



پیش بینی تلفات تبخیر با استفاده از شبکه عصبی مصنوعی

۱- محسن اسکافی نوغانی- دانشجوی کارشناسی ارشد مهندسی منابع آب دانشگاه علوم کشاورزی و منابع طبیعی گرگان آدرس:- دانشگاه تهران - پردیس ابوریحان- گروه مهندسی آبیاری و زهکشی

۲- امیر احمد دهقانی- استادیار دانشگاه علوم کشاورزی و منابع طبیعی گرگان

۳- ابوالفضل مساعدی- دانشیار دانشگاه علوم کشاورزی و منابع طبیعی گرگان

تلفن ۰۲۹۲-۳۰۲۵۹۹۱ پست الکترونیک mohsenskafi@yahoo.com

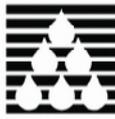
چکیده:

تبخیر یکی از پارامترهای مهم برنامه ریزی و بهره برداری از مخازن آبی می باشد. در ایستگاه های تبخیر سنجی مجاور مخازن این پارامتر اندازه گیری می شود. برنامه ریزی مخازن بر اساس داده های دوره های پیشین انجام می شود بنا بر این مقادیر اندازه گیری شده در ایستگاه های تبخیر سنجی مستقیماً برای برنامه ریزی استفاده نمی شود. تلفات تبخیر از مخازن، به صورت تجربی و بر اساس اندازه گیری های دوره های قبل در نظر گرفته می شود. امروزه مدل های رگرسیونی در سطح وسیعی در علوم مختلف برای پیشگویی به کار گرفته می شوند. از مزایای این مدل ها در دسترس بودن پارامترهای مورد نیاز و سادگی محاسبات می باشد. هدف این تحقیق تدوین مدلی است که بتواند با توجه به متغیرهای هواشناسی مقدار تبخیر از تشت را پیش بینی کند. تا به حال، معادله ای که به صورت کامل روابط فیزیکی این پدیده را بیان کند ارائه نشده است. یکی از روش هایی که در علوم مختلف کاربرد وسیعی دارد شبکه های عصبی مصنوعی (ANNs) می باشد. این شبکه ها با طراحی و آموزش صحیح قابلیت انطباق و نگاشت توابع مختلف را دارند. شبکه های عصبی قادر به ارائه تابع نمی باشند و پس از آموزش با دریافت اطلاعات ورودی مقادیر خروجی را ارائه می دهند. هدف از این تحقیق ارائه یک مدل شبکه عصبی پرسپترون چند لایه با تابع ریاضی آن به صورت یک معادله ماتریسی می باشد. معادلات ماتریسی مدل باعث سادگی کاربرد و استفاده از آن در مدل های برنامه ریزی می شود. مقایسه نتایج این مدل و نتایج اندازه گیری شده در ایستگاه های تبخیر سنجی دقت مدل ارائه شده را تایید می کند.

واژه های کلیدی: تبخیر و تعرق، شبکه های عصبی مصنوعی، مدل رگرسیونی، معادله پنمن ماننیس

مقدمه:

شدت تبخیر با استفاده از تشت تبخیر اندازه گیری می شود. یکی از کاربردهای این پارامتر برآورد تلفات آب در مخازن سدها است. علاوه بر آن تبخیر از اجزای معادله بیلان آبی می باشد. همیشه برنامه ریزی جهت بهره برداری بهینه از منابع آب برای دوره های پیشین انجام می شود. بنابر این مقادیر تبخیر اندازه گیری شده به صورت مستقیم نمی تواند مورد استفاده قرار گیرد. این پارامتر ممکن است به صورت قطعی از معادلات تجربی یا استفاده از میانگین آمار گذشته در نظر گرفته شود. کاربرد دیگر تبخیر از تشت محاسبه تبخیر و تعرق پتانسیل (ETO) می باشد. استفاده از تشت تبخیر کلاس A روشی برای



