



## عدم قطعیت شبکه عصبی مصنوعی در تخمین تبخیر روزانه (مطالعه موردی: ایستگاه‌های رشت و منجیل)

سید مصطفی بی آزار<sup>۱</sup>، محمدعلی قربانی<sup>۲</sup> و کاکا شاهدهی<sup>۳</sup>

۱- دانشجوی کارشناسی ارشد، مهندسی منابع آب، دانشگاه تبریز، (نویسنده مسوول: seyedmstafa.b@gmail.com)

۲- دانشیار، گروه مهندسی آب دانشگاه تبریز

۳- دانشیار، گروه آبخیزداری دانشگاه علوم کشاورزی و منابع طبیعی ساری

تاریخ دریافت: ۹۵/۷/۲۷ تاریخ پذیرش: ۹۶/۲/۱۳

صفحه: ۱ تا ۱۲

### چکیده

در این تحقیق کاربرد شبکه عصبی پرسپترون چندلایه (MLP) برای پیش‌بینی تبخیر روزانه در دو ایستگاه سینوپتیک رشت و منجیل واقع در استان گیلان در شمال ایران بررسی گردیده است. ابتدا با استفاده از آزمون گاما مهم‌ترین ترکیب از پارامترهای هواشناسی برای هر دو ایستگاه شناسایی و مدل‌سازی براساس ترکیب بهینه صورت گرفت. نتایج مدل شبکه عصبی مصنوعی - آزمون گاما (ANN-GT) با استفاده از معیارهای ارزیابی مدل همچون مجذور میانگین مربعات خطا (RMSE) ضریب همبستگی (CC) و ضریب نائش-ساتکلیف (NS) ارزیابی شده است. نتایج نشان داد که مدل (ANN-GT) برای ایستگاه رشت با ضریب همبستگی ۰/۸۶، مجذور میانگین مربعات خطا ۰/۹۵، ضریب نائش-ساتکلیف ۰/۷۴ و ایستگاه منجیل با ضریب همبستگی ۰/۹۴، مجذور میانگین مربعات خطا ۱/۵۸، ضریب نائش-ساتکلیف ۰/۸۹، دارای عملکرد قابل قبولی در پیش‌بینی تبخیر روزانه می‌باشد. برای بررسی عدم قطعیت، درصدی از داده‌های مشاهده شده که در محدوده باند پیش‌بینی عدم قطعیت ۹۵ درصد (95PPU) قرار گرفته‌اند (P-factor) و عرض متوسط باند (d-factor) برای مدل، مدنظر قرار داده شد. بنابر نتایج عدم قطعیت، عرض متوسط باند عدم قطعیت (d-factor) برای ایستگاه رشت (۰/۳۰) و برای منجیل (۰/۳۳) برآورد شد. این امر حاکی از عدم قطعیت پایین مدل شبکه عصبی مصنوعی-آزمون گاما (ANN-GT) در پیش‌بینی تبخیر روزانه برای هر دو ایستگاه می‌باشد. همچنین درصد داده‌های مشاهداتی در باند (95PPU) برای رشت ۲۵ و برای منجیل ۴۵ درصد به‌دست آمد. دلیل پایین بودن این مقادیر را می‌توان، وجود عدم قطعیت‌های کوچک در پارامترها ذکر کرد.

واژه‌های کلیدی: آزمون گاما، تبخیر روزانه، شبکه عصبی مصنوعی، گیلان، عدم قطعیت

### مقدمه

تبخیر-تعرق لایسیمتری استفاده کردند. نتایج را با دو مدل شبکه عصبی مصنوعی، سیستم استنتاج فازی-عصبی تطبیقی<sup>۵</sup> و داده‌های لایسیمتری مقایسه نمودند. نتایج بیانگر عملکرد خوب هر دو مدل شبکه عصبی مصنوعی و ماشین بردار پشتیبان با کرنل‌های مختلف بوده است. تحلیل عدم قطعیت در پژوهش ایشان نشان داد که مدل حداقل مربعات ماشین بردار پشتیبان عدم قطعیت پایین‌تری نسبت به مدل‌های دیگر دارد. نوری و همکاران (۱۹) عدم قطعیت شبکه عصبی مصنوعی و سیستم استنتاجی فازی-عصبی تطبیقی را برای پیش‌بینی روزانه منوکسید کربن در تهران مورد بررسی قرار دادند. آنها برای انتخاب ترکیب مناسب، برای ورودی شبکه عصبی از آزمون گاما و انتخاب پیشرو<sup>۶</sup> استفاده کردند. نتایج نشان داد که انتخاب پیشرو برای هر دو مدل، نتایج بهتری دارد و همچنین مدل شبکه عصبی مصنوعی مبتنی بر انتخاب پیشرو دارای عدم قطعیت پایین‌تری نسبت به مدل‌های دیگر می‌باشد. گوپال و همکاران (۱۲) در مطالعه‌ای توانایی شبکه عصبی مصنوعی، حداقل مربعات رگرسیون بردار پشتیبان، منطق فازی<sup>۷</sup> و سیستم استنتاجی فازی-عصبی تطبیقی را در تخمین تبخیر روزانه مورد ارزیابی قرار دادند. این مطالعه در آب و هوای نیمه گرمسیری در کارسو هندوستان انجام شد. آنها برای به‌دست آوردن نتایج بهتر و کم شدن میزان خطا، از آزمون گاما برای انتخاب ترکیب بهینه استفاده کردند. بر اساس مقایسه‌های انجام شده، منطق فازی و حداقل مربعات رگرسیون بردار پشتیبان در برآورد تبخیر روزانه با توجه به داده‌های در در

