



# ارزیابی عملکرد شبکه های عصبی مصنوعی در کاهش پارامترهای مورد نیاز، جهت برآورد تبخیر و تعرق مرجع

مهدی کوچکزاده

استادیار گروه آبیاری و زهکشی، دانشگاه تربیت مدرس

عارف بهمنی

دانش آموخته کارشناسی ارشد آبیاری و زهکشی، دانشگاه تربیت مدرس

## چکیده:

تخمین درست تبخیر و تعرق مرجع ( $ET_0$ ) به عنوان یکی از عمده ترین اجزاء چرخه هیدرولوژیکی، در مطالعات، طراحی و مدیریت سیستم های آبیاری حائز اهمیت فراوان است. لکن تعدد پارامترهای مورد نیاز در محاسبه تبخیر و تعرق از یکسو و عدم اندازه گیری برخی پارامترها از سوی دیگر، تخمین درست آن را در برخی مناطق با مشکل مواجه کرده است. هدف از این تحقیق، ارزیابی عملکرد شبکه های عصبی مصنوعی (ANN) در کاهش پارامترهای مورد نیاز برای برآورد تبخیر و تعرق مرجع ( $ET_0$ ) و مقایسه آن با روشهایی چون فائو پنمن مانتیس، بلانی کریدل، جنسن هیز اصلاح شده و هارگریوز سامانی می باشد. برای این منظور از شبکه های پرسپترون چند لایه، قانون یادگیری پس انتشار خطا و داده های روزانه ایستگاه مهرآباد تهران، طی سالهای ۱۹۹۱ تا ۲۰۰۰ میلادی استفاده شد. روش فائو پنمن مانتیس به عنوان روش استاندارد انتخاب و به کمک پارامترهای  $(T_{max}, T_{min}, T_{dew}, R_n, RH_{max}, U_2, n)$  مدل ANN با ساختارهای متفاوت طراحی گردید. انتخاب مدل های ANN مطلوب با استفاده از معیارهای  $RMSE, R^2, MAE, MBE$  صورت گرفت. بر اساس نتایج به دست آمده مدل ANN1 با پارامترهای  $(T_{mean}, R_n, U_2, RH_{mean})$  و مدل ANN10 با تنها یک پارامتر ورودی  $(T_{mean})$  بیشترین و کمترین دقت را در برآورد  $ET_0$  به همراه داشتند. از طرفی دو پارامتر دما و سرعت باد به عنوان مؤثرترین فاکتورها در دقت برآورد مدل های ANN شناسایی شد. به طور کلی هرچند با کاهش پارامترهای ورودی از دقت مدل های ANN کاسته می شود ولی نتایج بدست آمده حاکی از عملکرد مطلوب شبکه های عصبی در کنار روشهای چون فائو پنمن مانتیس، بلانی کریدل، جنسن هیز اصلاح شده و هارگریوز سامانی است. از اینرو مدل های ANN می توانند در شرایط فقدان اطلاعات کافی، راهکار مناسبتری نسبت به روشهای تجربی به شمار روند.