تخمین ETo می‌باشد این روش در سراسر دنیا مورد استفاده قرار گرفته و دقت آن مورد قبول واقع شده‌است شده‌است [۱]. اسنایدر و همکاران ETo را با استفاده از اطلاعات تشت تبخیر در کالیفرنیا محاسبه نموده‌اند [۲]. دورنبوس و پرویت نسبت ETo به شدت تبخیر از تشت (E_{pan}) را با ضریب K_p ارتباط داده‌اند و با توجه به وضعیت پوشش گیاهی محل نصب و فاصله آن جداولی را ارائه داده‌اند [۳ و ۴]. رحیمی خوب با استفاده از نرم‌افزار SPSS مدل‌های خطی درجه ۱، ۲ و ۳ را مورد بررسی قرار داد و پارامترهای تبخیر از تشت (E_{PAN})، سرعت باد در ارتفاع ۲ متری (U) و رطوبت نسبی (RH) را در ترکیب معادلات برای محاسبه تبخیر و تعرق پتانسیل استفاده نمود [۵].

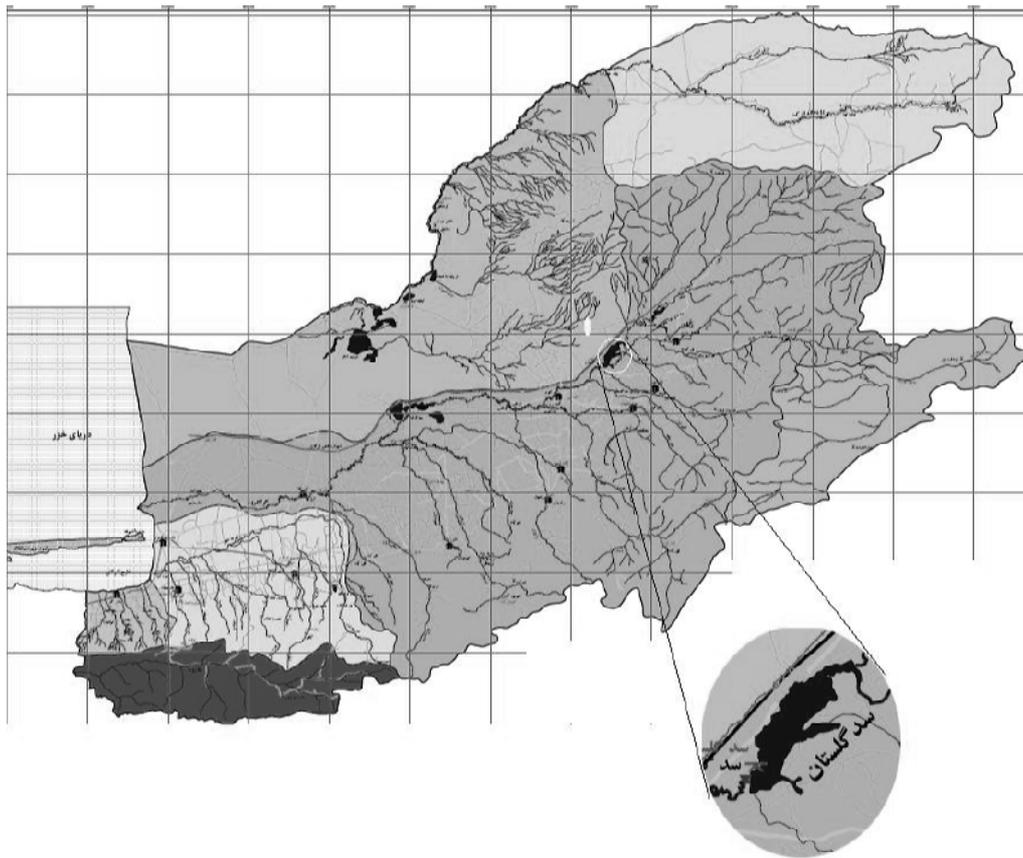
روش دیگری که توجه پژوهشگران را به خود جلب نموده‌است. شبکه‌های عصبی مصنوعی (ANNs) می‌باشد. ANNs برای حل مسائل مختلف در سطح وسیعی از علوم به کار گرفته می‌شود. یکی از مزایای اصلی ANNs حل مسائل غیرخطی و پیچیده مانند Eto می‌باشد [۶]. محققان زیادی برای محاسبه Eto از ANN استفاده نموده‌اند [۷، ۸، ۹ و ۱۰]. نتایج این تحقیقات دقت ANNs را تایید می‌کنند. و برخی از تحقیقات برتری نتایج آن‌ها را نسبت معادله پنمن مانیس (PM) را نشان می‌دهند [۱۱]. رحیمی خوب با ارائه مدل ANN برتری شبکه‌های عصبی هوشمند را نسبت به معادله هارگریورز نشان داد [۱۲]. مدل‌های ANNs قادر به ارائه توابع ریاضی نمی‌باشند و همین موضوع کاربرد آن‌ها را محدود نموده‌است. این مدل‌ها مانند یک جعبه سیاه عمل نموده، ورودی‌ها را دریافت و خروجی‌ها را ارائه می‌دهند، دقت خروجی‌ها بستگی به نحوه آموزش و پارامترهای انتخاب شده دارد. در واقع توابع ریاضی داخل این جعبه سیاه به صورت معادلات ماتریس و توابع تحریک می‌باشند. هدف این تحقیق ارائه مدل شبکه عصبی مصنوعی به همراه معادلات ماتریسی آن برای پیش‌بینی تبخیر روزانه می‌باشد.

