

آنالیز حساسیت داده‌های ورودی به شبکه عصبی مصنوعی به منظور برآورد مقدار تبخیر روزانه

مینا سیاح فرد^۲

وحید نورانی^۱

(دریافت ۸۹/۱۰/۱ آخرین اصلاحات دریافتی ۹۰/۱۰/۲۵ پذیرش ۹۰/۱۲/۲۰)

چکیده

برآورد مقادیر تبخیر برای مدیریت کارآمد منابع آب در مناطق با اقلیم نیمه خشک امری ضروری است. این مقاله کاربرد شبکه‌های عصبی مصنوعی، رگرسیون خطی چند متغیره و سه روش تجربی تعادل انرژی، آیرودینامیکی و ترکیبی پنمن را به منظور برآورد مقادیر تبخیر روزانه تشتک برای دو شهر تبریز و ارومیه مورد ارزیابی قرار داد. علاوه بر این آنالیز حساسیت به دو روش مشتقات جزئی و وزن‌های اتصالی برای تبیین میزان اثر هر پارامتر ورودی از نظر مقدار و جهت روی نتایج مدل‌های شبکه عصبی و نیز تشخیص بهترین ترکیبات ورودی انجام شد. متغیرهای هیدرولوژیکی استفاده شده شامل مشاهدات روزانه کمیت‌های دمای هوا، تبخیر تشتک، تشعشع خورشیدی، فشار هوا، رطوبت نسبی و سرعت باد بودند. نتایج روش‌های کلاسیک و مدل‌های شبکه عصبی با مقادیر تبخیر روزانه مقایسه شد. مقایسه‌ها بهتر بودن پاسخ شبکه‌های عصبی در برآورد تبخیر روزانه نسبت به سایر مدل‌ها را نشان داد. نتایج آنالیز حساسیت نشان داد که درجه حرارت هوا، تشعشع خورشیدی و تبخیر روز گذشته بیشترین تأثیر را روی تبخیر روزانه نسبت به سایر عوامل در هر دو منطقه دارند و تأثیر متغیرهای دیگر کم است.

واژه‌های کلیدی: آنالیز حساسیت، شبکه‌های عصبی مصنوعی، تبخیر روزانه، تبریز، ارومیه

Sensitivity Analysis of ANN Inputs in Estimating Daily Evaporation

Vahid Nourani¹

Mina Sayyah Fard²

(Received Dec. 22, 2010 Revised Jan. 15, 2012 Accepted March 10, 2012)

Abstract

Estimation of evaporation values is needed for efficient management of water resources at semi-arid regions. This paper presents application of Artificial Neural Networks (ANNs), Multiple Linear Regression (MLR) and empirical models viz.: Energy balance, Aerodynamic, Penman for estimation of daily pan evaporation for Tabriz and Urmia cities. Furthermore, in order to determine the effect of each input parameter on the output variable in terms of magnitude and direction and also identify the best combinations of the model inputs, two sensitivity analysis methods i.e. the Partial Derivation method (PaD) and the Weights method have been applied on the ANN results. The used hydrological variables include daily observations of air temperature, pan evaporation, solar radiation, air pressure, relative humidity, and wind speed. The results of the classic methods and ANN models are compared to daily observations of evaporation values. The comparison showed that there is better agreement between the ANN estimations and measurements of daily evaporation than other models. Sensitivity analysis results showed that air temperature, solar radiation and previous day evaporation have maximum effects on daily evaporation in both regions and the contributions of the other variables are insignificant.

Keywords: Sensitivity Analysis, Artificial Neural Networks, Daily Evaporation, Tabriz, Urmia.

1. Assoc. Prof. of Water Eng., Dept. of Civil Eng., Tabriz University, Tabriz
(Corresponding Author) (+98 411) 3392409 vnourani@umn.edu
2. M.Sc. Student of Hydraulic Structures, Dept. of Civil Eng., Tabriz
University, Tabriz

۱- دانشیار گروه مهندسی عمران آب، دانشکده مهندسی عمران، دانشگاه تبریز (نویسنده
مسئول) ۳۳۹۲۴۰۹ (۰۴۱۱) vnourani@umn.edu

۲- دانشجوی کارشناسی ارشد سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه
تبریز

از نظر مقدار و جهت در کل فضای ورودی قابل تعیین نیست. از این رو آنها با روشی مبتنی بر آنالیز آماری مشتق خروجی شبکه نسبت به ورودی (حساسیت خروجی به ورودی)، آنالیز حساسیتی بر روی مسئله بهره‌وری در تولید لوله‌های انتقال انجام داده‌اند و بیان کرده‌اند که مطالعه بر روی روابط درون شبکه‌های عصبی باعث آسان‌تر شدن درک و تفسیر نتایج مدل‌سازی می‌شود [۴].

در ارتباط با تحقیقات صورت گرفته در مورد برآورد میزان تبخیر و تعرق توسط مدل‌های ANN می‌توان به موارد متنوعی اشاره کرد. در سال ۲۰۰۸ تکنولوژی ANN برای تخمین تبخیر و تعرق با متغیرهای ورودی محدود به‌کاربرده شده است [۹]. در تخمین تبخیر و تعرق نیاز به متغیرهای اقلیمی زیادی است حال آنکه تحقیق بالا در پی بررسی دقت یک مدل ANN در تخمین تبخیر و تعرق با فضای ورودی محدود بوده است. در اقلیم‌های خشک و نیمه‌خشک نقش تبخیر در توسعه منابع آبی پررنگ‌تر می‌شود. نتایج حاصل از به‌کار بردن رابطه‌های تجربی با توجه به پیچیده بودن فرایند تبخیر و داده‌های آماری زیاد مورد نیاز، چندان رضایت‌بخش نیست. مقدم‌نیا و همکاران در سال ۲۰۰۸ مدل‌های ANN و سیستم استنتاج فازی تطبیقی^۶ را برای تخمین تبخیر به‌کار برده‌اند که نتایج برتر بودن این دو تکنیک را در تخمین تبخیر نسبت به رابطه‌های تجربی نشان می‌دهد [۱۰].

در راستای مطالعه تأثیر ترکیبات مختلف پارامترهای اقلیمی بر تلفات تبخیر مخزن سد، دیسوال^۷ و پال^۸ در سال ۲۰۰۸ تکنیک مدل‌سازی ANN را به‌کاربرده‌اند [۱۱]. در مرکز تحقیقات کشاورزی خوزستان و نیز در منطقه‌ای در تایوان، ابزار ANN و معادله تجربی هارگریوز^۹ به‌منظور برآورد میزان تبخیر روزانه تشتک به‌کار گرفته شده‌اند [۱۲ و ۱۳]. یک مدل ANN برای تخمین میزان تبخیر آب موجود در خاک محیط گلخانه در چین به‌کار گرفته شده است که نتایج، دقت بالای این روش را نشان می‌دهد [۱۴]. طبری و همکاران در تحقیق خود برای تخمین میزان تبخیر از تشتک در ناحیه‌ای با اقلیم نیمه‌خشک در ایران، مدل‌های ANN و رگرسیونی را به‌کار برده‌اند که نتایج، برتر بودن مدل شبکه را به مدل رگرسیونی در تخمین نزدیک به واقعیت نشان می‌دهد [۱۵]. پارامترهای زیادی در برآورد میزان تبخیر دخالت می‌کنند که با توجه به متفاوت بودن شدت تأثیر آنها از اقلیمی به اقلیم دیگر و یا حساس‌تر بودن فرایند تبخیر به پاره‌ای از عوامل یاد شده در یک ناحیه، انجام آنالیز حساسیت روی مدل ANN می‌تواند مفید باشد.

عمده‌ترین معیار برای تعیین درجه خشکی در یک منطقه، رابطه بین مقدار بارندگی سالانه و توان تبخیر محیط است. هر اندازه مقدار باران نسبت به تبخیر کمتر باشد، درجه خشکی آن منطقه بیشتر است. به‌جز نواحی محدودی در ایران (حاشیه دریای خزر) در سایر مناطق، توان تبخیر به‌مراتب بالاتر از میزان بارندگی است. در ایران حدود ۷۲ درصد از نزولات جوی روی خشکی‌ها بلافاصله تبخیر می‌شود. در مقیاس جهانی این رقم ۵۷ درصد بوده و این خود اهمیت تبخیر و تعرق، خصوصاً در مناطق با اقلیم خشک و نیمه‌خشک ایران را مشخص می‌کند [۱]. در طبقه‌بندی اقلیمی ایران، شهرهای تبریز و ارومیه جزء مناطق نیمه‌خشک محسوب می‌شوند. به همین دلیل پیش‌بینی و تعیین مهم‌ترین عوامل مؤثر در میزان شدت تبخیر در این مناطق پر اهمیت است. پیچیدگی سیستم‌های هیدرولوژیکی از نظر تعیین تمامی پارامترهای دخیل و نقص اطلاعات آماری، امکان مدل‌سازی فیزیکی کامل سیستم‌های هیدرولوژیکی را غیرممکن می‌سازد. در چنین شرایطی استفاده از مدل‌سازی سیستمی که مبتنی بر روابط ریاضی باشد، مورد توجه قرار می‌گیرد.

