تعداد فاکتورهای اقلیمی و دقت

اندازه‌گیری آن‌ها بستگی دارد. در نتیجه پژوهشگران
برای دستیابی به جواب‌های دقیق تمایل به استفاده از
روش‌های هوشمند را دارند. در این بین شبکه‌های
عصبي مصنوعی با توجه به توانمندی در مدل نمودن
پدیده‌های غیرخطی و نیازمندی به حداقل داده‌ها یکی از
ابزارهای موثر، در مدل کردن تبخیر و تعرق می‌باشند
(میثاقی و محمدی، ۱۳۸۳). شبکه عصبی مصنوعی،
ابزاری است متتشکل از پردازشگرهای ساده‌ای به نام نرون-
می‌باشد که تلاش دارد با شناخت روابط ذاتی بین داده-
ها، نگاشتی میان فضای ورودی (لایه ورودی) از طریق
پردازش داده‌ها در لایه (لایه‌های) میانی و فضای مطلوب
(لایه خروجی) ارائه دهد.

استفاده از شبکه‌های عصبی مصنوعی از سال ۱۹۹۰ در علوم مختلف از جمله علوم کشاورزی توسعه
یافت (لک و همکاران، ۱۹۹۹). سرنگی و همکاران
(۲۰۰۶) روند استفاده از شبکه‌های عصبی مصنوعی در
علم هیدرولوژی و مدل‌های کیفی آب را رو به رشد
دانسته‌اند. خانا (۱۹۹۰) و دایهوف (۱۹۹۰) سرعت بالای
پردازش و انعطاف‌پذیری در برابر خطاهای ناخواسته را از
ویژگی‌های شبکه عصبی مصنوعی ذکر کرده‌اند. به اعتقاد
طهماسبی و زمردیان، (۱۳۸۳) خطای داده‌ای در توابع
ریاضی معمولاً منجر به خطای بزرگ ناخواسته در نتایج
خرجی می‌شود، در صورتی که در شبکه‌های عصبی
مصنوعی تا حد زیادی این خطاهای تاثیر خود را از دست
می‌دهند. شایان‌نژاد (۱۳۸۵) با مقایسه برآوردهای حاصل
از روش پنمن- مانتیس- فائق و شبکه عصبی نتیجه گرفت
که روش شبکه عصبی با نیاز اطلاعاتی کمتر، نسبت به
روش پنمن- مانتیس دقیق‌تر است. پلنگی و همکاران
(۱۳۸۵) نیز به طریق مشابه با مطالعه تبخیر و تعرق گیاه
مرجع در منطقه اهواز نتیجه گرفتند که پیش‌بینی‌های
شبکه عصبی در مقایسه با روش پنمن- مانتیس- فائق
دارای خطای کمتری است. قاسمی و همکاران (۱۳۸۶)
شبکه‌های عصبی مصنوعی را ابزاری مناسب با سرعت و
دقت کافی در تعیین تبخیر و تعرق گیاه مرجع معرفی
نمودند. کمار و همکاران (۲۰۰۲) شبکه عصبی را ابزاری
برتر و توانمندتر در مقایسه با روش‌های تجربی برای
پیش‌بینی تبخیر و تعرق گیاه مرجع دیویس (کالیفرنیا)

مصنوعی با نتایج لایسیمتری و ارزیابی دقت آنها از اهداف دیگر این مطالعه میباشد.

مواد و روش‌ها

به منظور انجام این پژوهش از داده‌های اندازه‌گیری شده دو ساله تبخیر و تعرق گیاه مرجع چمن حاصل از سه دستگاه لایسیمتر زهکش‌دار به ابعاد $2/25 \times 1 \times 1$ متر استفاده شد. لایسیمترها در ایستگاه تحقیقاتی اکباتان، شهرستان همدان با طول جغرافیایی $48^{\circ} 32'$ شمالی و عرض جغرافیایی $52^{\circ} 34'$ شرقی در ارتفاع ۱۷۳۰ متری از سطح دریا استقرار داشتند. آب هوای منطقه نیمه خشک سرد با میانگین حداقل دمای 40° و میانگین حداقل دمای 34° - درجه سانتی‌گراد است. متوسط سالیانه بارش $312/3$ میلی‌متر و متوسط تعداد روزهای یخ‌بندان 142 روز می‌باشد (بی‌نام، ۱۳۷۹). تبخیر و تعرق با استفاده از داده‌های اقلیمی ایستگاه هواشناسی سینوپتیک فرودگاه همدان با 14 روش تجربی و شبکه‌های عصبی مصنوعی محاسبه و با نتایج لایسیمتر مقایسه شدند. اندازه‌گیری‌های لایسیمتری براساس معادله بیلان آب خاک درون آن به صورت روزانه انجام شد (اتوست و همکاران، ۲۰۰۷):

$$(1) ET_{0i} = I_i + P_i - D_i \pm (W_{i-1} - W_i)$$

که در آن i تبخیر و تعرق بالقوه گیاه مرجع (میلی‌متر در روز)، I_i مقدار آب آبیاری (میلی‌متر)، P_i مقدار بارندگی (میلی‌متر)، D_i مقدار زه‌آب (میلی‌متر)، W_{i-1} : مقدار رطوبت خاک در زمان اول اندازه‌گیری (میلی‌متر) و W_i : مقدار رطوبت خاک در زمان دوم اندازه‌گیری (میلی‌متر) می‌باشد.

به منظور افزایش دقت نتایج لایسیمتری در حدود 1500 مترمربع اطراف لایسیمترها نیز با شرایط یکسان چمن کشت گردیده و آبیاری شد. جهت اطمینان از نشت، دیواره‌های لایسیمتر قبل از نصب با قیر و گونی اندود شد. همچنین جهت جلوگیری از نشست، محل استقرار آن بتون ریزی گردید. برای سهولت حرکت زه‌آب، ابتدا یک لایه شن به ضخامت 20 سانتی‌متر در کف و سپس لایه‌های خاک به گونه‌ای مشابه با زمین اطراف درون لایسیمتر قرار گرفت. پس از پر نمودن لایسیمتر از