مواد و روش‌ها:

محدوده‌ی مورد مطالعه حوزه آبریز گرگانرود می‌باشد و داده‌های لازم برای انجام محاسبات از اداره کل هواشناسی استان گلستان اخذ شده‌است. این اطلاعات شامل درجه حرارت روزانه، ساعات آفتابی، سرعت باد، رطوبت نسبی و تبخیر از تشت می‌باشد. محدوده‌ی زمانی اطلاعات در دسترس، از سال ۱۳۶۳ الی ۱۳۸۶ و ایستگاه مورد مطالعه سد گلستان می‌باشد با توجه به روش مورد مطالعه اطلاعات ده سال اخیر شامل ۳۴۲۸ رکورد در محاسبات استفاده شده‌است. شکل (۱) موقعیت ایستگاه و جدول (۱) میانگین پارامترهای اندازه‌گیری شده را نشان می‌دهد. رکوردهای ناقص اطلاعات اندازه‌گیری شده حذف و همچنین با استفاده از توزیع آماری نرمال که تطابق خوبی با داده‌ها داشت داده‌هایی که احتمال تجمعی آن‌ها کمتر از ۱٪ و بیشتر از ۹۹٪ بود حذف گردید.

جدول (۱) - میانگین پارامترهای اندازه‌گیری شده ایستگاه مورد مطالعه

پارامتر ردیف	میانگین درجه حرارت روزانه	ساعات آفتابی	میانگین سرعت باد روزانه (m/s)	میانگین رطوبت نسبی روزانه (%)	میانگین تبخیر روزانه (mm)
میانگین ده ساله	۱۸/۸	۶/۳	۲/۰	۶۹	۳/۷
بیشینه ده ساله	۳۳/۰	۱۳/۹	۱۳/۰	۹۶/۵	۱۴/۱
کمینه ده ساله	۲/۵	۰/۰	۰/۰	۲۷/۵	۰/۰



شکل (۱) - نمایش موقعیت ایستگاه مورد مطالعه در حوزه آبخیز گرگانرود.