از جمله تکنیک‌های مدل‌سازی به‌صورت سیستمی یا جعبه سیاه^۱، استفاده از شبکه‌های عصبی مصنوعی^۲ است. ANNs ابزارهایی قوی در یادگیری رابطه ناشناخته و پیچیده بین یک فضای ورودی به فضای خروجی هستند که در زمینه‌های مختلف علمی به‌کار برده می‌شوند [۲ و ۳]. اما برخلاف مدل‌های ریاضی به‌خودی خود اثر پارامترهای ورودی به خروجی و چگونگی به‌دست آمدن خروجی را توضیح نمی‌دهند، به‌همین دلیل از آنجایی که ارزش روشهای هوش مصنوعی با تفسیر نتایج خروجی آنها (اثر ورودی‌ها بر خروجی) بیشتر می‌شود، مطالعات متعددی بر روی توضیح رابطه حاکم بر محیط یک شبکه عصبی و همچنین چگونگی اثر پارامترهای ورودی بر خروجی انجام شده است که از آن جمله می‌توان به مطالعه لو و همکاران^۳ در سال ۲۰۰۱ اشاره کرد [۴]. نمونه‌ای از این روشها عبارت‌اند از استخراج روابط حاکم بر نرون‌های میانی و خروجی، استفاده از آنالیز آماری مؤلفه اصلی^۴ روی مدل شبکه پس‌انتشار خطا^۵، استفاده از وزن‌های لایه میانی متصل به هر ورودی و همچنین استفاده از ترکیب منطق فازی با شبکه‌های عصبی [۵-۸]. لو و همکاران با بررسی این روشها به این نتیجه رسیده‌اند که اثر هر پارامتر ورودی بر روی متغیرهای خروجی

¹ Black-Box

² Artificial Neural Networks (ANNs)

³ Lu et al.

⁴ Principal Component Analysis (PCA)

⁵ Back Propagation Neural Networks (BPNN)

⁶ Adaptive Neuro-Fuzzy Inference System (ANFIS)

⁷ Deswal

⁸ Pal

⁹ Hargreaves (HG)

شهر تبریز بیشتر از ارومیه و میانگین رطوبت نسبی، تشعشع خورشیدی و فشار (تا حدودی) در شهر ارومیه بیشتر از شهر تبریز است. مقادیر انحراف از معیار کمیتهای تبخیر، دما، رطوبت و باد در شهر تبریز بیشتر از شهر ارومیه و انحراف از معیار کمیتهای تشعشع خورشیدی و فشار در شهر ارومیه بیشتر از تبریز است.

۳- روشهای برآورد تبخیر

چاو و همکاران^۸ سه روش تجربی برای تخمین تبخیر از سطح آزاد آبها را ارائه کرده‌اند که عبارت‌اند از: روشهای آیرودینامیکی^۹، تعادل انرژی^{۱۰} و ترکیبی پنمن^{۱۱}. این روشهای تجربی به منظور برآورد مقادیر تبخیر روزانه در مطالعه حاضر به کار گرفته شد که توضیح جامع در مورد هر سه روش در مطالعات قبلی آورده شده است [۲۰]. از جمله مدل‌های جعبه سیاه، مدل رگرسیون خطی چندمتغیره^{۱۲} و مدل‌های ANN را می‌توان نام برد که در این مطالعه مورد استفاده قرار گرفت [۲۱ و ۲۲]. رابطه رگرسیون چندمتغیره به صورت کلی زیر است [۲۳]

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_K X_K + A \quad (1)$$

که در این رابطه

Y متغیر وابسته، X_1 تا X_K متغیرهای مستقل، پارامترهای β_0 تا β_K ضرایب و A خطای رگرسیون است. این مدل موقعیت یک ابر صفحه^{۱۳} در فضای K بعدی متغیرهای مستقل را توصیف می‌کند. پراکنش مشاهدات در یک فضای K بعدی بوده و موقعیت بهترین ابر صفحه رگرسیون که می‌توان بین آنها برازش داد، تعیین می‌شود. در رابطه رگرسیون برای یافتن بهترین برازش مدل بر داده‌های مشاهداتی، پارامترهای رابطه به روش کمترین مربعات خطا^{۱۴} محاسبه می‌شوند.

در علوم مختلف، مطالعاتی در زمینه آنالیز حساسیت ANNs برای مشخص کردن میزان اثرپذیری خروجی شبکه از ورودی‌های مختلف آن به روشهای گوناگون انجام شده است، مانند تحقیقات انجام شده توسط بنی‌مهد^۱ و یثروبی^۲، جین و همکاران^۳، جوری و همکاران^۴ و لیونق و همکاران^۵ [۱۶-۱۹]. از بررسی ادبیات گذشته و تحقیقات صورت گرفته در زمینه آنالیز حساسیت و ANNs نتیجه گرفته می‌شود که تحقیقی در خصوص تحلیل حساسیت خصوصاً به روش مشتقات جزئی در زمینه کارهای هیدرولوژیکی و فرایند تبخیر صورت نگرفته است. در مقاله حاضر به بررسی قدرت ANNs در برآورد میزان تبخیر روزانه تشتک در مناطق مطالعاتی و تحلیل حساسیت فرایند مورد نظر نسبت به عوامل مؤثر در آن پرداخته شد.

۲- مناطق مطالعاتی و داده‌ها

در این تحقیق تبخیر شهرهای تبریز و ارومیه واقع در شمال غربی ایران مدل شده که برای این منظور از داده‌های هیدرولوژیکی و روزانه ایستگاههای سینوپتیک تبریز در محدوده سالهای ۱۳۷۳-۱۳۸۷ و ارومیه در سالهای ۱۳۷۴-۱۳۸۱ که به ترتیب شامل ۵۴۷۹ و ۲۹۲۲ رکورد ثبت شده برای هر پارامتر بودند، استفاده شد. متغیرها عبارت بودند از: تشعشع خورشید^۶، دمای هوا (T)، رطوبت نسبی^۷، سرعت باد U_2 ، فشار ستون هوا (P) و تبخیر تشتک E_t که به منظور مدل‌سازی با ANNs به دو قسمت آموزشی (۷۵ درصد داده‌ها) و آزمایشی (۲۵ درصد داده‌ها) تقسیم‌بندی شدند. جدول ۱ برخی از مشخصات آماری داده‌ها را برای دو دسته آموزشی و آزمایشی که در مدل شبکه استفاده شد را نشان می‌دهد. برای دوره‌های آماری در نظر گرفته شده میانگین تبخیر، دما و باد در

⁸ Chow et al.
⁹ Aerodynamic
¹⁰ Energy Balance
¹¹ Penman
¹² Multiple Linear Regression (MLR)
¹³ Hyperplane
¹⁴ Least Squares Error

¹ Banimahd
² Yasrobi
³ Jain et al.
⁴ Gevrey et al.
⁵ Liong et al.
⁶ Solar Radiation (R_a)
⁷ Relative Humidity (R_H)

جدول ۱- مشخصات آماری گروههای آموزشی و آزمایشی

| متغیرها | ایستگاه ارومیه | | | | | | ایستگاه تبریز | | | | | |
|-------------------|----------------|-------|--------|--------------|-------|--------|---------------|-------|--------|--------------|-------|--------|
| | گروه آموزشی | | | گروه آزمایشی | | | گروه آموزشی | | | گروه آزمایشی | | |
| | Std | کمینه | بیشینه | Std | کمینه | بیشینه | Std | کمینه | بیشینه | Std | کمینه | بیشینه |
| E_t (mm/d) | ۳/۵۶۱ | ۰/۰۱۶ | ۱۳/۲ | ۴/۳۳۵ | ۲/۲۳۴ | ۰/۰۱۱ | ۴/۱۹۳ | ۱۳/۶ | ۰/۰۱۱ | ۴/۳۳۵ | ۲/۲۳۴ | ۰/۰۱۶ |
| T (°C) | ۹/۱۲۴ | ۸/۸۷۵ | ۲۶/۹۷ | ۱۰/۸۸ | ۹/۵۲۹ | ۲۸/۷۵ | ۱۱/۹۵ | ۲۸/۷۵ | ۱۲/۹۵ | ۹/۵۲۹ | ۱۰/۸۸ | ۲۶/۹۷ |
| R_H (درصد) | ۱۵/۶۲ | ۲۸/۷۵ | ۹۸/۱۲ | ۵۹/۳۱ | ۱۵/۴۵ | ۱۵/۶۲ | ۵۷/۵۲ | ۱۰۰ | ۱۵/۶۲ | ۱۵/۴۵ | ۵۹/۳۱ | ۹۸/۱۲ |
| U_2 (m/s) | ۱/۲۱۲ | ۰/۱ | ۷/۳۷۵ | ۱/۶۱۴ | ۱/۱۰۰ | ۰/۱ | ۲/۱۷۶ | ۸/۲۵ | ۰/۱ | ۱/۱۰۰ | ۱/۶۱۴ | ۷/۳۷۵ |
| R_a (w/m^2) | ۲۳۱/۹ | ۳۸ | ۹۴۳/۱ | ۴۰۱/۰ | ۱۸۴/۶ | ۹۵۰/۲ | ۴۴۳/۹ | ۹۵۰/۲ | ۱۱/۰۷ | ۱۸۴/۶ | ۴۰۱/۰ | ۹۴۳/۱ |
| P (Hpa) | ۴/۴۵۱ | ۸۵۴/۹ | ۸۸۱/۴ | ۸۶۸/۰ | ۴/۴۸۳ | ۸۵۱/۳ | ۸۶۷/۳ | ۸۸۱/۱ | ۸۵۱/۳ | ۴/۴۸۳ | ۸۶۸/۰ | ۸۸۱/۴ |