**واژه های کلیدی:** تبخیر و تعرق، شبکه های عصبی مصنوعی، فائو پنمن مانتیس

## مقدمه

فرآیند تبخیر و تعرق (ET) از عمده ترین اجزاء چرخه هیدرولوژیکی است که تخمین درست آن در طراحی و مدیریت سیستم‌های آبیاری، مطالعات منابع آب و موارد مشابه دیگر از اهمیت زیادی برخوردار است. تخمین بیش از حد آب مورد نیاز گیاه ضمن هدر دادن آب آبیاری باعث ماندابی شدن اراضی، شستشوی مواد غذایی خاک و آلوده نمودن منابع آب زیرزمینی می‌شود. ضمن آنکه تخمین کمتر نیز باعث اعمال استرس رطوبتی به گیاه شده و در نتیجه کاهش محصول را به همراه خواهد داشت. سابقه مطالعات علمی در زمینه تبخیر و تعرق به بیش از ۲۵۰ سال می‌رسد و شاید واژه‌هایی چون نیاز آبی و آب مصرفی قدمتی ۱۰۰ ساله داشته باشند. در این مدت و در طی سالهای گذشته همواره محققین در صدد مدل کردن این پدیده برآمده‌اند، به گونه‌ای که در پنج دهه اخیر عمده مطالعات بر روی توسعه روشهای برآورد تبخیر و تعرق و بهبود بخشیدن به عملکرد روشهای موجود متمرکز شده است. اثر متقابل فاکتورهای کلیماتولوژی از قبیل دما، رطوبت نسبی، سرعت باد، تشعشع، نوع و مرحله رشد گیاه، و عوامل دیگر سبب شده است تا تبخیر و تعرق به صورت پدیده‌ای غیر خطی و پیچیده بیان شود. پیچیدگی فرآیند تبخیر و تعرق و کثرت اطلاعات مورد نیاز برای محاسبه آن از یک طرف و مشکلات موجود در سر راه اندازه‌گیری این پارامترها که غالباً موجب فقدان آنها می‌گردد از طرف دیگر، ضرورت استفاده از شبکه‌های عصبی مصنوعی را در برآورد تبخیر و تعرق مرجع آشکار می‌سازد. از این رو این مقاله می‌کوشد تا ضمن ارزیابی عملکرد شبکه‌های عصبی مصنوعی در برآورد تبخیر و تعرق مرجع  $ET_0$ ، رفتار مدل‌های ANN را در حذف انتخابی پارامترهای ورودی و اثر آن بر دقت برآورد  $ET_0$  مورد بررسی قرار دهد.

## شبکه‌های عصبی مصنوعی

شبکه عصبی مصنوعی<sup>۱</sup> که رسماً از دهه ۱۹۷۰ میلادی مطرح شده است، با الگو قرار دادن فعالیت‌های مغز انسان و بر اساس روابط منطقی مشابه، با دریافت یک سری اطلاعات نتایج منطقی را عرضه کرده و به کاربر ارائه می‌دهد. شبکه عصبی مصنوعی با تجزیه و تحلیل داده‌های ورودی و نتایج نظیر آنها ارتباطی منطقی بین داده‌ها برقرار می‌کند که ممکن است غیر خطی و نامشخص باشد، سپس با استفاده از این ارتباط منطقی کار شبیه سازی را برای موارد احتمالی مشابه انجام می‌دهد. این شبکه‌ها بر مبنای مقایسه بین خروجی شبکه و هدف، تعدیل می‌شوند و تا زمانی که خروجی شبکه با خروجی هدف تطبیق پیدا کند این کار ادامه می‌یابد. شبکه‌های آموزش یافته را می‌توان به صورت رویه‌ای از جعبه سیاه برای برآوردهای غیر خطی با عنوان نگاشتهای غیر خطی قابل تنظیم معرفی کرد، چرا که فضای بردار ورودی را به وسیله مجموعه‌ای از توابع غیر خطی به فضای خروجی مرتبط می‌سازند. کاربردی‌ترین نوع شبکه‌های عصبی، شبکه‌های پرسپترون چند لایه (MLP) و شبکه‌های توابع شعاعی (RBF) می‌باشند (Jam et al., 2000).

## مواد و روشها

شبکه‌های عصبی مصنوعی جهت طراحی و آموزش، نیازمند یک سری داده‌های ورودی و خروجی می‌باشند تا با تجزیه و تحلیل منطقی این داده‌ها به عنوان نمونه، بتوانند روابط غیر خطی یا نامشخص بین آنها را استخراج کرده و کار شبیه سازی را برای موارد احتمالی مشابه انجام دهند. بر اساس بررسی‌های انجام شده، روش فائو پنمن مانتیس در شرایط آب و هوایی خشک و مرطوب و نبود لایسیمتر،  $ET_0$  را با بیشترین دقت برآورد خواهد کرد. از اینرو و با توجه به عدم دسترسی به داده لایسیمتری کافی، از روش مذکور به عنوان روش استاندارد جهت تکمیل الگوهای آموزش استفاده شد. داده‌های مورد استفاده در این مطالعه آمار هواشناسی روزانه ایستگاه مهرآباد تهران مربوط به سالهای