شبکه عصبی مصنوعی:

در این تحقیق از شبکه عصبی پرسپترون چند لایه^۱ (MLP) با یک لایه نهان استفاده شده است. با استفاده از روش آزمون خطا بهترین ساختار شبکه انتخاب شده است. پارامترهای آماری، مجموع مربعات خطا و ضریب تعیین برای گزینش بهترین ساختار استفاده شده اند. تعداد نرون‌های مورد بررسی لایه نهان بین ۲ و ۱۵ نرون در نظر گرفته شده است. توابع تحریک مورد بررسی در نرون‌های لایه نهان و خروجی در زیر آمده است. به منظور آموزش بهتر داده‌های اندازه‌گیری شده ورودی‌ها و خروجی‌های اندازه‌گیری شده به صورت خطی در فاصله (۰ و ۱) نرمال شده است.

$$\begin{cases} y = \frac{1}{1 - e^{(-s)}} \\ y = Tgh(s) \\ y = e^{-e^{-s}} \\ y = s \end{cases}$$

¹ -Multy Layer Perseptron

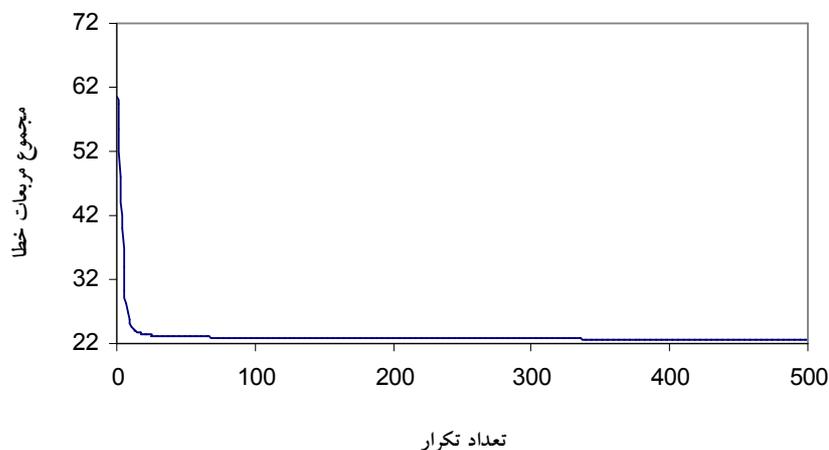


$$\left\{ \begin{array}{l} s = \sum_{i=1}^{input_n} v(j,i) \times Input_i \quad (Hidden\ Layer) \\ s = \sum_{j=1}^{hide_n} G\left(\sum_{i=1}^{input_n} v(j,i) * Input_i\right) \times w(k,j) + b \times w(k,0) \quad (Output\ Layer) \end{array} \right.$$

در معادلات زیر i ، j و k به ترتیب شماره ورودی‌ها، نرون‌های لایه نهان و خروجی‌ها می‌باشند. $Input_n$ تعداد ورودی‌ها، $hide_n$ تعداد نرون‌های لایه نهان، $input$ مقدار ورودی و b مقدار بایاس می‌باشد. معادلات بررسی شده برای نرمال کردن اطلاعات ورودی و خروجی، توابع خطی و سینوسی برای فواصل (۱ و ۰) و (۱ و -۱) مورد استفاده قرار گرفته است. اطلاعات موجود به سه قسمت آموزش، اعتبار سنجی و آزمایش تقسیم شده‌اند در این تقسیم بندی دقت شده است هر قسمت مضربی از تمام داده‌های یک دوره باشد. برای آموزش اطلاعات ۶ سال، برای اعتبار سنجی اطلاعات ۲ سال و برای آزمایش اطلاعات ۲ سال در نظر گرفته شده است. برای انجام محاسبات در محیط ویژوال بیسیک با کد نویسی و کامپایل نرم افزار مورد نیاز تدوین شده است.