۱-۳- مدل شبکه عصبی مصنوعی

از جمله شبکه‌های عصبی که به‌طور وسیعی در علوم مختلف از جمله مهندسی آب مورد استفاده قرار گرفته است، BPNN است که در این مطالعه همراه با الگوریتم آموزشی لونبرگ مارگارت^۱ به‌کار گرفته شد. از نظر ساختار ریاضی، BPNN یک الگوریتم بهینه‌سازی شیب نزولی است که با هدف کمینه کردن خطای کل بین مقادیر خروجی از ANN و مقادیر مشاهداتی ساخته شده است [۴]. با توجه به محدوده توابع محرک، انتقال متغیرهای خروجی و ورودی به بازه مناسب با یک توزیع لازم به‌نظر می‌رسد. مهم‌ترین هدف از این انتقال، تصحیح پخش متغیرهای ورودی و خروجی به‌نحوی است که خطای مدل‌سازی کم شود. با توجه به شکل و رفتار توابع محرک، زمانی که ورودی‌ها در محدوده (۰، ۱) یا (-۱، ۱) قرار می‌گیرند، میزان تغییرات در خروجی این توابع به‌ازای تغییرات ورودی بهتر نمایان شده و سرعت آموزش و همگرایی بیشتر می‌گردد، لذا در این مطالعه قبل از وارد کردن داده‌ها به شبکه، مقیاس‌دهی روی داده‌ها اعمال شد تا تمامی داده‌ها به‌صورت انتخابی بین (۰، ۱) قرار بگیرند. به‌منظور یافتن بهترین نگاشت ورودی-خروجی، در شبکه‌های آزمایشی تعداد حداکثر دو لایه میانی با توابع انتقال تانژانت سیگموئید^۲ و لگاریتم سیگموئید^۳ و برای لایه خروجی از تابع انتقال خطی^۴ استفاده شد. برای یافتن تعداد نرون مناسب در لایه‌های میانی شبکه، آرایش نرون‌های لایه میانی برای تک لایه

میانی از ۱ تا ۱۰ و برای دو لایه میانی به‌صورت تصادفی بازه اعداد بین ۵ تا ۱۲ امتحان شد تا بهترین حالت بر اساس آزمون و خطا به‌دست آید. برای ارزیابی روشهای یاد شده شاخصهای آماری ضریب تبیین^۵ (R^2) و جذر متوسط مربعات خطا^۶ به‌کار برده شد [۲۴].

۴- آنالیز حساسیت مدل

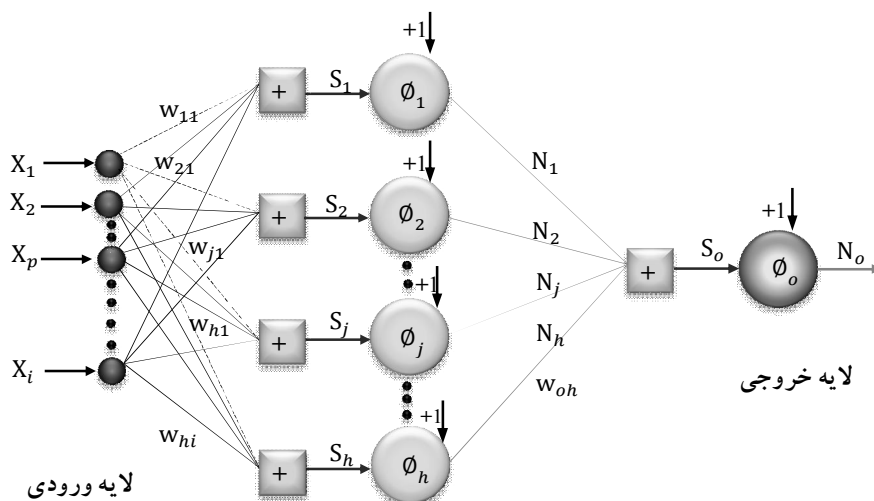
روشهای مختلفی تحت نام آنالیز حساسیت برای استخراج قوانین حاکم بر مدل هدف به‌کار برده می‌شوند. مطالعه حاضر به بررسی آنالیز حساسیت مدل‌های ANN به دو روش وزن‌های اتصال^۷ و مشتقات جزئی^۸ خروجی نسبت به ورودی پرداخت. آنالیز حساسیت به روش وزن‌های اتصالی برای اولین بار توسط گارسون^۹ به‌کار برده شده است و توسط گوح^{۱۰} تکرار شده است [۲۵-۲۷].

۴-۱- روش مشتقات جزئی

روش PaD به‌صورت مشتق جزئی خروجی نسبت به ورودی‌ها تعریف می‌شود. برای یک شبکه پرسپترون سه لایه فرضی که در شکل ۱ نشان داده شده است، می‌توان روابط آنالیز حساسیت را به‌دست آورد.

⁵ Determination Coefficient
⁶ Root Mean Squared Error (RMSE)
⁷ Weight Method
⁸ Partial Derivation Method (PaD)
⁹ Garson
¹⁰ Goh

¹ Levenberg-Marquardt
² Tansig
³ Logsig
⁴ Purelin



لایه میانی

شکل ۱- یک شبکه پرسپترون چند لایه فرضی

$$\frac{\partial N_o}{\partial X_p} = \phi'_o(S_o)W_{oh}\phi'_h(S_h)W_{hp} \quad (12)$$

رابطه نهایی حساسیت خروجی نسبت به متغیر ورودی X_p با توجه به اینکه در لایه میانی بیش از یک نرون وجود دارد به صورت زیر نوشته می شود

$$\frac{\partial N_o}{\partial X_p} = \sum_{h=1}^{nh} \phi'_o(S_o)W_{oh}\phi'_h(S_h)W_{hp} \quad (13)$$

که در این رابطه

تعداد نرون در لایه میانی با nh نشان داده می شود. در مطالعه حاضر و در مرحله آموزش مدل‌ها، توابع انتقال Tansig و Purelin به ترتیب برای لایه‌های میانی و خروجی شبکه‌ها منجر به نتایج مناسبی شدند که مشتق مرتبه اول تابع Tansig با رابطه ۱۴ و تابع Purelin با رابطه ۱۵ به دست می آیند

$$\phi'_h(S_h) = (1 - \phi_h^2(S_h)) = 1 - N_h^2 \quad (14)$$

$$\phi'_h(S_o) = 1 \quad (15)$$

با جایگذاری روابط ۱۴ و ۱۵ در رابطه ۱۳ رابطه نهایی حساسیت برای شبکه پرسپترون سه لایه فرضی به صورت رابطه ۱۶ به دست می آید

$$\frac{\partial N_o}{\partial X_p} = \sum_{h=1}^{nh} W_{oh} (1 - N_h^2) W_{hp} \quad (16)$$

در نهایت اهمیت نسبی هر متغیر ورودی نسبت به خروجی شبکه در روش PaD با شاخص مجموع مربع مشتقات^۱ به صورت زیر محاسبه می شود [۲۷]

$$SSD_p = \sum_{m=1}^{NO} \left(\frac{\partial N_o}{\partial X_p} \right)^2 \quad (17)$$

که در این رابطه

m شمارنده داده‌های مشاهداتی روی دامنه متغیر ورودی p با NO رکورد ثبت شده است. این حساسیت‌ها $\left(\frac{\partial N_o}{\partial X_p} \right)$ برای نمونه گرفته شده از بانک اطلاعاتی مدل (کلیه رکوردهای ثبت شده) و در فضای n بعدی متغیرهای ورودی محاسبه می شوند. یک حساسیت مثبت نشان دهنده رابطه مستقیم و یک مقدار منفی نشان دهنده رابطه معکوس متغیر مورد نظر با خروجی است. برای این روابط

¹ Sum of Square Derivatives (SSD)

در این شبکه، برای یک نرون در لایه ورودی که پردازشی روی آن صورت نمی‌گیرد، به صورت زیر است

$$N_i = X_i \quad (2)$$

که در این رابطه

i زیرنویس نرون در لایه ورودی، X متغیر ورودی به شبکه و N سیگنال خروجی از نرون است. نرونی که در لایه میانی باشد سیگنال ورودی را به فرم زیر پردازش می‌کند

$$S_h = N_p W_{hp} + \sum_{i \neq p} N_i X_{hi} \quad (3)$$

$$N_h = \phi_h(S_h) \quad (4)$$

که در این روابط

S سیگنال ورودی به نرون، زیرنویس p یک ورودی مستقل را نشان می‌دهد که حساسیت آن به دست می‌آید، W_{hi} وزن اتصال بین نرون i و نرون h در لایه میانی (لایه بعدی)، زیرنویس h برای یک نرون در لایه میانی ϕ و نشان دهنده تابع انتقال است. سیگنال خروجی از نرون h در لایه میانی نیز به صورت زیر به نرون لایه خروجی تغذیه می‌شود

$$S_o = N_h W_{oh} + \sum_{j \neq h} N_j X_{oj} \quad (5)$$

$$N_o = \phi_o(S_o) \quad (6)$$

که در این روابط

o نشان دهنده یک نرون در لایه میانی و زیرنویس o مبین نرون در لایه خروجی است. در نتیجه تعیین مشتق مرتبه اول خروجی نسبت به متغیر ورودی X_p به صورت زیر انجام می‌شود

$$\frac{\partial S_h}{\partial N_p} = W_{hp} \quad (7)$$

$$\frac{\partial S_o}{\partial N_h} = W_{oh} \quad (8)$$

$$\frac{\partial N_o}{\partial N_p} = \frac{\partial N_o}{\partial N_p} = \frac{\partial N_o}{\partial N_h} \frac{\partial N_h}{\partial N_p} = \left(\frac{dN_o}{dS_o} \frac{\partial S_o}{\partial N_h} \right) \left(\frac{dN_h}{dS_h} \frac{\partial S_h}{\partial N_p} \right) \quad (9)$$