دانستند. برتن و همکاران (۲۰۰۰) به کمک شبکه عصبی، تبخیر روزانه تست را در بازه زمانی 1992 تا 1996 برای برخی از شهرهای مهم جهان پیش‌بینی کردند. خطای شبکه عصبی در مقایسه با سایر روش‌ها در مطالعه فوق کمتر و حداکثر معادل 0.011 میلی‌متر در روز گزارش شد. تراجکویک و همکاران (۲۰۰۳) برای پیش‌بینی تبخیر و تعرق گیاه مرجع از شبکه عصبی استفاده نمودند. آنان برای پیش‌بینی تبخیر و تعرق روز بعد، از مقادیر تبخیر و تعرق 11 و 23 روز قبل استفاده کردند. نسبت تبخیر و تعرق پیش‌بینی به اندازه‌گیری 0.994 بود که نشان‌دهنده کارایی خوب شبکه عصبی است. کانون و ویتفیلد (۲۰۰۲) با انجام مطالعاتی در خصوص پیش‌بینی رواناب مربوط به ریزش‌های جوی 21 حوزه در کانادا، شبکه عصبی را دارای کارائی بالائی نسبت به مدل رگرسیون خطی دانستند. کیسی (۲۰۰۶) در پیش‌بینی تبخیر و تعرق مرجع روزانه، از شبکه عصبی با دو مدل آموزش لورنبرگ-مارکوات¹ (LM) و گرادیان مزدوج² (CG) استفاده کرد. مقایسه نتایج شبکه عصبی با مدل پنمن و هارگریوز نشان داد که شبکه عصبی با دقت بالاتری قادر است تا تبخیر و تعرق را به کمک داده‌های هواشناسی پیش‌بینی نماید. زانتی و همکاران (۲۰۰۷) از شبکه عصبی با حداقل داده‌های هواشناسی برای تخمین تبخیر و تعرق در شهر ریودو-ژانیروی برزیل استفاده کردند. آنان از سری زمانی داده‌های هواشناسی سپتامبر 1996 تا آگوست 2002 برای آموزش شبکه استفاده نمودند. نتایج به دست آمده نشان داد شبکه عصبی با دمای حداقل و حداقل هوا به عنوان ورودی قابلیت پیش‌بینی تبخیر و تعرق را دارد. آرکا و همکاران (۱۹۹۸) از شبکه عصبی مصنوعی جهت پیش‌بینی تبخیر از تست کلاس A و تکمیل داده‌های مفقوده سال‌های قبل، بهره جست.

اهداف این پژوهش شامل ارائه مناسب‌ترین روش تعیین تبخیر و تعرق از طریق روش‌های تجربی و شبکه‌های عصبی مصنوعی در منطقه همدان است. همچنین مقایسه بین نتایج روش‌های تجربی و شبکه‌های عصبی

1. Levenberg-Marquardt
2. Conjugate Gradient

های ۱۳۷۶ و ۱۳۷۷ جهت آموزش و از باقی‌مانده داده‌ها برای کنترل صحت برآوردها استفاده شد. در لایه ورودی از اطلاعات اقلیمی ایستگاه هواشناسی فرودگاه (اکباتان) شامل حداکثر و حداقل دمای هوا، حداکثر و حداقل رطوبت نسبی هوا، سرعت باد و ساعت‌های آفتابی استفاده شد. انتخاب تعداد لایه پنهان و تعداد نرون‌های هر لایه، به روش آزمون و خطا انجام شد.

توابع آستانه (محرك) متفاوتی نظیر توابع سینوسی، سینگوموید، خطی، تانژانت هایپربولیک و ساختار شبکه عصبی دیجیتالی^۴ برای یافتن حالت بهینه شبکه مورد ارزیابی قرار گرفتند. نرم‌افزار مجموع وزن ورودی (X_j) به هر نرون از لایه j را از طریق رابطه زیر لحاظ می‌کند (خانا، ۱۹۹۰).

$$X_j = \sum_{i=1}^m W_{ij} \times Y_i + b_j \quad (3)$$

که m تعداد نرون‌های لایه خروجی، W_{ij} وزن بین لایه i و j ، خروجی نرون j و b_j بیاس نرون لایه j است. از قواعد یادگیری مختلف برای بهنگام‌سازی وزن‌های شبکه عصبی طراحی ده و کاهش خطای یادگیری در فرآیند آموزش استفاده شد. قواعد شامل قاعده دلتا^۵، قاعده نرم‌آنباشت^۶، قاعده Ext DBD^۷، قاعده پسانشوار سریع^۸، قاعده بیش پسانشوار^۹، قاعده دلتا-بار دلتا^{۱۰} بودند.

انتخاب تعداد لایه پنهان و تعداد نرون‌های هر لایه، به روش آزمون و خطا انجام شد. در نهایت لازم است تا از بین شبکه (های) ایجاد شده در مرحله قبل، شبکه (های) بهینه تشخیص داده شوند. این امر مستلزم ارضا معیارهای معیار خطای مربعات میانگین^{۱۱} خطای میانگین مطلق^{۱۲} و انحراف معیار خطای میانگین مطلق^{۱۳} می‌باشد. شکل ریاضی معیارهای استفاده شده به صورت زیر است (دایهوف ۱۹۹۰).

4. Digital neural network architecture

5. Delta-rule

6. Norm-cum delta-rule

7. Extended delta- bar- delta-rule

8. Quick propagation rule

9. Max propagation rule

10. Delta bar delta rule

11. Root mean square error

12. Mean absolute error

13. Standard deviation mean absolute error

خاک، به اندازه کافی به آن آب داده شد تا اشباع شود و خاک نشست لازم را جهت حصول شرایط طبیعی نماید و خصوصیات فیزیکی خاک، مشابه زمین اطراف باشد. بافت خاک محل اجرای آزمایش؛ متوسط تا سنگین شامل بافت لومی برای لایه ۰-۲۶ سانتی‌متر، لوم-رس ۹۴-۹۶ سانتی‌متر و شنی برای لایه ۹۶-۱۶۰ سانتی‌متر بود. همچنین حدود رطوبتی خاک لایسیمتر دارای حد ظرفیت زراعی ۲۲/۱، نقطه پژمردگی دائم ۱۰/۳۵ درصد وزنی و چگالی ظاهری ۱/۸۲ گرم بر سانتی‌متر مکعب بود.