1. Artificial Neural Network (ANN)

۱۹۹۱ تا ۲۰۰۰ میلادی می باشد. در این مرحله مقدار  $ET_0$  با روش فائو پنمن مانیتیس برای تعداد ۳۶۵۲ روز آماری محاسبه و به همراه پارامترهای هواشناسی کل دوره، الگوهای مورد نیاز جهت طراحی مدلها استخراج گردید. شبکه های مورد استفاده از نوع شبکه های پرسپترون چند لایه (MLP) با الگوریتم آموزشی پس انتشار خطا<sup>۱</sup> (BP) و قانون یادگیری دلتا رول بودند که به صورت پیشرو عمل می کنند. در این قانون مقدار تصحیح اعمال شده به وزنه های ورودی یک نرون در هر تکرار، تابعی از ورودی خالص نرون، میزان خطای شبکه و نرخ یادگیری شبکه می باشد. تابع فعالیت به کار گرفته شده جهت تنظیم پارامترهای شبکه از نوع سیگموئید (S شکل) می باشد.

$$f(x) = \frac{1}{1 + e^{-kx}} \quad (1)$$

اصولاً وارد کردن داده ها به صورت خام باعث کاهش سرعت و دقت شبکه می شود. از اینرو برای جلوگیری از اشباع زود هنگام نرونها و یکسان سازی ارزش دادها برای شبکه، بایستی ورودی خالص آنها در محدوده تابع سیگموئید قرار گیرد. این کار مانع از کوچک شدن بیش از حد وزنها شده (Sajikumar et al., 1999) و از اشباع زود هنگام نرونها جلوگیری می کند. محدوده خروجی تابع سیگموئید در بازه (۰ و ۱) می باشد. طبق بررسی های انجام شده بهتر است سعی شود تا نرمال کردن داده ها به گونه ای صورت گیرد تا میانگین داده ها نزدیک ۰/۵ باشد. (Kumar et al., 2002).

$$X_{normal} = 0.5 * \left( \frac{X_o - \bar{X}}{X_{max} - X_{min}} \right) + 0.5 \quad (2)$$

طراحی شبکه های عصبی با تعداد ۱۶۰۰ الگو از الگوهای موجود صورت گرفت. در تقسیم بندی الگوها به سه دسته آموزش، صحت سنجی و تست به ترتیب درصدهای ۵۰، ۳۰ و ۲۰ درصد در نظر گرفته شد. بنابراین تعداد الگوهای آموزش شامل ۸۰۰ الگو، صحت سنجی ۴۸۰ الگو و تست شامل ۳۲۰ الگو می باشد. در انتخاب داده های آموزش از سالهای غیر متوالی با شرایط اقلیمی متفاوت استفاده و سعی شد تا الگوهای ماکزیمم و مینیمم دوره آماری را نیز دربر گیرد. انتخاب دو دسته دیگر به صورت کاملاً تصادفی (Random) صورت گرفت.