از طرفی از روابط ۴ و ۶ روابط ۱۰ و ۱۱ حاصل شده و همچنین رابطه ۹ به فرم ۱۲ بازنویسی می‌شود

$$\frac{dN_o}{dS_o} = \phi'_o(S_o) \quad (10)$$

$$\frac{dN_h}{dS_h} = \phi'_h(S_h) \quad (11)$$

اگر داده‌ها به صورت خام وارد شبکه شوند نتیجه حاصل بیانگر حساسیت مطلق است که باید اصلاح شود. اما اگر داده‌های ورودی به شبکه نرمالیزه شوند روابط به دست آمده بیانگر حساسیت نسبی خواهند بود [۴]. شاخص SSD اهمیت نسبی شرکت هر متغیر ورودی در محاسبه متغیر خروجی شبکه را به دست می‌آورد ولی جهت تأثیر را مشخص نمی‌کند. هر اندازه مقدار این شاخص بیشتر باشد، نشان دهنده تأثیر بیشتر متغیر مورد نظر روی خروجی از مدل است. برای مشخص کردن میزان پراکندگی و به منظور تأثیر مقادیر مختلف حساسیت نسبی متغیر خروجی نسبت به یک متغیر ورودی در کل فضای ورودی از روش آنالیز آماری مقادیر حساسیت‌های به دست آمده استفاده می‌شود [۴]. در این روش ۵ درصد آماری (D ۱۰ درصد، D ۲۵ درصد، D ۵۰ درصد، D ۷۵ درصد و D ۹۰ درصد) مقادیر حساسیت نسبی خروجی نسبت به ورودی مربوطه محاسبه می‌شوند که توضیح این شاخصها به این صورت است که D ۱۰ درصد نشان دهنده مقداری برای حساسیت نسبی است که ۹۰ درصد مقادیر از آن بیشتر و ۱۰ درصد از آن کمتر هستند. بنابراین اگر مثبت شود نشان می‌دهد که احتمال اینکه مقدار حساسیت نسبی مثبت باشد بالای ۹۰ درصد است یا به عبارتی احتمال اینکه خروجی با افزایش ورودی مورد نظر افزایش یابد بالای ۹۰ درصد است. D ۹۰ درصد نشان دهنده مقداری برای حساسیت نسبی است که ۹۰ درصد مقادیر از آن کمتر است، بنابراین اگر منفی باشد نشان می‌دهد که به احتمال بالای ۹۰ درصد، خروجی با افزایش ورودی مورد نظر کاهش می‌یابد. توضیح D ۲۵ درصد، D ۵۰ درصد و D ۷۵ درصد مانند D ۱۰ درصد و D ۹۰ درصد است. ورودی که مقادیر درصد‌های حساسیت نسبی آن در اطراف خط پایه متمرکز شده باشد، دارای اثر کمتر بر روی خروجی نسبت به ورودی است که دسته درصد‌های حساسیت نسبی آن دارای پراکنش وسیع‌تری در اطراف خط پایه است.

۵- نتایج و بحث

۵-۱- نتایج مدل‌سازی تبخیر

برای هر دو منطقه مطالعاتی نتایج به‌کارگیری سه روش کلاسیک (تبادل انرژی، آبرودینامیکی و پنمن) با توجه به شاخص R^2 به دست آمده، نشان دهنده برتر بودن روش ترکیبی پنمن نسبت به دو روش دیگر است. بعد از روش پنمن در هر دو منطقه روش آبرودینامیکی بهتر از تبادل انرژی رفتار کرد. به منظور مقایسه کلیه مدل‌ها نتایج این قسمت برای دو گروه آموزشی و آزمایشی جدا شد. روشهای تجربی مبتنی بر روابط فیزیکی هستند که عوامل مختلفی در به دست آمدن آنها دخالت دارند. به علت پیچیده بودن اندازه‌گیری پاره‌ای از عوامل تأثیرگذار و در روند ساده‌سازی روابط

نهایی روشهای مذکور، فرضیاتی در نظر گرفته می‌شود. چنین روشهایی که در ابتدا به علت در نظر گرفتن عوامل مختلف می‌توانند جامعیت داشته باشند، با اعمال فرضیات ساده‌کننده، خطاهای بزرگی در پاسخ نهایی آنها ایجاد می‌شود که دقت آنها را در مقایسه با مدل‌های جعبه سیاه که برای هر مورد مطالعاتی خاص کالیبره می‌شوند پایین می‌آورد. یکی از دلایل برتری پاسخ روش پنمن نسبت به دو روش تجربی دیگر به کار رفته، تأثیر کمتر فرضیات ساده‌کننده بر روش مذکور است. به منظور مدل‌سازی با روش MLR، داده‌های ورودی به صورت غیرنرمال استفاده شد و پاسخ مدل حاوی مقادیر سطوح معنی‌داری نزدیک به صفر برای تمامی ورودی‌ها بود که بیانگر مدل‌سازی خوب است. اگر این سطوح برای ورودی خاصی دارای مقادیر بالا باشد به این معنی است که در فرایند مدل‌سازی لازم است که آن ورودی حذف شود، همچنین نتایج روش رگرسیون حاوی برآورد مقادیر منفی برای تبخیر است (به صورت جزئی). این خطا ناشی از نحوه مدل‌سازی روش رگرسیون خطی چند متغیره است که موقعیت بهترین ابر صفحه رگرسیون با استفاده از کمترین خطای مربعات را که می‌توان بین مشاهدات برازش داد، تعیین می‌کند. در ارتباط با مدل‌سازی توسط ANN، جدول ۲ تعدادی از ساختارهای بهینه به دست آمده از مدل‌های ANN را نشان می‌دهد. برای مقایسه نتایج دو روش رگرسیونی و ANN، نتایج مدل‌ها به عنوان مثال برای شهر ارومیه به ترتیب در شکل‌های ۲ و ۳ رسم شده‌اند.

جدول ۳ شامل R^2 و RMSE به دست آمده از تمامی روشهای به‌کار گرفته شده برای هر منطقه است. از جدول ۳ استنباط می‌شود که مدل‌سازی با ANNs در هر دو منطقه میزان تبخیر روزانه را در مقایسه با دیگر روشها با میزان خطای پائین‌تری تخمین زده است. از دلایل این برتری می‌توان به انعطاف‌پذیری بودن ANNs در تخمین روندهای خطی و غیرخطی اشاره کرد. به طور مشابه دیگر مطالعات صورت گرفته در زمینه برآورد تبخیر توسط محققانی نظیر مقدم‌نیا و همکاران، رحیمی‌خوب، ترائوره و همکاران^۱، عمدتاً برتری پاسخ ANNs را نسبت به روشهای تجربی و مطالعات انجام شده توسط طبری، دیسوال و پال دقیق‌تر بودن ANNs را نسبت به مدل MLR گزارش کرده‌اند [۱۰-۱۳ و ۱۵]. همان‌طوری که نتایج جدول ۳ نیز حاکی از عملکرد ضعیف‌تر روش رگرسیونی نسبت به مدل ANN در مدل‌سازی فرایند غیرخطی تبخیر است. همچنین از جدول ۳ نتیجه می‌شود که روشهای جعبه سیاه رگرسیونی و ANN که برای مورد مطالعاتی تبخیر روزانه و برای دو منطقه تبریز و ارومیه کالیبره شده‌اند، پاسخهایی بهتر و با خطای پایین نسبت به

¹ Traore et al.


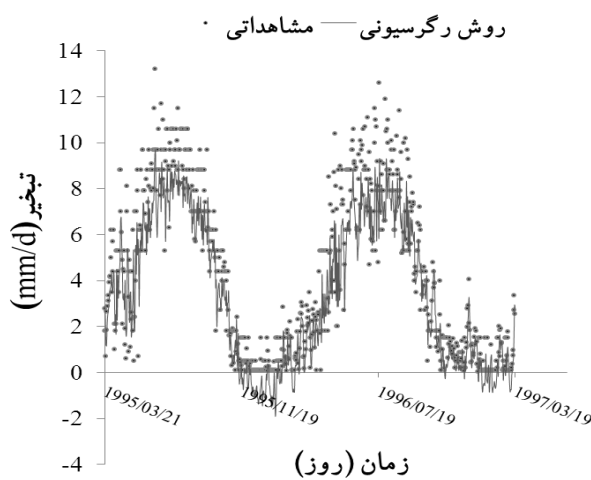

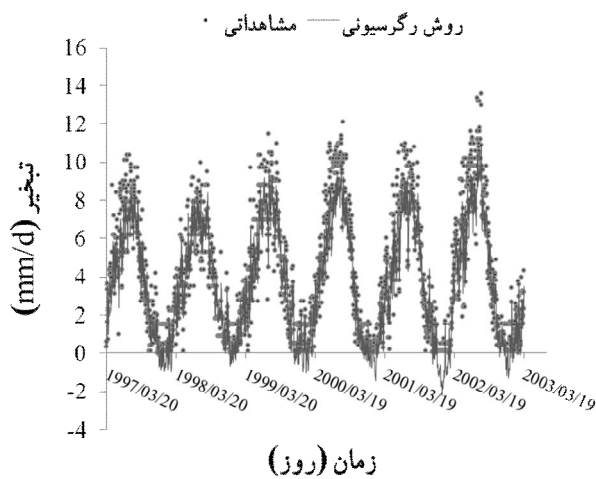
در زمان قبل (t-1) دارد. بنابراین یکی از دلایل برتری مدل‌های رگرسیونی و ANN به روشهای تجربی به کار رفته را می‌توان در نظر گرفتن تبخیر به عنوان یک فرایند مارکوف دانست که با وارد کردن مؤلفه تبخیر روز گذشته E_{t-1} در مدل‌سازی، دقت مدل در آن افزایش می‌یابد.