در این پژوهش از ۱۴ روش تجربی متکی بر داده‌های اقلیمی در پنج گروه ترکیبی، دائمی، تشعشعی، رطوبتی و تشت تبخیر برای برآورد تبخیر و تعرق گیاه مرجع استفاده شد. در گروه روش‌های دائمی از روابط بلانی-کریدل-فائو، کریستین-هارگریوز، جنسن و همکاران، وان‌باول لیناکر و در گروه روش‌های تشعشعی و تشعشعی-دائمی از روابط تشعشعی فائو، سورک، مکینگ استفاده شد. از صور مختلف رابطه پنمن نظیر پنمن-فائو، پنمن-رایت، پنمن-مانتیس و رایت به عنوان روش‌های ترکیبی و از تشت تبخیر فائو برای برآورد تبخیر و تعرق گیاه مرجع استفاده شد. پس از این مرحله باقیستی تبخیر و تعرق از طریق شبکه عصبی به دست آید Neural Work Professional II, Plus (Ver.5.23) قابل پیگیری است. در شبکه‌های عصبی لازم است تا برای افزایش دقت و سرعت شبکه، داده‌های ورودی و خروجی در شکل هنجار^۱ (رابطه ۲) به کار گرفته شوند.

$$X_n = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (2)$$

که X_n مقدار هنجارشده، X_{\min} مقدار واقعی، X_{\max} کمینه مقدار واقعی و X_{\min} بیشینه مقدار واقعی است. شبکه عصبی مصنوعی انتخابی پرسپترون چند لایه^۲ (MLP) با ساختار پیشخور بود. برای آموزش شبکه از الگوریتم پسانشوار خطای^۳ (BP) استفاده شد. بدین منظور ۷۰ درصد داده‌های هواشناسی موجود در سال-

1. Normal

2. Multi layer perceptron

3. Back propagation

$$y = ax^2 + bx + c \quad (8)$$

در روابط فوق y مقادیر ET_0 لایسیمتری، x مقادیر ET_0 برآورده، a و b و c ضرایب تبیین مدل‌ها هستند.

نتایج و بحث

جدول (۱) مقادیر حداکثر و حداقل داده‌های اقلیمی را در دوره دو ساله ۱۳۷۶ و ۱۳۷۷ را به عنوان مقادیر ورودی در لایه اول شبکه عصبی نشان می‌دهد. داده‌های جدول ۱ در دامنه داده‌های هواشناسی ۵۰ سال اخیر می‌باشد.

جدول ۱: پارامترهای ورودی شبکه عصبی مصنوعی و محدوده‌های کمینه و بیشینه آن‌ها

پارامتر	بیشینه	کمینه
۳۹/۸	۰	دماهی حداکثر (c)
-۲۰/۳	-۷	دماهی حداقل (c)
۱۰۰	۳۳	رطوبت نسبی حداکثر (%)
۹۲	۸	رطوبت نسبی حداقل (%)
۱۳/۵	۰	سرعت باد (knot)
۱۴/۱	۰	ساعات آفتابی (h)

پراکنش داده‌های دو ساله‌ی لایسیمتری مورد استفاده در این پژوهش در شکل ۱ نشان داده شده است. آن‌چه که از این شکل مشخص می‌شود، آن است که داده‌های سال دوم از پراکنش کمتری برخوردار هستند. این امر می‌تواند ناشی از بهبود ساختمان خاک در اثر کشت و کار ناشی از سال قبل و دقیت در اندازه‌گیری‌ها باشد. در حالی که در سال اول هر چند سعی شد تا خاک درون لایسیمتر مشابه خاک زمین طبیعی باشد، اما به هر حال درون لایسیمتر از خاک دست‌خورده پرسد و تجربه و مهارت سال دوم نیز بیش از سال اول بود. حداکثر مقدار تبخیر و تعرق براساس شکل ۱ در هر دو سال زراعی تقریباً در اواسط فصل زراعی در حدود ۸/۵ میلی‌متر در روز قابل مشاهده است.

$$E_{RMS} = \sqrt{\frac{\sum_{p=1}^M \sum_{i=1}^N (S_i - T_i)^2}{M}} \quad (4)$$

$$E_{MA} = \frac{1}{M} \sum_{p=1}^M |S_i - T_i| \quad (5)$$

$$SD_{EMA} = \sqrt{\frac{\sum_{i=1}^M |S_i - T_i| - \bar{|S_i - T_i|}}{M - 1}} \quad (6)$$

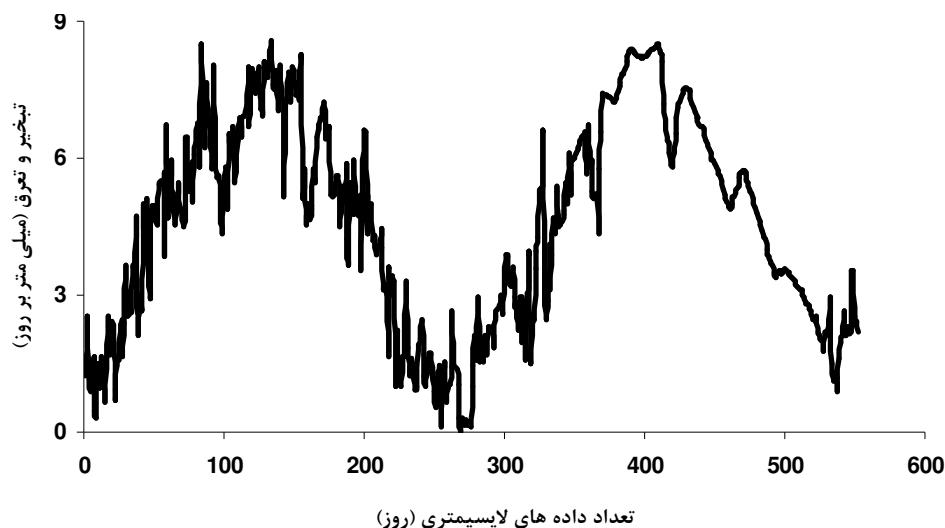
که در آن E_{RMS} خطای مربعات میانگین در مرحله آموزش، S_i خروجی شبکه در نرون λ_m ، T_i خروجی هدف در نرون λ_m ، N تعداد نرون‌های خروجی و M تعداد الگوهای آموزشی است. E_{MA} خطای میانگین مطلق و SD_{EMA} انحراف معیار خطای میانگین مطلق است. سایر پارامترها قبلاً معرفی شده‌اند.

معیارهای ارزیابی برای شبکه عصبی شامل خطای مربعات میانگین حاصل از داده‌های آموزش و تست، خطای میانگین مطلق و انحراف معیار خطای میانگین مطلق می‌باشند. که از نظر عددی حداقل مقادیر را کسب می‌کنند در حالی که معیار ضریب همبستگی باید حداکثر مقدار را کسب نماید. پس از شناسایی شبکه بهینه با توجه به معیارهای ارزیابی فوق از طریق نرم‌افزار به شکل آزمون و خطا اقدام به محاسبه ضریب اندازه حرکت^۱ و ضریب یادگیری^۲ برای تمامی لایه‌ها شد. این کار به منظور ایجاد بهینه‌ترین ساختار شبکه انجام شد. در نهایت نیز شبکه با تعداد تکرارهای مختلف اجرا گردید تا حداقل تکرار لازم برای دستیابی به جواب مطلوب به دست آید.