نتایج و بحث:

پارامترهای شبکه عصبی پرسپترون چند لایه عبارتند از تعداد نرون‌های لایه مخفی، تابع تحریک لایه نهان و خروجی، ضرایب تصحیح در مراحل مختلف، انتخاب اطلاعات ورودی و انتخاب تابع نرمال می‌باشد. برای گزینش بهترین پارامترها باید ترکیب‌های مختلف آن‌ها بررسی شوند. مجموع مربعات خطا (SSE) در شبکه با افزایش تعداد تکرارهای آموزش کاهش می‌یابد و آموزش شبکه در تکرارهای اولیه سریعتر انجام می‌شود. با افزایش تکرارهای آموزش SSE ثابت می‌شود. مقدار SSE نهایی بیانگر توانایی شبکه در حل مسئله می‌باشد. هر چقدر این پارامتر کوچکتر باشد عملکرد شبکه بهتر است. شکل (۲) نمودار تغییرات SSE را نسبت به تکرار نشان می‌دهد.





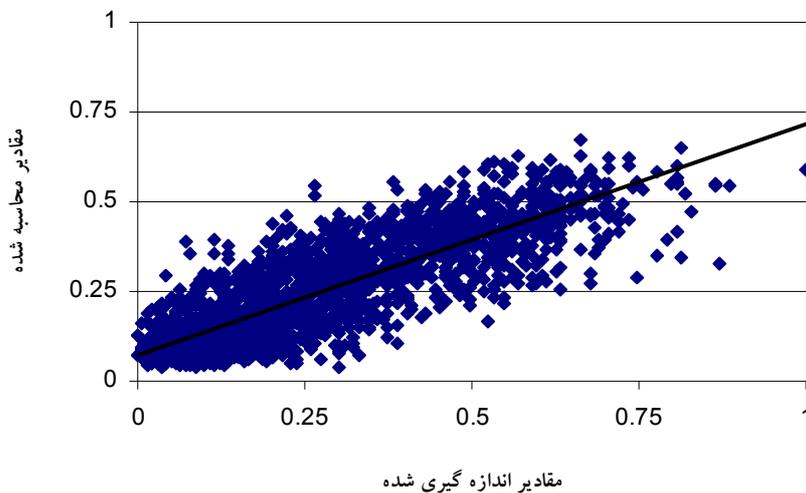
شکل (۲) - نمایش کاهش مجموع مربعات خطا نسبت به تعداد تکرار.

مشخصات شبکه تدوین شده.

تابع تبدیل برای نرمال سازی اطلاعات اندازه گیری شده به شکل زیر می باشد.

$$x_{Normal} = \frac{x - x_{Min}}{x_{Max} - x_{Min}}$$

در معادله (۱) اطلاعات تبدیل شده، x اطلاعات اندازه گیری شده، x_{Ave} میانگین x_{Max} و x_{Min} می باشد. تابع تحریک در لایه نهان و خروجی سیگموئید، تعداد نرون های لایه مخفی ۸ و ضریب تصحیح c ، در ۵۰۰ تکرار اول ۰/۱۵ و در ۵۰۰ تکرار بعدی ۰/۱ می باشد. ضریب همبستگی در مرحله آموزش ۰/۸۵۶ و در مرحله آزمایش و تایید ۰/۸۵۲ می باشد. شکل (۳) نتایج مدل و اندازه گیری شده را با هم مقایسه می کند.



شکل (۳) - نمایش رابطه بین تبخیر اندازه گیری شده و برآورد شده

معادله ماتریسی شبکه طراحی شده به شکل زیر می باشد.

$$[In_1 \quad In_2 \quad In_3 \quad In_4 \quad In_5] \begin{bmatrix} v(1,1) & v(2,1) & v(3,1) & v(4,1) & v(5,1) & v(6,1) & v(7,1) & v(8,1) \\ v(1,2) & v(2,2) & v(3,2) & v(4,2) & v(5,2) & v(6,2) & v(7,2) & v(8,2) \\ v(1,3) & v(2,3) & v(3,3) & v(4,3) & v(5,3) & v(6,3) & v(7,3) & v(8,3) \\ v(1,4) & v(2,4) & v(3,4) & v(4,4) & v(5,4) & v(6,4) & v(7,4) & v(8,4) \\ v(1,5) & v(2,5) & v(3,5) & v(4,5) & v(5,5) & v(6,5) & v(7,5) & v(8,5) \end{bmatrix} = [S_{Hid}]$$