روشهای تجربی که بر اساس روابط فیزیکی هستند، تولید کرده‌اند. از طرف دیگر مانند اغلب پدیده‌های هیدرولوژیکی، تبخیر را می‌توان یک فرایند مارکوف^۱ در نظر گرفت. در چنین فرایندهایی احتمال وقوع یک حالت اقلیمی در زمان t بستگی به وضعیت آن


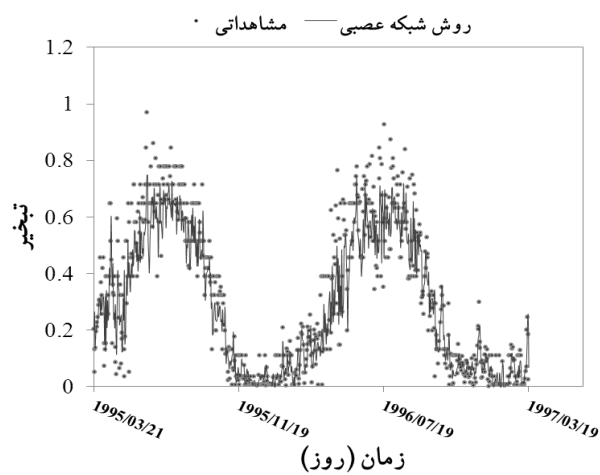

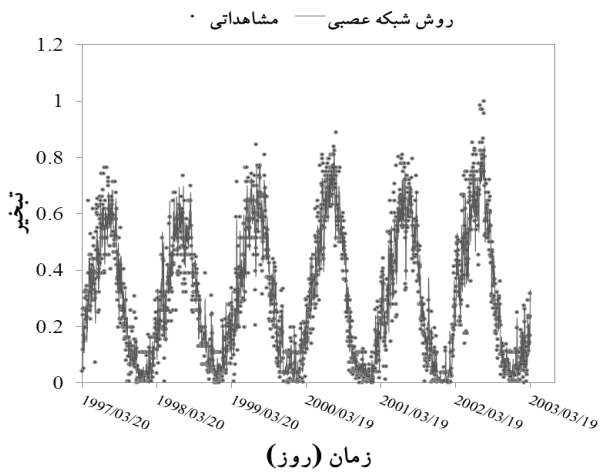
^۱ Markovian Process

جدول ۲- ترکیبات بهینه مدل‌سازی تبخیر با ANNs برای شهرهای تبریز و ارومیه

| ارومیه | | | | تبریز | | | | Epoch | | | | ساختار لایه‌ها | | | |
|-------------|----------------|-------------|----------------|-------------|----------------|-------------|----------------|--------|----|--------|--------|--------------------------------|--|-------|--|
| آزمایش | | آموزش | | آزمایش | | آموزش | | ارومیه | | تبریز | | ارومیه | | تبریز | |
| RMSE (mm/d) | R ² | RMSE (mm/d) | R ² | RMSE (mm/d) | R ² | RMSE (mm/d) | R ² | | | | | | | | |
| ۰/۱۰۹ | ۰/۸۲۸ | ۰/۰۷۹ | ۰/۸۸۹ | ۰/۰۷۷ | ۰/۸۹۳ | ۰/۰۷۸ | ۰/۸۸۸ | ۵۰ | ۸۰ | ۶-۶-۱ | ۶-۸-۱ | $E_{t-1}, R_H, R_a, T, P, U_2$ | | | |
| - | - | - | - | ۰/۰۷۸ | ۰/۸۹۱ | ۰/۰۷۸ | ۰/۸۸۶ | - | ۷۰ | - | ۴-۱۰-۱ | E_{t-1}, R_a, T, U_2 | | | |
| ۰/۱۰۷ | ۰/۸۳۴ | ۰/۰۸۲ | ۰/۸۸۱ | - | - | - | - | ۷۰ | - | ۴-۹-۱ | - | E_{t-1}, R_a, T, R_H | | | |
| ۰/۱۱۶ | ۰/۸۲۷ | ۰/۰۷۹۰ | ۰/۸۹۰ | ۰/۰۸۳۰ | ۰/۸۸۳ | ۰/۰۷۹ | ۰/۸۸۳ | ۵۰ | ۵۰ | ۳-۱۲-۱ | ۳-۱۱-۱ | E_{t-1}, R_a, T | | | |



شکل ۲- نتایج روش MLR برای ترکیب ۶ متغیره برای شهر ارومیه



شکل ۳- نتایج روش ANN برای ترکیب ۶ متغیره برای شهر ارومیه

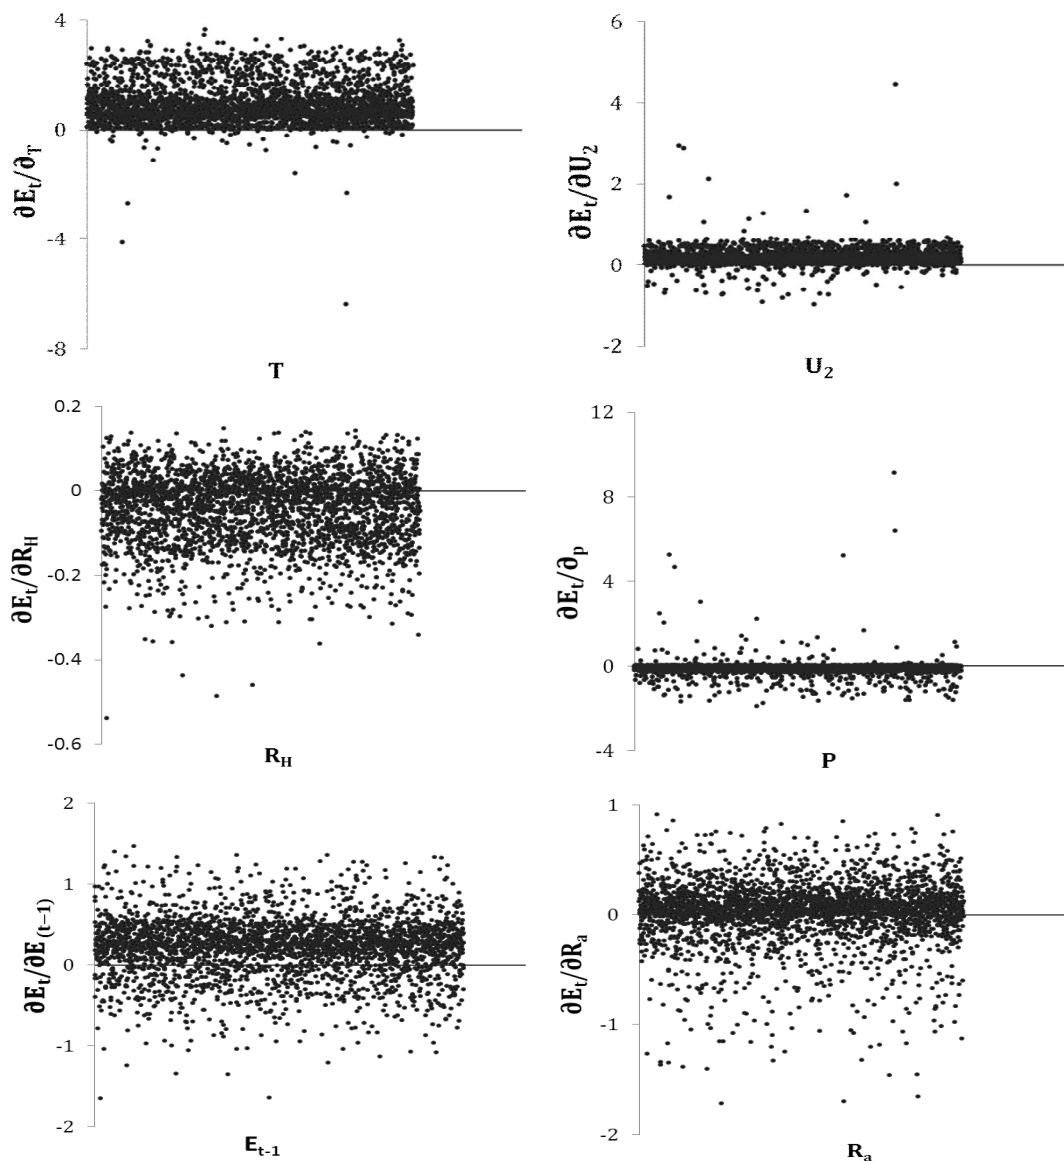
جدول ۳- خلاصه نتایج کلیه روشهای به کار برده شده به منظور برآورد مقدار تبخیر روزانه الف- تبریز و ب- ارومیه