با به دست آمدن شرایط فوق، انتظار آن است که شبکه عصبی برآوردهای مناسبی از تبخیر و تعرق ارائه دهد. بدین منظور مقادیر لایسیمتری به عنوان تابعی از برآوردهای حاصل از روابط تجربی و شبکه عصبی بهینه ارزیابی گردید. هدف ارائه رابطه‌ای ساده و کاربردی با توجه به ضریب همبستگی برای سنجش‌های میدانی است. در این راستا از مدل‌های خطی و چند جمله‌ای درجه دو استفاده شد. فرم کلی مدل‌ها به صورت زیر می‌باشند (زارع ابیانه و همکاران، ۲۰۰۵).

$$y = ax + b \quad (7)$$

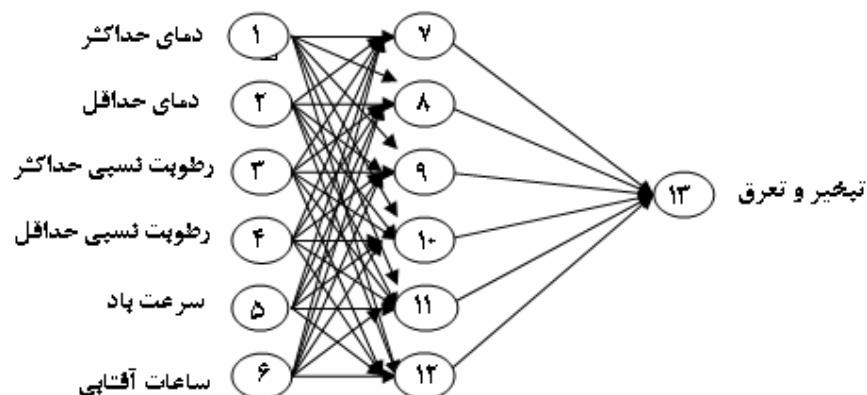
1. Momentum
2. Learning coefficient



شکل ۱: پراکندگی داده‌های لایسیمتری مورد استفاده در شبکه عصبی

جدول ۲ آرایش ردیفهای ۲، ۳، ۶ و ۱۳ به دلیل بالا بودن ضریب همبستگی در مقایسه با سایر آرایش‌ها مطلوب هستند. در بین آرایش‌های یاد شده آرایشی از شبکه عصبی مناسب است که از نظر عددی کمترین مقدار را از سایر معیارهای ارزیابی به خود اختصاص داده است. به این ترتیب آرایش ۱-۶-۶-۶ به عنوان آرایش بهینه قابل توجه است. وضعیت شماتیک آرایش بهینه انتخابی در شکل ۲ نشان داده است. پیشنهاد آرایش ۱-۶-۶-۶ با نتایج شایان نژاد (۱۳۸۵) و نتایج پلنگی و همکاران (۱۳۸۵) هم خوانی دارد.

نتایج آرایش‌های بهینه مختلف شبکه عصبی با قوانین مختلف یادگیری و توابع آستانه متفاوت (از بین تمامی آرایش‌ها) و دیگر توابع محرک مورد آزمایش برای ۲۰ آرایش متفاوت، در جدول ۲ نشان داده شده است. نتایج جدول ۲ براساس داده‌های هنجار شده (رابطه ۶) می‌باشند. همان‌گونه که قبلاً بیان شد آرایشی که کمترین مقدار خطای مربعات میانگین حاصل از داده‌های آموزش و تست، خطای میانگین مطلق و انحراف معیار خطای میانگین مطلق را در کنار حداقل ضریب همبستگی کسب نماید، مناسب‌ترین نوع شبکه عصبی در بین شبکه‌های اجرشده است. لذا براساس



شکل ۲: ساختار شبکه عصبی مصنوعی بهینه مورد استفاده

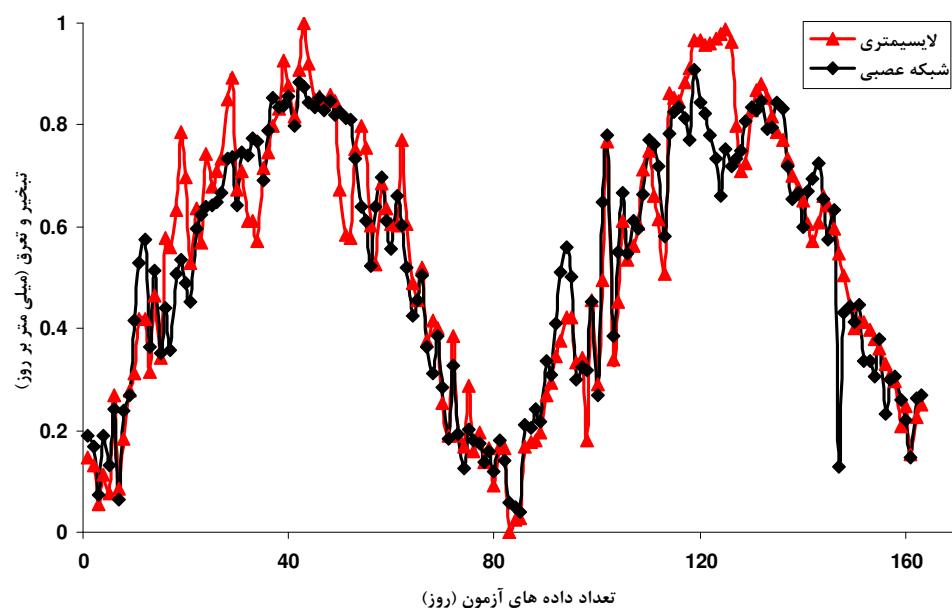
جدول ۲: خلاصه نتایج آماری مربوط به اجرای آرایش‌های مختلف شبکه عصبی