$$[f(S_{Hid})] [W] = S_{Out} = Output = f(S_{out})$$



در معادلات بالا مقادیر In_1 تا In_5 به ترتیب حداکثر درجه حرارت، حداقل درجه حرارت، ساعات آفتابی، سرعت باد و رطوبت نسبی و ماتریس V شامل وزن‌های نرون‌های متصل به لایه نهان می‌باشند. تابع f در این تحقیق تابع سیگموئید، S_{Hid} خروجی نرون‌های لایه نهان، ماتریس W شامل وزن‌های متصل به لایه خروجی و مقدار $Output$ خروجی نرمال شده مدل می‌باشد. برای تعیین مقدار واقعی باید از تابع معکوس نرمال استفاده نمود. از نتایج این تحقیق در دسترس بودن ماتریس‌های وزن‌ها می‌باشد. نرم افزار طراحی شده قادر است وزن‌ها را پس از آموزش ارائه دهد. با استفاده از معادلات ماتریسی ارائه شده می‌توان محاسبات لازم را انجام داد و نیازی به مدل شبکه عصبی طراحی شده نیست بنابراین به کارگیری این مدل در سایر پروژه‌های امکان‌پذیر می‌باشد.

مراجع:

- [1] Irmak, S., Haman, D.Z. and Matyyac, S. (2002). Evaluation of Class A pan coefficients for Estimated Reference Evapotranspiration in Humid Location. *Irrig. Drain. Eng.*, 128(3): 153-159.
- [2] Snyder, R. L., Orang, M., Matyyac, S. and Grismer, M. E., (2005). Simplified Estimation of Reference Evapotranspiration from pan Evaporation Data in California. *J. Irrig.*, 131(3):758-773.
- [3] Doorenbos, J., and Pruitt, W.O. (1975). Guidelines for prediction of crop water requirements. Irrigation and Drainage Paper No. 24, FAO, Rome, Italy, 179 pp.
- [4] Doorenbos, J., and Pruitt, W.O. (1977). Guidelines for prediction of crop water requirements. Irrigation and Drainage Paper No. 24, FAO, (revised), Rome, Italy, 144 pp.
- [5] رحیمی خوب ا. (۱۳۸۵). تدوین مدل تبدیل تبخیر از تشت به تبخیر و تعرق گیاه مرجع مطالعه موردی استان خوزستان. همایش ملی مدیریت شبکه‌های آبیاری و زهکشی. دانشگاه شهید چمران اهواز ص ۷۴۵-۷۵۱.
- [6] Sudheer KP, Gosain A.K. and Ramasastri K.S. (2003). Estimating actual evapotranspiration from limited climatic data using neural computing technique. *J Irrig Drain Eng* 129(3):214-218.
- [7] Odhiambo LO, Yoder RE, Hines JW (2001) Optimization of fuzzy evapotranspiration model through neural training with input-output examples. *Trans ASAE* 44(6):1625-1633
- [8] Kumar M., Raghuwanshi N.S., Singh R., Wallender W.W. and Pruitt W.W. (2002) Estimating evapotranspiration using artificial neural network. *J Irrig Drain Eng* 128(4):224-233
- [9] Silva A.F. (2002). Previsao da evapotranspiracao de referencia utilizando redes neurais. Dissertacao de Mestrado, Univ. Federal de Vicosa, Vicosa, Minas Gerais, Brazil
- [10] Trajkovic S., Todorovic B. and Stankovic M. (2003) Forecasting of reference evapotranspiration by artificial neural networks. *J Irrig Drain Eng* 129(6):454-457
- [11] Zanetti S.S., Sousa E.F., Oliveira V.P.S., Almeida F.T. and Bernard S. (2007). Estimating evapotranspiration using artificial neural network and minimum climatological data. *J. Irrig Drain Eng* 133(2):83-88
- [12] Rahimi Khoob A. (2008). Comparative study of Hargreaves's and artificial neural. *Irrig Sci* 26:253-259