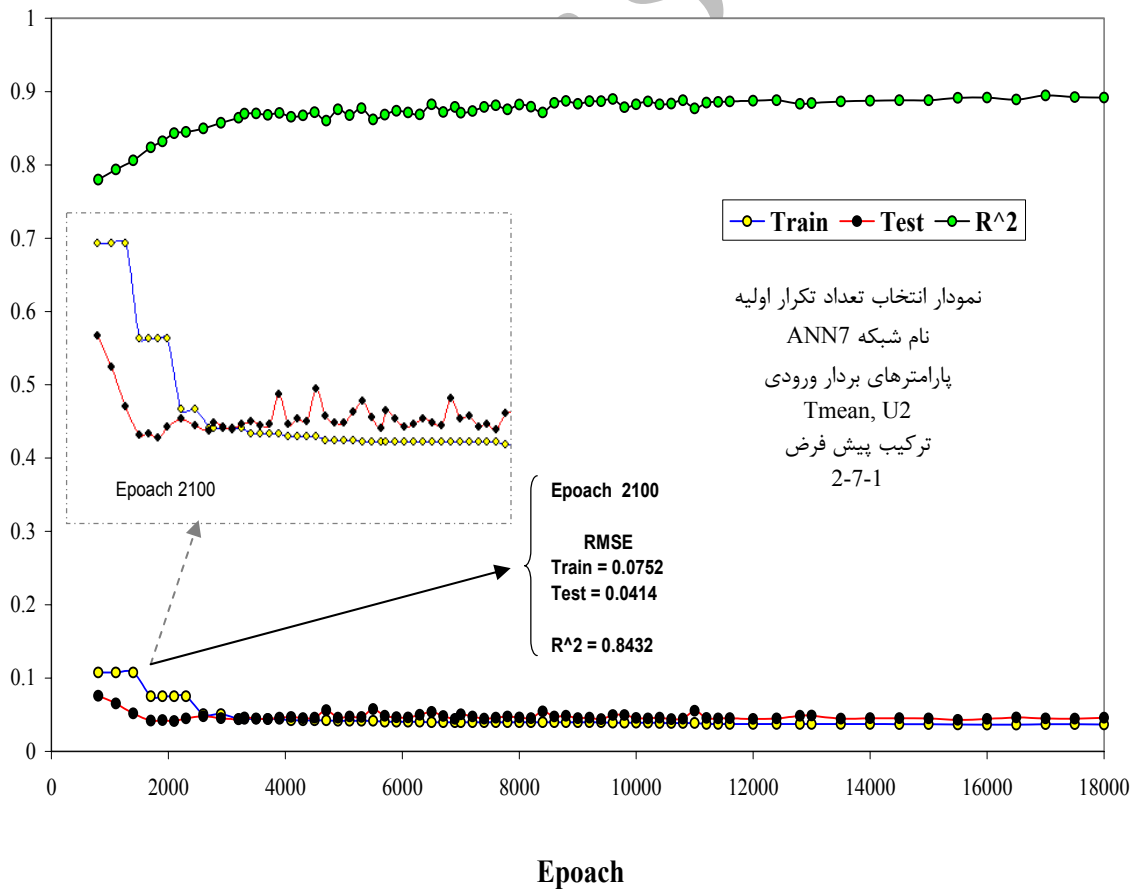
مهمترین عامل در انتخاب عناصر بردار ورودی، فیزیک حاکم بر پدیده ای است که توسط مدل (ANN) بررسی می شود. پارامترهای مؤثر بر تبخیر و تعرق دامنه وسیعی را دربر می گیرند و هر چه تعداد پارامترهای لحاظ شده بیشتر باشد دقت برآورد بالا می رود. نکته حائز اهمیت عدم دسترسی به تمامی پارامترها در نقاط مختلف است. از این رو با توجه به پارامترهای شاخص اثرگذار تعداد، ۱۰ ترکیب بردار ورودی به شرح جدول (۱-۱) در نظر گرفته شد.

### طراحی مدل:

در این تحقیق انتخاب تعداد مناسب نرونها در لایه میانی و تعداد تکرار مطلوب بر اساس مقایسه شاخصهای  $RMSE$ ,  $R^2$  در ترکیبهای مختلف صورت گرفت. برای هر شبکه ( $ANN_i$ )، ابتدا در یک ترکیب پیش فرض و با تکرارهای متفاوت مقادیر  $RMSE$ ,  $R^2$  مورد بررسی قرار گرفت. تعداد تکراری که به ازای آن مقدار  $RMSE$  داده های صحت سنجی کمترین و ضریب همبستگی  $R^2$  بالا بود به عنوان تعداد تکرار اولیه انتخاب شد. در نمودار (۱-۱) روند انتخاب تعداد تکرار اولیه در یکی از شبکه های مورد نظر آمده است.