ردیف	آرایش شبکه*	قانون یادگیری	تابع محرك	R^2 **	R_{MSE} ***	R_{MSE}^{**}	E_{MA}	SD_{EMA}
1	6-5-5-1	DELTA	LINEAR	0.85	0.152	0.159	0.074	0.070
2	6-5-5-1	DELTA	TANH	0.86	0.137	0.147	0.070	0.063
3	6-6-1	DELTA	SIGMOID	0.86	0.056	0.057	0.069	0.068
4	6-6-6-1	DELTA	SIGMOID	0.85	0.056	0.057	0.069	0.066
5	6-5-1	DELTA	DNNA	0.85	0.057	0.057	0.069	0.066
6	6-7-7-1	DELTA	SINE	0.86	0.146	0.139	0.071	0.068
7	6-6-1	NORM-CUM	TANH	0.84	0.154	0.152	0.074	0.065
8	6-3-1	NORM-CUM	SIGMOID	0.81	0.063	0.061	0.077	0.069
9	6-3-1	NORM-CUM	DNNA	0.80	0.065	0.063	0.081	0.070
10	6-4-1	NORM-CUM	SINE	0.85	0.151	0.153	0.070	0.068
11	6-3-1	EXT-DBD	SIGMOID	0.85	0.056	0.057	0.068	0.067
12	6-5-1	EXT-DBD	DNNA	0.85	0.058	0.057	0.071	0.066
13	6-7-1	EXT-DBD	SINE	0.86	0.146	0.151	0.069	0.066
14	6-5-1	QUICKPROP	TANH	0.84	0.177	0.206	0.107	0.082
15	6-3-1	QUICKPROP	SIGMOID	0.84	0.060	0.061	0.073	0.070
16	6-5-1	QUICKPROP	DNNA	0.81	0.064	0.063	0.079	0.070
17	6-8-8-1	QUICKPROP	SINE	0.83	0.291	0.180	0.142	0.095
18	6-5-5-1	DELTA	SIGMOID	0.82	0.171	0.167	0.082	0.069
19	6-8-8-1	DELTA	SIGMOID	0.83	0.159	0.158	0.073	0.069
20	6-8-8-1	NORM-CUM	TANH	0.84	0.159	0.016	0.073	0.070

*، **، *** به ترتیب مربوط به عدد اول تعداد گرههای لایه ورودی، عدد دوم تعداد گرههای پنهان و عدد آخر تعداد گرهها یا داده‌های برآورده.

در روز برای داده‌های هنجارشده نسبت به مقادیر لایسیمتری فاصله دارد. اختلاف بین نتایج برآورده از شبکه عصبی با آرایش ۶-۶-۱ نسبت به مقادیر لایسیمتری در شکل ۳ نشان داده شده است.

براساس جدول ۲، مقدار انحراف معیار خطای میانگین مطلق (ستون آخر) در آرایش ۶-۶-۱ معادل ۰/۰۶۸ است که بیانگر آن است که مقادیر حاصل از شبکه عصبی به طور میانگین به اندازه ۰/۰۶۸ ± میلی‌متر



شکل ۳: خطای واقعی حاصل از پیش‌بینی مقادیر تبخیر و تعرق مرجع بهوسیله شبکه بهینه طراحی شده

مناسب بودن نسبی ضریب همبستگی روش و جامعیت روش پنمن- فائو نسبت به سایر روش‌ها برای منطقه قابل توصیه باشد. همچنین شبکه عصبی در مقایسه با تمامی روش‌ها تجربی برآوردهای مناسب‌تری از تبخیر و تعرق گیاه مرجع داشته‌است. مشابه چنین نتیجه‌ای را قاسمی و همکاران (۱۳۸۶) و آرکا و همکاران (۱۹۹۸) توصیه نمودند.

شکل ۵ نشان می‌دهد که افزایش تعداد تکرارهای محاسبات منجر به کاهش دامنه نوسانات E_{RMS} و ثابت-شدن آن می‌شود. به عبارت دیگر افزایش تعداد تکرارها بیش از حد مشخصی نه تنها تاثیر خاصی بر افزایش دقت نتایج نداشته، بلکه سبب افزایش هزینه زمان محاسباتی می‌گردد. بر این اساس و با توجه به شکل ۵ انجام عملیات تکرار تا حد ۴۰۰۰ تکرار مناسب به نظر می‌رسد و در تکرارهای بیشتر دامنه نوسانات E_{RMS} ثابت است.

همان‌گونه که رابطه ۲ و شکل ۲ نشان می‌دهند، نرون‌های هر لایه، خروجی دارند که مجموع خروجی تمامی نرون‌ها به عنوان ورودی نرون لایه بعدی محسوب می‌شود. به عبارت دیگر وزن‌های اعمال شده در بهینه-ترین حالت در جدول ۴ ارائه شده است.

از معیارهای دیگر که در انتخاب ساختار بهینه شبکه عصبی قابل پیگیری است، مقادیر ضریب اندازه حرکت، ضریب یادگیری لایه‌ها یک شبکه می‌باشد. در پژوهش حاضر مقادیر ضریب اندازه حرکت، ضریب یادگیری لایه اول، لایه پنهان دوم و لایه خروجی برای شبکه عصبی بهینه به طریق آزمون و خطای بهترین $0/۹$ ، $0/۲۵$ و $0/۱۵$ به دست آمد که در دامنه توصیه شده توسط پژوهشگران است (امیری چایجان، ۲۰۰۶).