| آزمایش | | آموزش | | روشها | (الف) |
|-------------|----------------|-------------|----------------|--------------------------------|-----------|
| RMSE (mm/d) | R ² | RMSE (mm/d) | R ² | | |
| ۹/۱۸ | ۰/۰۹ | ۴/۰۶ | ۰/۳۷ | تبادل انرژی | شبکه عصبی |
| ۴/۰۲ | ۰/۳۸ | ۳/۸۳ | ۰/۴۳ | آیرودینامیکی | |
| ۳/۶۵ | ۰/۴۶ | ۳/۲۰ | ۰/۵۰ | ترکیبی پنمن | |
| ۰/۰۸ | ۰/۸۹ | ۰/۰۸ | ۰/۸۹ | $E_{t-1}, R_H, R_a, T, P, U_2$ | شبکه عصبی |
| ۰/۰۹ | ۰/۸۷ | ۰/۰۸ | ۰/۸۷ | R_H, R_a, T, P, U_2 | |
| ۱/۸۳ | ۰/۸۶ | ۱/۸۵ | ۰/۸۶ | $E_{t-1}, R_H, R_a, T, P, U_2$ | رگرسیون |
| ۲/۱۵ | ۰/۸۴ | ۲/۱۵ | ۰/۸۵ | R_H, R_a, T, P, U_2 | |
| آزمایش | | آموزش | | روشها | (ب) |
| RMSE (mm/d) | R ² | RMSE (mm/d) | R ² | | |
| ۹/۷۹ | ۰/۰۰۴ | ۵/۷۲ | ۰/۲۳ | تبادل انرژی | شبکه عصبی |
| ۶/۰۱ | ۰/۱۲ | ۳/۸۳ | ۰/۴۱ | آیرودینامیکی | |
| ۴/۲۵ | ۰/۳۵ | ۲/۸۱ | ۰/۵۶ | ترکیبی پنمن | |
| ۰/۱۱ | ۰/۸۳ | ۰/۰۸ | ۰/۸۹ | $E_{t-1}, R_H, R_a, T, P, U_2$ | شبکه عصبی |
| ۰/۱۳ | ۰/۷۷ | ۰/۰۹ | ۰/۸۷ | R_H, R_a, T, P, U_2 | |
| ۱/۶۱ | ۰/۷۸ | ۱/۲۵ | ۰/۸۵ | $E_{t-1}, R_H, R_a, T, P, U_2$ | رگرسیون |
| ۱/۹۷۴ | ۰/۷۴ | ۱/۴۷ | ۰/۸۲ | R_H, R_a, T, P, U_2 | |

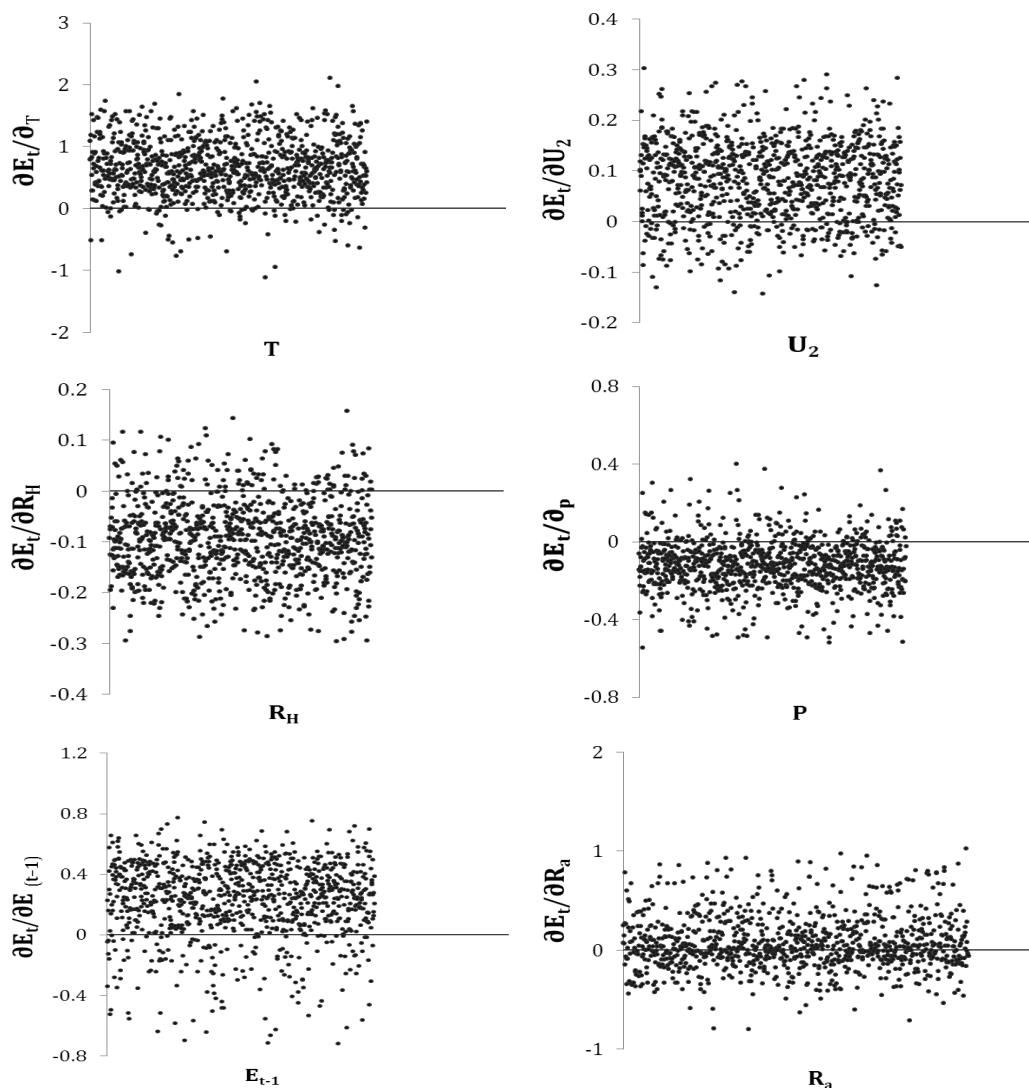
۲-۵- نتایج آنالیز حساسیت

میانگین آن ورودی و با کمترین واریانس یا انحراف داشته باشند. به این ترتیب احتمال وارد شدن داده‌هایی که ممکن است با خطا اندازه‌گیری شده باشند در مرحله آنالیز حساسیت مدل از بین رفته و در نتیجه تحقیق در خصوص میزان حساسیت مدل به آن ورودی خاص، نتایج بهتری را تولید می‌کند. در مرحله بعدی با استفاده از نمونه‌های گرفته شده و روابط مشتقات جزئی ارائه شده، حساسیت نسبی خروجی به ورودی‌های مختلف به دست آمد. نمودار پراکنش مقادیر حساسیت‌های به دست آمده در شکل‌های ۴ و ۵ به ترتیب برای تبریز و ارومیه نشان داده شده‌اند. در این نمودارها محور افقی نشان دهنده متغیر ورودی و محور قائم نشان دهنده مقادیر حساسیت به دست آمده (مشتقات خروجی تبخیر روی دامنه متغیر ورودی) هستند.

به منظور سنجش حساسیت ANNs آموزش دیده با روش PaD، از ساختارهای بهینه ANNs که برای ترکیبات ۶ پارامتری با توجه به جدول ۲ به دست آمدند، استفاده شد و در ادامه مشتقات توابع حاکم بر شبکه نسبت به همه ورودی‌ها و با ثابت نگه داشتن سایر متغیرها به دست آمد (تغییر نسبت به ورودی خاص با ثابت نگه داشتن بقیه ورودی‌ها). سپس با استفاده از بانک اطلاعاتی داده‌های مدل‌ها (۵۴۷۹ و ۲۹۲۲ رکورد ثبت شده برای هر متغیر ورودی) و در فضای ۶ بعدی ورودی‌ها برای شهر تبریز و ارومیه، نمونه‌هایی به ترتیب با تعداد ۳۰۰۰ و ۱۰۰۰ نقطه و با توزیع نرمال انتخاب شدند. نمونه‌گیری با توزیع نرمال باعث می‌شود که از دامنه هر متغیر ورودی داده‌هایی انتخاب شوند که بیشترین پراکندگی را در اطراف