جدول (۱-۱): شبکه‌های در نظر گرفته شده بر اساس پارامترهای مؤثر بر تبخیر و تعرق

پارامترهای بردار ورودی	نام شبکه
Tmax, Tmin, n, U2, RHmean, Tdew,	ANN 1
Tmax, Tmin, n, U2, RH mean	ANN 2
Tmean, Rn, U2, RH mean	ANN 3
Tmean, U2, RH mean	ANN 4
Tmax, Tmin, U2	ANN 5
RH mean, U2, n	ANN 6
Tmean, U2	ANN 7
Tmean, RH mean	ANN 8
U2, RH mean	ANN 9
Tmean	ANN 10




نمودار (۱-۱). چگونگی تغییرات شاخصهای  $R^2$ , RMSE با افزایش تعداد تکرار اولیه

پس از انتخاب تعداد تکرار اولیه ، ۱۳۶ ترکیب متفاوت با لایه میانی و تعداد نرون مختلف با همان تعداد تکرار اولیه تست شد. سپس به لحاظ شاخصهای  $R^2$ , RMSE, ترکیب بهینه با کمترین مقدار RMSE صحت سنجی و بالاترین  $R^2$  انتخاب گردید. این عمل برای تک تک مدل‌های (ANN) صورت گرفت.

↓

### بحث

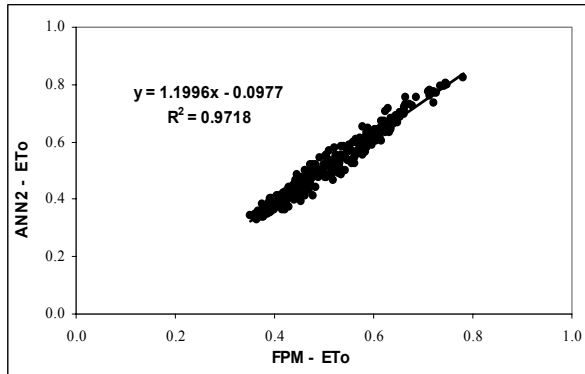
به منظور ارزیابی و مقایسه عملکرد شبکه‌ها با یکدیگر، از دسته سومی از داده‌ها تحت عنوان داده‌های تست که حاوی داده‌های ناشناخته برای شبکه بودند استفاده شد. مقادیر خروجی از هر شبکه با مقادیر متناظر آن توسط رابطه فائو پنمن مانیتیس مقایسه و جزئیات آن بر اساس معیارهای  $RMSE$ ,  $R^2$ ,  $b$ ,  $MBE$ ,  $MAE$ ,  $SEE$ ,  $SE$ ,  $MSE$  استخراج گردید. (جدول ۱ - ۲). بررسی‌های انجام شده نشان داد که مدل ANN1 با ترکیب شش پارامتر ورودی بیشترین تعداد ورودی را دارا بوده که البته نتایج به دست آمده از آن نیز به سبب لحاظ کردن فاکتورهای بیشتر از دقت خوبی برخوردار می‌باشد. بیشترین مقدار ضریب همبستگی و کمترین مقدار خطای مطلق در بین شبکه‌های طراحی شده و نیز مطلوب بودن سایر شاخصهای لحاظ شده در مدل ANN3 رخ داد که دلالت بر قدرت بالای این مدل در برآورد  $ET_0$  می‌باشد. دخالت دادن تشعشعات خالص خورشیدی و دمای ماکزیمم می‌تواند به عنوان دلیل این امر در نظر گرفته شود. کمترین دقت برآورد نیز در مدل‌های ANN8, ANN10 دیده شد که کم بودن پارامترهای لحاظ شده و ترکیب آنها می‌تواند عامل مؤثر باشد. نمودارهای (۱ - ۲) تا (۱ - ۱۲) مقایسه نتایج مدل‌های طراحی شده با مدل فائو پنمن مانیتیس را نشان می‌دهد.