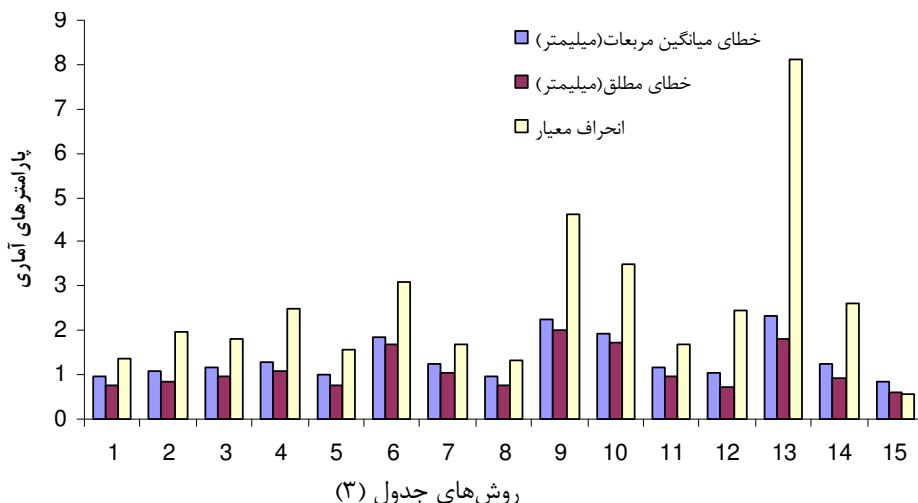
به منظور انتخاب روش مناسب از میان ۱۴ روش تجربی و شبکه عصبی مصنوعی با آرایش ۱-۶-۶ به عنوان آرایش مناسب اعتبارسنجی به گونه‌ای دیگر با هدف ارائه رابطه‌ای ساده و کاربردی در سنجش‌های میدانی انجام شد. بدین ترتیب که ضریب همبستگی (R^2) حاصل از روش‌های تجربی و شبکه عصبی (آرایش ۱-۶-۶) در مقایسه با داده‌های لایسیمتری به عنوان ملاک نسبتاً مناسب مد نظر قرار گرفت (جدول ۳). جدول ۳ نشان می‌دهد که مدل چندجمله‌ای، ضریب همبستگی بالاتری نسبت به مدل خطی دارد. نتایج به کارگیری شبکه عصبی نیز نشان می‌دهد بین مدل خطی و چندجمله‌ای از نظر ضریب همبستگی تفاوتی نیست. بنابراین نسبت به مدل‌های تجربی برآوردهای بهتری ارائه می‌کند. ضرایب مدل‌های خطی و چندجمله‌ای متفاوت از یکدیگر هستند (جدول ۳). به منظور افزایش دقت، عرض از مبدأ صفر پیشنهادی صفر لحاظ گردید. ذکر این نکته بی‌فایده نیست که تخمین براساس عرض از مبدأ صفر نتایج دقیق‌تری را به دست می‌دهد، هر چند ضریب همبستگی قدری کاهش می‌یابد (زارع ابیانه و همکاران، ۲۰۰۵). پس به تبعیت از ضریب همبستگی می‌توان روش‌های تجربی بلانی- کریدل و پنمن- فائو ۲۴ را به ترتیب پیشنهاد نمود. از آن جایی که به دنبال روابط کاربردی هستیم به نظر می‌رسد برآوردهای مدل‌های تجربی و عصبی در قالب مدل چندجمله‌ای با عرض از مبدأ صفر می‌توانند تخمین دقیق‌تری از تبخیر و تعرق لایسیمتری را به دست دهند. روابط رگرسیونی برای ۱۴ روش برآورده تبخیر و تعرق مرجع به انضمام شبکه عصبی در جدول ۳ ارائه شده است.

از طرف دیگر به منظور ارزیابی مناسب‌تر از نتایج جدول ۳ معیارهای خطای میانگین مربعات (R_{MSE})، خطای میانگین مطلق (E_{MA}) و انحراف از معیار نتایج (SD_{EMA}) حاصل از روش‌های تجربی و شبکه عصبی (آرایش ۱-۶-۶) در مقایسه با داده‌های لایسیمتری نیز در شکل ۴ ترسیم شدند. شکل ۴ بر اساس نتایج داده‌های غیرهنگار حاصل روش‌های تجربی و مدل ۱-۶-۶ شبکه عصبی می‌باشد. شکل ۴ نشان می‌دهد که براساس معیارهای خطای میانگین مربعات و انحراف از معیار و

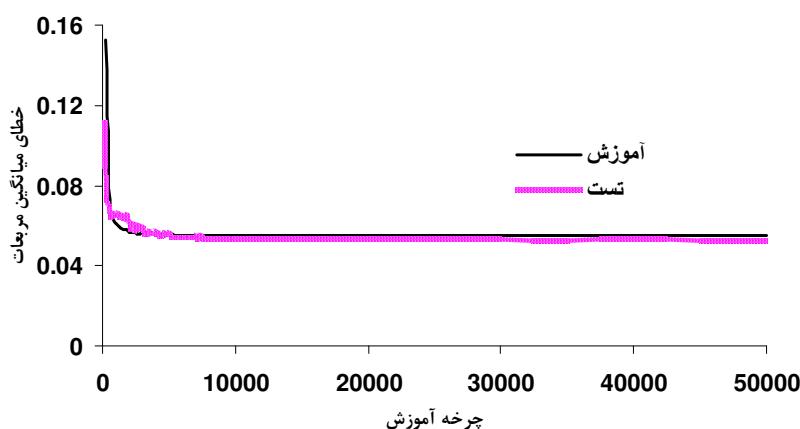
جدول ۳: ضریب همبستگی مدل‌های برازش داده شده برای روش‌های مختلف تبخیر و تعرق

شماره	روش	مدل خطی			مدل خطی			مدل چندجمله‌ای				مدل چندجمله‌ای			R _{MSE}	E _{MA}	SD EMA
		a	b	R ^{2*}	a	R ^{2*}	a	b	c	R ^{2*}	a	b	R ^{2*}				
1	پنمن (۲۴)	0.81	1.23	0.68	1.02	0.63	-0.04	1.28	0.18	0.69	-0.05	1.36	0.69	0.961	0.765	1.365	
2	(C = ۱ با ۲۴)	0.71	1.51	0.64	0.95	0.56	-0.06	1.34	0.02	0.66	-0.06	1.36	0.66	1.078	0.842	1.968	
3	پنمن-رایت (۱۹۸۲)	0.65	2.05	0.66	0.99	0.46	-0.06	1.33	0.57	0.68	-0.08	1.57	0.68	1.155	0.952	1.817	
4	تشتک (فائقو)	0.89	1.42	0.68	1.16	0.61	-0.07	1.58	0.02	0.69	-0.07	1.60	0.69	1.290	1.069	2.481	
5	بلانی-کریدل (فائقو)	0.70	1.57	0.70	0.99	0.60	-0.04	1.23	0.46	0.71	-0.06	1.41	0.71	0.989	0.770	1.555	
6	پنمن-ماتیث	1.02	1.55	0.66	1.37	0.57	-0.09	1.73	0.41	0.67	-0.12	1.97	0.67	1.865	1.676	3.087	
7	رایت (۱۹۸۹)	0.66	2.19	0.64	1.04	0.41	-0.08	1.44	0.59	0.67	-0.10	1.70	0.67	1.232	1.053	1.676	
8	پنمن (۱۹۶۳)	0.83	1.15	0.68	1.03	0.64	-0.05	1.34	0.03	0.68	-0.05	1.36	0.68	0.968	0.774	1.323	
9	وان باول-لیناکر (۱۹۶۹)	1.26	1.01	0.57	1.52	0.54	-0.24	2.92	-1.51	0.59	-0.11	2.0	0.58	2.249	2.005	4.633	
10	مکینگ (۱۹۵۷)	1.2	0.86	0.63	1.4	0.61	-0.22	2.85	-1.93	0.65	-0.08	1.77	0.64	1.936	1.724	3.494	
11	تورک	0.87	1.36	0.69	1.12	0.63	-0.08	1.62	-0.10	0.70	-0.07	1.55	0.70	1.158	0.967	1.698	
12	کریستینسن-هارگریوز (۱۹۶۸)	0.74	1.59	0.66	1.0	0.57	-0.07	1.51	-0.20	0.68	-0.06	1.43	0.68	1.034	0.722	2.443	
13	جنسن و همکاران (۱۹۷۰)	0.42	2.7	0.66	0.75	0.18	-0.04	0.97	1.23	0.70	-0.06	1.36	0.68	2.341	1.813	8.135	
14	تشعشعی (فائقو)	0.69	1.23	0.68	0.87	0.63	-0.04	1.22	-0.12	0.69	-0.04	1.18	0.69	1.245	0.929	2.609	
15	شبکه عصبی مصنوعی	1.0	0.01	0.86	1.01	0.86	0.08	0.92	0.03	0.86	0.01	1.0	0.86	0.827	0.592	0.579	