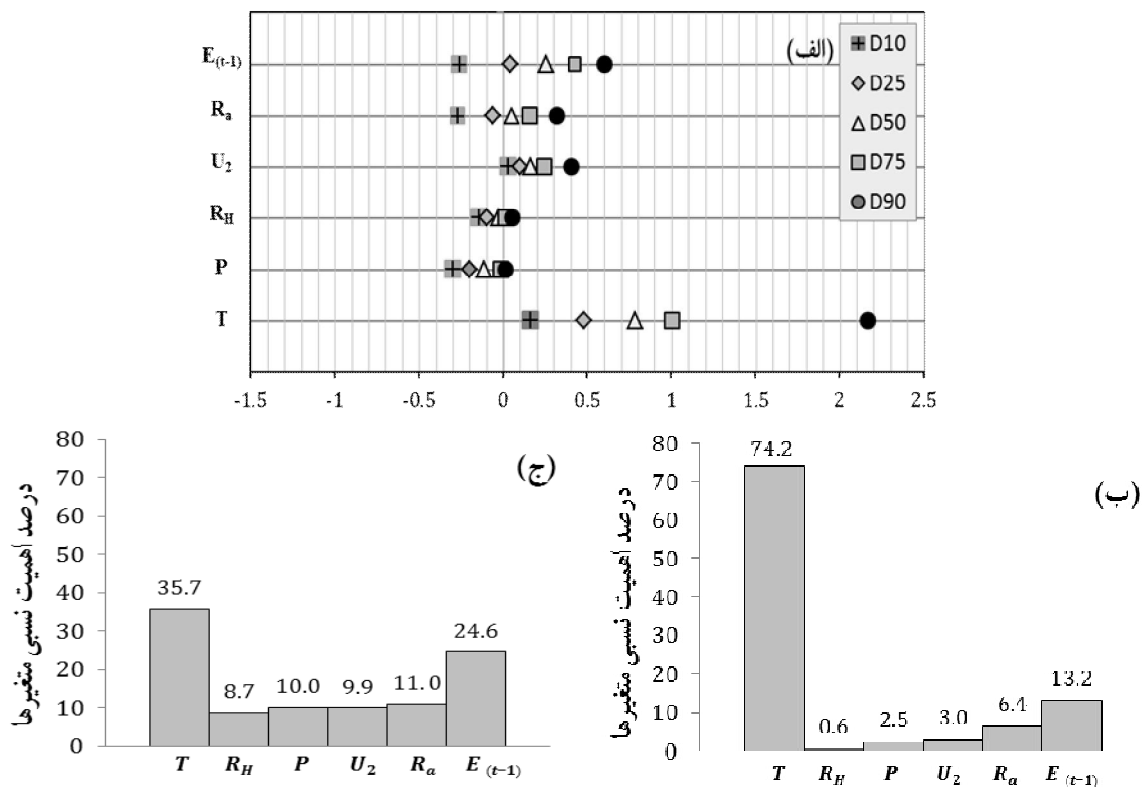
شکل ۴- نمودارهای پراکنش مقادیر حساسیت نسبی برای شهر تبریز



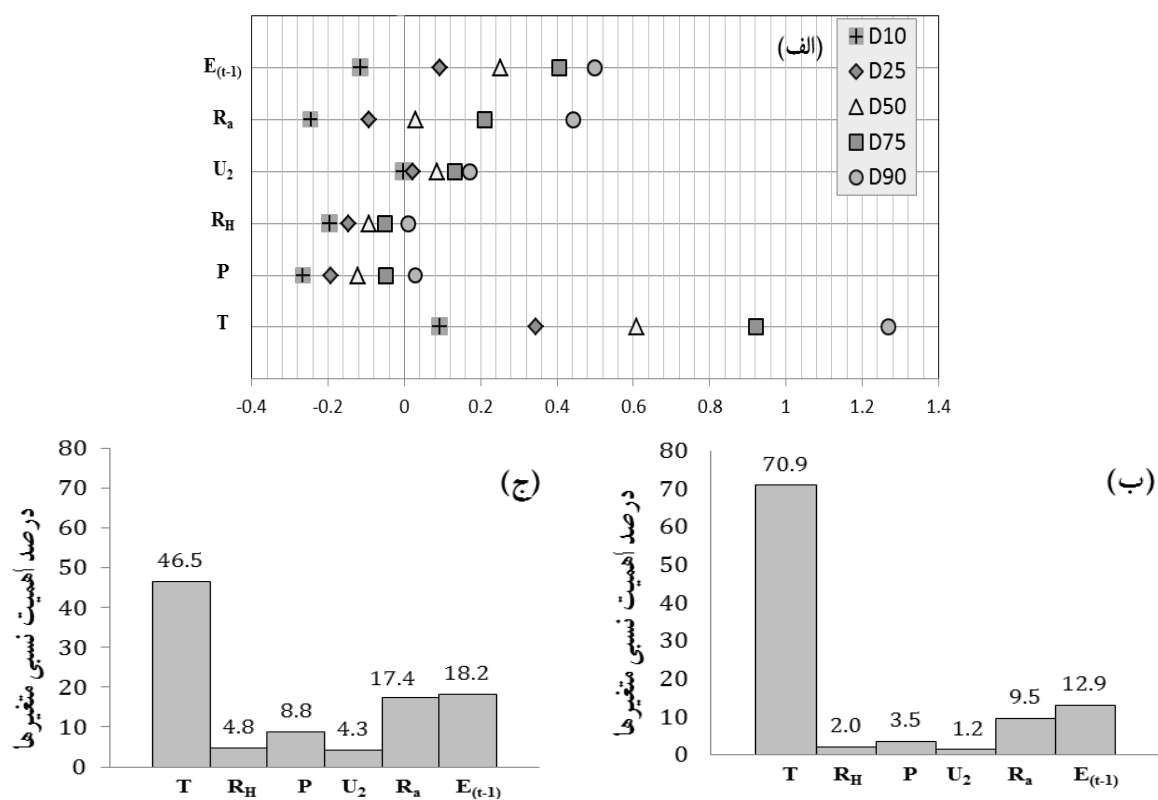
شکل ۵- نمودارهای پراکنش مقادیر حساسیت نسبی برای شهر ارومیه

هنگامی که این پراکنندگی و یا تجمع، حول خط پایه صفر (حساسیت صفر) باشد، اهمیت بیشتری پیدا می‌کند، به این ترتیب که تجمع حول خط پایه صفر، نشانگر صفر شدن تقریبی مشتق در تمام فضای متغیرهای ورودی و بی‌تأثیر بودن تغییرات متغیر X_1 بر تابع f است. در عین حال، پراکنندگی این مقادیر حول خط پایه صفر نشان می‌دهد که متغیر X_1 در بعضی سطوح خود و یا متغیرهای دیگر تأثیر افزایشی بر تابع دارد و در بعضی سطوح دیگر خود یا متغیرهای دیگر تأثیر کاهش‌ی بر روی تابع f دارد، از این رو پیدا کردن اندرکنش بین متغیر X_1 با متغیرهای دیگر در تأثیر بر تابع f و در نظر گرفتن این اندرکنش‌ها در مقادیر طراحی متغیرهای ورودی، می‌تواند مفید باشد. برای مثال در این مورد می‌توان تأثیر تشعشع و تبخیر روز قبل را بر تبخیر روزانه در شکل‌های ۶- الف و ۷- الف به وضوح ملاحظه کرد.

برای یافتن جهت تأثیر ورودی‌ها بر خروجی مدل شبکه، آنالیز درصد‌های آماری مقادیر حساسیت نسبی به دست آمد. در شکل‌های ۶ و ۷ نمودارهای نتایج آنالیز درصد‌های آماری مقادیر حساسیت نسبی به روش PaD، اهمیت نسبی ورودی‌ها به روش وزن‌های اتصالی به ترتیب برای شهرهای تبریز و ارومیه نشان داده شده‌اند. با توجه به شکل‌های ۶- الف و ۷- الف، لازم به ذکر است که تجمع مقادیر درصد‌های آماری حساسیت نسبی یک متغیر ورودی مانند X_1 حول یک عدد ثابت، بیانگر تغییرات ثابت تابع مورد نظر ($f(X_1, X_2, \dots, X_n)$) نسبت به متغیر X_1 در فضای مورد بررسی است، یعنی با قطعیت بالا (بیش از ۹۰ درصد) می‌توان گفت که نقش متغیر X_1 در تغییرات تابع f ، مستقل از سطوح خود متغیر X_1 و نیز مستقل از تغییرات دیگر متغیرهای ورودی است. به عبارت دیگر متغیر X_1 در تغییرات تابع f با متغیرهای دیگر فضای ورودی اندرکنشی ندارد.



شکل ۶- نتایج برای شهر تبریز: الف- نمودار تورنادو (پراکندگی درصد حساسیت‌های نسبی) به روش PaD، ب- نمودار درصد اهمیت و شرکت پارامترها به روش PaD و با تعریف پارامتر SSD و ج- نمودار درصد اهمیت و شرکت پارامترها به روش وزن‌های اتصالی است.



شکل ۷- نتایج برای شهر ارومیه: الف- نمودار تورنادو (پراکندگی درصد حساسیت‌های نسبی) به روش PaD، ب- نمودار درصد اهمیت و شرکت پارامترها به روش PaD و با تعریف پارامتر SSD و ج- نمودار درصد اهمیت و شرکت پارامترها به روش وزن‌های اتصالی است.