نمودار (۱-۲): مقایسه نتایج شبکه ANN 3 و روش فائو پنمن مانیتیس

جدول (۱-۲) - نتایج مقایسه شبکه‌های عصبی طراحی شده بر مبنای پارامترهای ورودی و مقادیر حاصل از روش فائو پنمن ماتنیس


SE	MAE	MBE	SEE	b	R <sup>2</sup>	RMSE		ترکیب بهینه			پارامترهای بردار ورودی	نام شبکه	
						تست	آموزش	ح <sub>۱</sub>	ح <sub>۲</sub>	ح <sub>۳</sub>			ح <sub>۴</sub>
۰/۱۱۸۳	۰/۰۱۹۲	۰/۰۰۶۵	۰/۰۲۳۲	۱/۳۲۷۹	۰/۹۷۵۵	۰/۰۲۳۲	۰/۰۲۱۶	۶	۱۹	۰	۱	T <sub>max</sub> , T <sub>min</sub> , n, U <sub>2</sub> , RH <sub>mean</sub> , T <sub>dew</sub>	ANN <sub>1</sub>
۰/۱۲۵۷	۰/۰۲۴۳	۰/۰۰۲۴	۰/۰۲۹۶	۱/۱۹۹۶	۰/۹۷۱۸	۰/۰۲۴۴	۰/۰۲۲۹	۵	۸	۰	۱	T <sub>max</sub> , T <sub>min</sub> , n, U <sub>2</sub> , RH <sub>mean</sub>	ANN <sub>2</sub>
۰/۱۱۸۹	۰/۰۱۸۸	-۰/۰۰۰۴	۰/۰۲۲۹	۱/۱۲۹۷	۰/۹۷۶۹	۰/۰۲۲۹	۰/۰۱۹۱	۴	۹	۴	۱	T <sub>mean</sub> , R <sub>n</sub> , U <sub>2</sub> , RH <sub>mean</sub>	ANN <sub>3</sub>
۰/۱۲۹۱	۰/۰۳۴۷	۰/۰۲۲۹	۰/۰۴۴۴	۱/۱۷۸۴	۰/۹۳۱۸	۰/۰۴۴۳	۰/۰۳۱۳	۳	۱۴	۴	۱	T <sub>mean</sub> , U <sub>2</sub> , RH <sub>mean</sub>	ANN <sub>4</sub>
۰/۱۱۹۷	۰/۰۲۴۹	-۰/۰۰۰۴	۰/۰۳۰۵	۱/۱۱۸۸	۰/۹۴۶۹	۰/۰۳۰۴	۰/۰۳۰۱	۳	۵	۶	۱	T <sub>max</sub> , T <sub>min</sub> , U <sub>2</sub>	ANN <sub>5</sub>
۰/۱۰۸۸	۰/۰۳۴۶	-۰/۰۰۰۷	۰/۰۴۵۵	۰/۹۵۱۷	۰/۸۳۰۷	۰/۰۴۵۴	۰/۰۵۰۶	۳	۵	۰	۱	RH <sub>mean</sub> , U <sub>2</sub> , n	ANN <sub>6</sub>
۰/۱۲۱۹	۰/۰۳۲۴	-۰/۰۰۱۴	۰/۰۴۰۲	۱/۱۱۲۴	۰/۹۱۳۴	۰/۰۴۰۱	۰/۰۲۴۱	۲	۱۰	۰	۱	T <sub>mean</sub> , U <sub>2</sub>	ANN <sub>7</sub>
۰/۱۰۸۸	۰/۰۴۷۶	۰/۰۰۱۷	۰/۰۵۹۸	۰/۸۸۱۶	۰/۷۱۱	۰/۰۵۹۷	۰/۰۵۹۴	۲	۸	۰	۱	T <sub>mean</sub> , RH <sub>mean</sub>	ANN <sub>8</sub>
۰/۱۰۱۸	۰/۰۳۹۴	-۰/۰۰۰۳	۰/۰۵۱۱	۰/۸۵۸۸	۰/۷۷۰۱	۰/۰۵۱۰	۰/۰۶۵۰	۲	۵	۰	۱	U <sub>2</sub> , RH <sub>mean</sub>	ANN <sub>9</sub>
۰/۱۰۵۵	۰/۰۴۶۷	-۰/۰۰۰۵	۰/۰۰۶	۰/۸۴۸۱	۰/۷۰۱۳	۰/۰۵۹۹	۰/۰۶۱۳	۱	۷	۰	۱	T <sub>mean</sub>	ANN <sub>10</sub>