*معنی دار در سطح ۵ درصد



شکل ۴: دسته‌بندی روش‌های پی‌آورده کننده تبخیر و تعرق پر اساس RMSE و MAE و STDV



شکل ۵: ارتباط بین E_{RMS} آموزش و تعداد تکرارهای محاسباتی

جدول ۴: مقدار وزن‌های ارتباطی بین نرون‌ها در شبکه طراحی شده بهینه

یافت. افزایش سرعت و دقت در محاسبات با شبکه عصبی مصنوعی از سوی میثاقی و محمدی (۱۳۸۳) و زانتی و همکاران (۲۰۰۷) نیز گزارش شده است. نتایج آرایش‌های مختلف شبکه عصبی (جدول ۲) بیانگر آن است که کاهش لایه‌های پنهان، به یک لایه از دقت نتایج نمی‌کاهد و از نظر زمانی نیز مقرن به صرفه خواهد بود. لذا ساختار شبکه عصبی ۱-۶ به عنوان آرایش بهینه ارزیابی می‌گردد. از نظر نوع تابع آستانه، توابع سیگموئید و ساختار شبکه عصبی دیجیتالی به عنوان توابع مناسب تشخیص داده شد و اختلاف خاصی بین تابع آستانه سیگموئید و ساختار شبکه عصبی دیجیتالی مشاهده نشد (جدول ۲). نتیجه مشابهی نیز در خصوص کاهش تکرارهای محاسباتی حاصل شد (شکل ۵). که مشابه نتایج گزارش شده توسط قاسمی و همکاران (۱۳۸۶) است.

نتیجه‌گیری

در نهایت با توجه به جدول شماره ۳ می‌توان چنین اظهار داشت که پنمن- فائو ۲۴ در بین روش‌های تجربی رتبه دوم ضریب همبستگی، رتبه اول E_{RMS} دوم SD_{EMA} و رتبه دوم E_{MA} را دارد. روش پنمن E_{RMS} مانیث رتبه هفتم ضریب همبستگی، رتبه یازدهم SD_{EMA} و رتبه یازدهم E_{MB} و رتبه یازدهم SD_{EMA} را دارد. مطالعه حاضر نشان داد که روش پنمن- فائو ۲۴ نسبت به روش پنمن مانیس اصلاح شده توسط فائو برای منطقه نیمه خشکی چون همدان مناسب‌تر است. مقایسه نتایج لایسیمتری با برآوردهای حاصل از شبکه عصبی، برتری شبکه عصبی را نسبت به مدل تجربی پنمن- فائو (جدول ۳ و شکل ۴) نشان داد. این امر ضمن افزایش دقت برآوردها، حاکی از آن است که با صرف زمان کمتری می‌توان به برآوردهای مناسب‌تری دست

مراجع

- بی‌نام، ۱۳۷۹. سال‌نامه هواشناسی استان همدان، سازمان هواشناسی کشور. پلنگی، ج.، معاضد، ھ. و طارقیان، ر. ۱۳۸۵. تخمین تبخیر و تعرق گیاه مرجع با استفاده از شبکه‌های عصبی در اهواز. همایش ملی مدیریت شبکه‌های آبیاری و زهکشی، دانشگاه شهید چمران اهواز.
- رحیمزادگان، ر. ۱۳۷۰، جستجوی روش مناسب برآورد تبخیر و تعرق در منطقه اصفهان، مجله علوم کشاورزی ایران، جلد ۲۲ شماره‌های ۱ و ۲.
- رضایی، ع. ۱۳۸۰. مدل‌سازی سیل و خشک‌سالی با استفاده از شبکه عصبی مصنوعی (ANN). اولین کنفرانس بررسی راهکارهای مقابله با بحران آب. دانشگاه زابل.
- rstemi، ا. ۱۳۷۴، گزارش نهایی تعیین تبخیر و تعرق پتانسیل گیاه مرجع با استفاده از لایسیمتر و مقایسه آن با فرمول تجربی، نشریه مرکز تحقیقات کشاورزی استان مرکزی.
- زارع ابیانه، ح.، قاسمی، ع. و احمدی، م. ۱۳۸۶. تعیین مناسب‌ترین روش برآورد تبخیر و تعرق گیاه مرجع در مقایسه با روش‌های تجربی برای منطقه همدان. نهمین سمینار آبیاری و کاهش تبخیر دانشگاه شهید باهنر کرمان.
- طهماسبی، ع. ر. و زمردان، س. م. ع. ۱۳۸۳. برآورد پتانسیل روان‌گرایی خاک‌ها با استفاده از شبکه عصبی مصنوعی. دومین کنفرانس ملی دانشجویی منابع آب و خاک. شیراز.
- شایان‌نژاد، م. ۱۳۸۵. مقایسه دقت روش‌های شبکه‌های عصبی مصنوعی و پنمن - مانتیس در محاسبه تبخیر و تعرق پتانسیل. همایش ملی مدیریت شبکه‌های آبیاری و زهکشی، دانشگاه شهید چمران اهواز.
- شریفان، ح.، قهرمان، ب.، علیزاده، ا. و میر لطیفی، س. م. ۱۳۸۵. مقایسه برآورد تبخیر و تعرق مرجع (ترکیبی و دمایی) با روش استاندارد و بررسی اثرات خشکی هوا بر آن (۱۳(۱): ۱۹-۲۹.
- قاسمی، ع.، زارع ابیانه، ح.، امیری چایجان، ر و محمدی، ک. ۱۳۸۶. ارزیابی دقت روش شبکه‌های عصبی مصنوعی و معادلات تجربی در محاسبه تبخیر و تعرق پتانسیل در استان همدان. نهمین سمینار آبیاری و کاهش تبخیر دانشگاه شهید باهنر کرمان.
- ضیاء تباراحمدی، م. خ. ۱۳۷۴. بررسی و مقایسه روش‌های محاسبه تبخیر و تعرق پتانسیل در استان مازندران، نیوار. شماره ۵۵-۴۰. ۲۸.
- میثاقی، ف. و محمدی، ک. ۱۳۸۳. پیش‌بینی تغییرات کیفیت آب رودخانه زاینده رود با استفاده از شبکه‌های عصبی مصنوعی. دومین کنفرانس ملی دانشجویی منابع آب و خاک. شیراز.
- نیک‌بخت، ج.، میرلطیفی، س. م. و کمالی، غ. ع. ۱۳۸۰. مقایسه تبخیر و تعرق محاسبه شده با روش‌های فائو-پنمن-مانتیث، پنمن-رایت و هارگریوز-سامانی در منطقه تهران. مجله علوم کشاورزی و منابع طبیعی گرگان، ۸(۴): ۳-۱۳.
- Amiri Chayjan, R. 2007. Prediction of pistachio thermal conductivity using artificial neural network approach. Int. J. Agri. Biol 9 (2).
- Arca, B., Benincasa, F., De Vincenzi, M. and Ventura A. 1998. Neural network to simulate evaporation from Class A pan. Proceedings of the 23rd Conference of agricultural and forest meteorology. New Mexico 258-288.
- Bruton, J. M., McClendon, R. W. and Hoogenboom, G. 2000. Estimating daily pan evaporation with artificial neural network. Trans. ASAE 43(2): 492-496.
- Cannon, A. J. and Whitfield, P. H. 2002. Down scaling recent stream-flow conditions in British Columbia, Canada using ensemble neural networks. J. Hydro 259: 136-151.
- Dayhoff, J. E. 1990. Neural Networks Principles. Prentice-Hall International, U.S.A.
- Dehghani Sanij, H., Yamamoto, T. and Rasiah, V. 2004. Assessment of evapotranspiration estimation models for use in semi-arid environments. Agricultural Water Management 64: 91-106.
- Dinpashoh, Y. 2006. Study of reference crop evapotranspiration in I.R. of Iran. Agricultural water management 84: 123-129.