از شکل‌های ۶- الف و ۷- الف مشخص است که حساسیت‌های خروجی شبکه برای T بیش از ۹۰ درصد و برای U_2 حدود ۹۰ درصد مقادیر مثبت است زیرا D ۱۰ درصد بزرگ‌تر از صفر به دست آمده، برای P و R_H حدود ۷۵ درصد مقادیر منفی به دست آمده و درصد باقیمانده دارای مقادیر مثبت کوچک هستند. برای R_a حدود ۵۰ درصد و برای E_{t-1} (تخیر روز قبل) حدود ۷۵ درصد مقادیر مثبت به دست آمد، زیرا به ترتیب D ۵۰ درصد بزرگ‌تر از صفر و $25D$ درصد بزرگ‌تر از صفر هستند. از این رو به طور کل می‌توان گفت که با احتمال ۹۰ درصد با افزایش T و U_2 مقدار تخیر روزانه افزایش، با احتمال حدود ۷۵ درصد با افزایش P و R_H مقدار تخیر روزانه کاهش، با احتمال حدود ۵۰ درصد با افزایش R_a و با احتمال بیش از ۷۵ درصد با افزایش E_{t-1} مقدار تخیر روزانه افزایش می‌یابد. از پراکندگی گسترده‌تر مقادیر آماری حساسیت‌های E_{t-1} ، T، R_a و $\left(\frac{\partial E}{\partial T}\right)$ ، $\left(\frac{\partial E}{\partial E_{t-1}}\right)$ و $\left(\frac{\partial E}{\partial R_a}\right)$ حول خط حساسیت صفر در شکل‌های ۶- الف و ۷- الف، می‌توان نتیجه گرفت که این متغیرها تأثیر بیشتری روی مقدار تخیر نسبت به سایر ورودی‌ها دارند. از شکل‌های ۶- ب و ۶- ج و ۷- ب و ۷- ج نیز معلوم است که بیشترین تأثیر را پارامتر T و پس از آن به ترتیب E_{t-1} و R_a دارند. از روی شکل‌های ۴ و ۵ می‌توان پراکندگی مقادیر حساسیت را ملاحظه کرد که برای بیشتر مقادیر T و U_2 در بالای خط صفر، برای بیشتر مقادیر P و R_H در پایین خط صفر، برای E_{t-1} بیشتر توزیع‌ها در بالای خط صفر و برای R_a ، حساسیت‌ها توزیع تقریباً مساوی در طرفین خط حساسیت صفر دارند.

طبق نمودارهای تورنادو (پراکندگی درصد حساسیت‌های نسبی) به دست آمده، میزان تأثیر دما، تشعشع و تخیر روز قبل در هر دو منطقه بیشتر از مابقی پارامترها است، ولی میزان تأثیر دما در شهر تبریز بیشتر از ارومیه است (شکل‌های ۶- الف و ۷- الف). بنا به نتایج آنالیز حساسیت، تأثیر سایر عوامل بر میزان تخیر نامحسوس است. برای مقایسه پاسخ ANNs با نتایج حاصل از

۷- منابع

- 1- Alizadeh, A. (2005). *Principles of applied hydrology*, University of Mashhad, Iran. (In Persian)
- 2- Zoqi, M.J., and Saeedi, M. (2011). "Modeling leachate generation using artificial neural networks." *J. of Water and Wastewater*, 77, 76-84. (In Persian)
- 3- Tabesh, M., and Dini, M. (2010). "Forecasting daily urban water demand using artificial neural networks, a case study of Tehran urban water." *J. of Water and Wastewater*, 73, 84-95. (In Persian)
- 4- Lu, M., AbouRizk, S.M., and Hermann, U.H. (2001). "Sensitivity analysis of neural networks in spool fabrication productivity studies." *J. of Comput. Civ. Eng.*, 15, 299-308.
- 5- Li, Y., Shen, L.Y., and Love, P.E.D. (1999). "ANN based mark-up estimation system with self-explanatory capabilities." *J. of Construct. Eng. Manag.*, 125, 185-189.

آنالیز حساسیت که منجر به تعیین مؤثرترین پارامترها شد، می‌توان به جدول ۲ مراجعه کرد. همانطوری که مشاهده می‌شود پاسخ شبکه زمانی که تمام متغیرهای ورودی را دریافت می‌کند با پاسخ شبکه زمانی که فقط ورودی‌های T، R_a و E_{t-1} را که در مرحله تحلیل حساسیت مؤثرترین تشخیص داده شدند، دریافت می‌کند تفاوت چندانی ندارد، بنابراین می‌توان نتیجه گرفت که سایر متغیرهای ورودی نسبت به متغیرهای T، R_a و E_{t-1} کم اهمیت بوده و در آموزش شبکه نقش کمی ایفا می‌کنند. نتیجه‌ای که گرفته می‌شود حاکی از این است که با انجام تحلیل حساسیت مدل شبکه در اقلیم‌های مختلف می‌توان فضای متغیرهای ورودی به شبکه و در نتیجه زمان آموزش را کاهش داد و پاسخی با دقت قابل قبول نیز به دست آورد.

۶- نتیجه‌گیری

شبکه‌های عصبی مصنوعی ابزارهای قوی برای مطالعات هیدرومتئورولوژیکی هستند که در این مطالعه برتری خود را در مسئله پیش‌بینی تخیر نسبت به سایر روش‌های به کار برده شده به اثبات رساندند. عیب این شبکه‌ها در غیرقابل تفسیر بودن نتایج حاصل از مدل‌سازی از نظر میزان تأثیر هر متغیر ورودی بر خروجی مورد نظر است. از این رو در این مطالعه با انجام آنالیز حساسیت به دو روش مشتقات جزئی و وزن‌های اتصالی، اهمیت نسبی شرکت ورودی‌های شبکه در برآورد تخیر روزانه شهرهای تبریز و ارومیه به دست آمد که هر دو روش نتایج تقریباً همسویی را نشان می‌دهند. برای یافتن جهت تأثیر هر ورودی در خروجی شبکه‌ها، روش آماری آنالیز درصد حساسیت‌های نسبی در روش PaD به کار برده شد. طبق نمودارهای تورنادو (پراکندگی درصد‌های حساسیت‌های نسبی) به دست آمده، میزان تأثیر دما، تشعشع و تخیر روز قبل در هر دو منطقه بیشتر از مابقی پارامترها بوده و تأثیر سایر عوامل نامحسوس است.

- 6- Sinha, S.K., and Mckin, R.A. (2000). "Artificial neural network for measuring organizational effectiveness." *J. of Comput. Civ. Eng.*, 14, 9-14.
- 7- Knoweles, P. (1997). "Predicting labor productivity using neural networks." M.Sc. Thesis, University of Alberta, Edmonton, Canada.
- 8- Sayed, T., and Razvi, A. (2000). "Comparision of neural and conventional approaches to mode choise analysis." *J. of Comput. Civ. Eng.*, 14, 23-30.
- 9- Jain, S.K., Nayak, P.C., and Sudheer, K.P. (2008). "Models for estimating evapotranspiration using artificial neural networks, and their physical interpretation." *J. of Hydrol. Process*, 22, 2225-2234.
- 10- Moghaddamnia, A., Ghafari Gousheh, M., Piri, J., Amin, S., and Han, D. (2009). "Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques." *J. of Adv. Water Resour.*, 32, 88-97.
- 11- Deswal, S., and Pal, M. (2008). "Artificial neural network based modeling of evaporation losses in reservoirs." *J. of Eng. Tech. Manag.*, 39, 79-83.
- 12- Rahimikhoob, A. (2008). "Estimating daily pan evaporation using artificial neural network in a semi-arid environment." *J. of Theor. Appl. Climatol*, 98, 101-105.
- 13- Traore, S., Wang, Y.M., and Kerh, T. (2010). "Artificial neural network for modeling reference evapotranspiration complex process in Sudano-Sahelian zone." *J. of Agr. Water Manag.*, 97, 707-714.
- 14- Ma, L., Wu, Y., Ji, J., and He, Ch. (2011). "The prediction model for soil water evaporation based on BP neural network." *Int Conf Intell Comput Tech Autom (ICICTA)*, 2, 276-280.
- 15- Tabari, H., Marofi, S., and Savziparvar, A.A. (2010). "Estimation of daily pan evaporation using artificial neural networks and multivariate non-linear regression." *J. of Irrig. Sci.*, 28, 399-406. (In Persian)
- 16- Banimahd, M., Yasrobi, S.S., and Woodward, P.K. (2005). "Artificial neural network for stress-strain behavior of sandy soils: Knowledge based verification." *J. of Comput. Geotech.*, 32, 377-386.
- 17- Jain, A., Kumar, S., and Misra, S. (2008). "Modeling and analysis of concrete slump using artificial neural networks." *J. of Mater. Civ. Eng.*, 20, 628-633.
- 18- Gevrey, M., Dimopoulos, I., and Lek, S. (2006). "Two-way interaction of input variables in the sensitivity analysis of neural network models." *J. of Ecol. Model.*, 195, 43-50.
- 19- Liong, S.Y., Lim, W.H., and Paudyal, G.N. (2000). "River stage forecasting in Bangladesh: Neural network approach." *J. of Comput. Civ. Eng.*, 14, 1-8.
- 20- Chow, V.T., Maidment, D.R., and Mays, L.W. (1988). *Applied hydrology*, McGraw-Hill Book Company, New York.
- 21- Phien, N.H., and Kha, N.D.A. (2003). "Flood forecasting for the upper reach of the Red river basin, North Vietnam." *J. of Water SA.*, 29, 267-272.
- 22- Reddy, T.A. (2006). *Evaluation and assessment of fault detection and diagnostic methods for centrifugal chillers-phase II*, Drexel University, Philadelphia.
- 23- Soltani, A. (1998). *Applied regression analysis*, Isfahan University Pub., Isfahan, Iran. (In Persian)
- 24- Rajaei, T., Mirbagheri, S.A., Nourani, V., and Alikhani, A. (2010). "Prediction of daily suspended sediment load using wavelet and neurofuzzy combined model." *Int J. of Environ. Sci. Tech.*, 7, 93-110
- 25- Garson, G.D. (1991). "Interpreting neural network connection weights." *J. of Artif. Intell. Expert*, 6, 47-51.
- 26- Goh, A.T.C. (1995). "Back-propagation neural networks for modeling complex systems." *J. of Artif. Intell. Eng.*, 9, 143-151.
- 27- Gevrey, M., Dimopoulos, I., and Lek, S. (2003). "Review and comparison of methods to study the contribution of variables in artificial neural network models." *J. of Ecol. Model*, 160, 249-264.