نمودار (۱-۴) - مقایسه ANN 2 و فائو پنمن مانتیس




نمودار (۱-۳) - مقایسه ANN 1 و فائو پنمن مانتیس




نمودار (۱-۶) - مقایسه ANN 5 و فائو پنمن مانتیس




نمودار (۱-۵) - مقایسه ANN 4 و فائو پنمن مانتیس




نمودار (۱-۸) - مقایسه ANN 7 و فائو پنمن مانتیس




نمودار (۱-۷) - مقایسه ANN 6 و فائو پنمن مانتیس




(۱۰-۱) - مقایسه مدل ANN9 و روش فائو پنمن مانتیس



(۹-۱) - مقایسه مدل ANN8 و روش فائو پنمن مانتیس



(۱۲-۱) - مقایسه ANN 3 و روش فائو پنمن مانتیس




(۱۱-۱) - مقایسه ANN 10 و روش فائو پنمن مانتیس

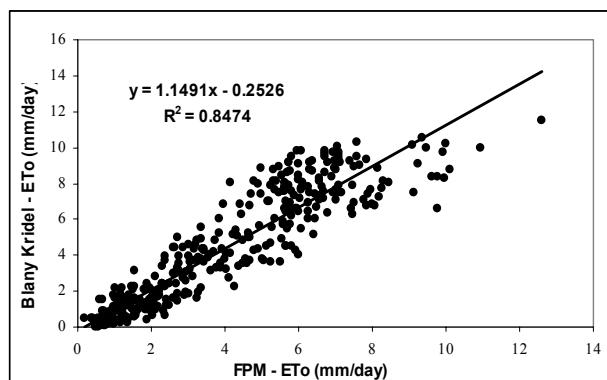
### نتیجه گیری:

بطور کلی نتایج به دست آمده حاکی از عملکرد مطلوب شبکه‌های عصبی مصنوعی در برآورد تبخیر و تعرق مرجع می‌باشد. گرچه با کاهش پارامترهای بردار ورودی از دقت برآورد مدلها کاسته می‌شود، اما با توجه به عدم دسترسی به آمار مورد نیاز، این شبکه‌ها می‌توانند راهکار مناسبتری نسبت به کاربرد روشهای تجربی در شرایط عدم وجود اطلاعات کافی باشند. از طرفی شبکه‌های عصبی مصنوعی توانستند مقادیر تبخیر و تعرق مرجع را بهتر از مدل‌های تجربی چون بلانی کریدل، جنسن هیز اصلاح شده و هارگریوز سامانی برآورد کنند. در نمودارهای (۱-۱۳) الی (۱-۱۵) نتایج مقایسه این روشها با روش فائو پنمن مانتیس آمده است که البته در کنار این نتایج نیز می‌توان به نتایج بهتر مدل‌های عصبی بیشتر پی برد.