- Doorenbos, J. and Pruitt, W.O. 1977. Guidelines for predicting crop water requirements. Irrigation Drainage Paper, No. 24, FAO, Rome, Italy.
- Ismail, S.M. 1993. Reference evapotranspiration study in Al-Qassim region. CAB Abstracts 1993-1994.
- Khanna, T. 1990. Foundations of Neural Networks. Addison-Wesley Publishing Company, USA.
- Kisi, O. 2006. Evapotranspiration estimation using feed-forward neural network. Nordic Hydrology 37(3): 247-260.
- Kumar, M., Raghwanshi, N. S., Singh, R., Wallender, W. W. and Pruitt W.O. 2002 Estimating evapotranspiration using artificial neural networks. J. Irr. and Drainage, ASCE 128(4): 224-233.
- Lek, S., Guiresse, M. and Giraudeau, J. L. 1999. Predicting stream nitrogen concentration from watershed features using neural networks. J. of University Paul Sabatier. Toulouse, France Water research 33(16): 3469-3478.
- Nwadiago, B. E. 1991. The estimation of reference crop evapotranspiration with minimum data in tropical climate. CAB Abstracts, 1992.
- Santos, A.O., Bergamaschi, H., Cunha, G. 1994. Evaluation of method for estimation of maximum evapotranspiration in lucene. CAB Abstract 1996-1997.
- Sarangi, A. Singh, M., Bhattacharya, A. K. and Singh, A. K. 2006. Subsurface drainage performance study using SALTMOD and ANN models. J. Agr. Water Manage 84(3): 240-248.
- Trajkovic, S., Todorovic, B. and Stankovic, M. 2003. Forecasting of reference evapotranspiration by artificial neural network. J. Irr. and Drainage. ASCE 129(6): 454-457.
- Zanetti S. S., Sousa,, E. F., Olivera, V. P. S., Almeida, F. T. and Bernardo, S. 2007. Estimating evapotranspiration using artificial neural network and minimum climatological data. J. Irr. and Drainage Eng., ASCE 133 (2): 83-89.
- Zare Abyaneh, H., Nazemi, A. H., Neyshabori, M. R., Mohammadi, K. and Majzoobi, G. H. 2005. Estimation in saline waters from Electrical Conductivity measurement. J. of Agricultural Sciences. Ankara University 11(1): 110-114.
- Utset, A. Velicia, H., Rio, B. D. and Morillo, R. 2007. Calibrating and validation an agro hydrological model to simulate sugar beet water use under Mediterranean. Agricultural water management 94 (1-3): 11-21.

Comparison of Reference Evapotranspiration (ET_0) results of Empirical methods and Artificial Neural Networks with Lysimetric data

Ghasemi¹, A., Zare Abyaneh², H., Amiri Chayjan², R., Mohammadi³, K., Marofi², S. and Ahmadi⁴, M.

Abstract

The purpose of this study is selection of the best method to estimation Reference Evapotranspiration (ET_0). To this purpose, the ET_0 of the region was estimated using meteorological data and different empirical methods as well as Artificial Neural Network (ANNs). Then, the each estimated ET_0 was compared with a 2 year lysimetric data. For ANN various layouts with hidden layer, threshold function and learning rule were performed. The results showed that Penman-FAO method and ANN were useful for this purpose. The results (from empirical methods and ANN) assessment were performed with statistical parameters such as E_{RMS} , E_{MA} , R^2 and SD_{EMA} . According to this results Penman-FAO method had better than the other methods with the second level of R^2 , the first level E_{RMS} , the second level E_{MA} , second level SD_{EMA} . Also, ANN with 6-6-1 layout had been (for the statistical parameters) 0.057, 0.069, 0.86 and 0.068 ($m\text{md}^{-1}$), respectively. Comparison between Penman-FAO, ANN and the lysimeter data showed that high accuracy of ANN rather than Penman-FAO method. Thus, ANN because of low input information and high speed and little time was suggested as the best method. The regression results of ANN and empirical method showed that polynomial model had the high R^2 value than linear model. So, polynomial model because of simplicity and having the high R^2 value is an exact mean of ET_0 estimation.

Keywords: Reference evapotranspiration, Artificial neural networks, Multi layer perceptron, Hamedan

1. M.Sc, Student of Irrigation and Drainage, Bu-Ali Sina University, Hamedan

2. Assistant Professors, Department of Irrigation and Drainage, Faculty of agriculture, Bu-Ali Sina University, Hamedan

3. Associate Professor, Department of Irrigation and Drainage, Faculty of Agriculture, Tarbiat Modares University, Hamedan