جنسن هیز اصلاح شده و فائو پنمن ماننسیس (۱۴-۱)



روش بلانی کریدل و فائو پنمن ماننسیس (۱۳-۱)



نمودار (۱۵-۱) - مقایسه نتایج روش هرگریوز سامانی و روش فائو پنمن ماننسیس

## منابع و مأخذ

۱. البرزی، (۱۳۸۰). آشنایی با شبکه های عصبی مصنوعی. انتشارات دانشگاه صنعتی شریف.
۲. منهج، م (۱۳۷۹). مبانی شبکه های عصبی مصنوعی. انتشارات دانشگاه صنعتی امیر کبیر، ۷۱۵ ص.
۳. هاشمی نیا، س. م. (۱۳۷۸). تبخیر- تعرق و داده های اقلیمی. سازمان تحقیقات، آموزش و ترویج کشاورزی.
4. Allen, R. G., Pereira, L. S., Rase, D., Smith, M. (1998). Crop Evapotranspiration. FAO Irrigation and Drainage Paper 56.
5. Kumar, M. Raghuwanshi N.S.Singh, R. Wallender, W.W. and Pruitt, W.O. (2002). Estimating Evapotranspiration Using Artificial Neural Network. Journal of Irrigation and Drainage Engineering. 128(4): 224-233
6. Odhiambo, L. O., Yoder, R. E., Yoder, D.C. (2001). Estimation of reference Crop Evapotranspiration Using Fuzzy State Models. 44 (3). 543-550.
7. Salehi, F., Lacroix, R., and Wade, K. M. (1998). Effects of Learning Parameters and Data Presentation on the Performance of Back Propagation Networks for Milk Yield Prediction. Transaction of ASAE. 41 (1). 253-259.
8. Sudheer, K.P. Gosain, A. K. Ramasastri, K.S. (2003). Estimation Actual Evapotranspiration from Limited Cliatic Data Using Neural Computing Technique. Journal of Irrigation and Drainage Engineering. 129(3): 214-218.
9. Trajkovic, S. Todorovic, B and Stankovic, M. (2003). Forecasting of Reference Evapotranspiration by Artificial Neural Networks. Journal of Irrigation and Drainage Engineering. 129 (6): 454-457.

10. Yang, C. C., Lacroix, R., and Prasher, S. O. ( 1998 ). The Use of Back – Propagation Neural Networks for The Simulation and Analysis of Time–Series Data in Surface Drainage System. Transaction of ASAE. 41 (4). 1181 – 1187.

Archive of SID

# Assessment of artificial neural networks revenue in reducing required parameters for estimation of reference evapotranspiration

**M. Kouch Akzadeh**

*Assistant Prof. Irrigation Dept, Tarbiat Modarres University.*

**A. Bahmani**

*M. S Graduate, Irrigation Dept, Tarbiat Modarres University.*

## Abstract

Exact estimation of evapotranspiration as a basic parameter in hydrologic cycle and study, design and management of irrigation systems is of great importance. Excessive data needed in evapotranspiration equations on one hand and lack of access to some of the required data on the other hand has made problems in proper computation of this parameter in some areas. This study aims at evaluating artificial neural networks revenue in reducing required data for estimation of reference evapotranspiration as well as its comparison with experimental methods of FAO-Penman Montith, Blany-Kridel, refined method of Jensen-Haize and Hargrives-Samani. To achieve this objective perceptron multilayer networks with learning law of back propagation error and daily data of Tehran Mehrabad weather station during 1991–2000 were used. FAO-Penman Montith was selected as the standard method and 11 ANN model with different structures were designed with the parameters ( $T_{max}$ ,  $T_{min}$ ,  $T_{dew}$ ,  $R_n$ ,  $RH_{max}$ ,  $U_2$ ,  $n$ ). Favorite network was selected based on (RMSE,  $R^2$ , MAE, MBE) criteria. Results showed that ANN1 model with ( $T_{mean}$ ,  $R_n$ ,  $U_2$ ,  $RH_{mean}$ ) as input data and ANN10 model with only one input, ( $T_{mean}$ ) were the most and least precise models in evaluation of evapotranspiration respectively. Air temperature and wind velocity were considered to be the two most effective data in models precision. Although reducing the number of input data in ANN models will results in the reduction of their output precision but results showed that ANN models can be used as a useful tool for ET estimation in presence of the methods such as FAO-Penman Montith, Blany-Kridel, refined method of Jensen-Haize and Hargrives-Samani.

**Keywords:** evapotranspiration, artificial neural networks, FAO - Penman Montith.