تبخیر یک جز اصلی در چرخه هیدرولوژیکی در نظر گرفته می‌شود و نقش مهم و کاربردی در مدیریت منابع آب و مطالعات زیست محیطی دارد. پیچیدگی سیستم‌های هیدرولوژیکی از نظر تعیین تمام پارامترهای دخیل و نقص اطلاعات آماری، امکان مدل‌سازی کامل سیستم‌های هیدرولوژیکی را غیرممکن می‌سازد (۱۶،۲۰،۲۱). در چنین شرایطی استفاده از مدل‌سازی سیستمی که مبتنی بر روابط ریاضی باشد، مورد توجه قرار می‌گیرد (۱۵). همچنین مسایل مرتبط با طبیعت همواره شامل دامنه‌ای گسترده از متغیرها و پارامترهای نامعلوم و تصادفی هستند. معمولاً در برآورد و اندازه‌گیری این نوع متغیرها خطاهای زیادی وجود دارد که باعث ایجاد عدم اطمینان در نتایج تحقیقات می‌شوند. بنابراین استفاده از معیاری کمی که برای تفسیر و تحلیل مقدار عدم قطعیت این مسایل می‌تواند به درک بهتر و قضاوت صحیح کمک کند فرخ‌نیا و مرادی (۸) در تحقیقی عدم قطعیت شبکه عصبی مصنوعی<sup>۱</sup> و مدل نروفازی<sup>۲</sup> در پیش‌بینی جریان رودخانه صوفی‌چای را مورد بررسی قرار دادند. نتایج نشان داد که مدل نروفازی از دقت بالاتر و عدم قطعیت پایین‌تری در پیش‌بینی برخوردار است. همچنین سیفی و همکاران (۲۳) تحقیقی دیگری را در زمینه معرفی و کاربرد حداقل مربعات ماشین بردار پشتیبان<sup>۳</sup> در برآورد تبخیر-تعرق مرجع در حوضه شهر کرمان انجام دادند. ایشان از روش حداقل مربعات ماشین بردار پشتیبان مبتنی بر آزمون گاما<sup>۴</sup> با کرنل شبکه عصبی تابع پایه شعاعی، خطی و چندجمله‌ای برای محاسبه

1- Artificial Neural Network

2- Neuro-fuzzy

3- Least Squares – Support Vector Machine (LS-SVM)

4- Gamma Test

5- Adaptive Neuro-Fuzzy Inference System (ANFIS)

6- Forward Selection

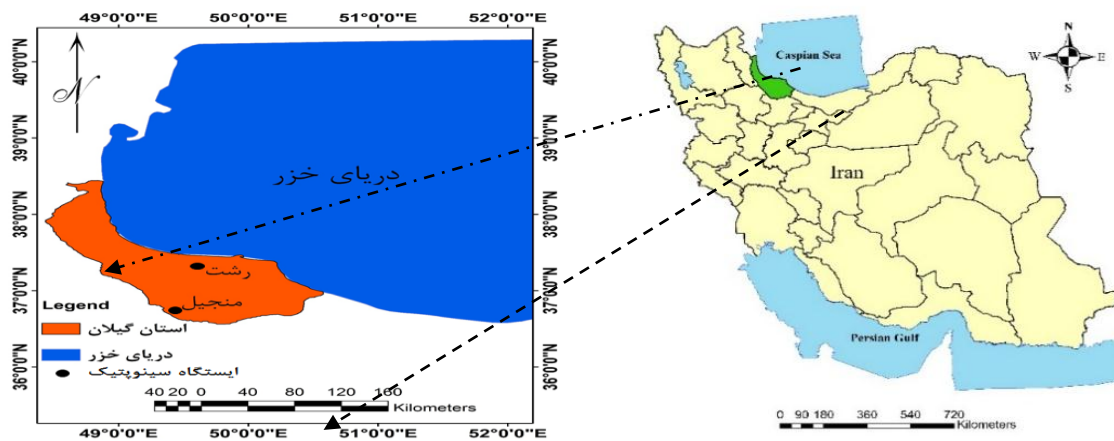
7- Fuzzy Logic

گرفته است و از شمال به دریای خزر، از شرق به استان مازندران، از جنوب به رشته کوه‌های البرز و استان‌های زنجان و قزوین و از غرب به استان اردبیل محدود می‌باشد. توزیع ناهماهنگ نزولات جوی و حجم جریانات سطحی در طول سال و از طرفی نقش آب در کشاورزی منطقه خصوصاً تولید محصول استراتژی برنج ضرورت بررسی و مطالعه سیستماتیک منابع آب اعم از سطحی و زیرزمینی را ایجاد نموده است. متوسط بارندگی استان گیلان ۱۱۰۰ میلی‌متر و میانگین حجم بارش ۱۵۰۲۷ میلیون مترمکعب می‌باشد که از حجم فوق میزان ۷۸۸۷ میلیون مترمکعب جز منابع غیرقابل دسترس (تبخیر و تعرق) و حجمی معادل ۷۱۴۰ میلیون مترمکعب قابل دسترس و تجدیدپذیر می‌باشد. در این مطالعه از داده‌های دو ایستگاه سینوپتیک منجیل و رشت (شکل ۱) استفاده شده است. دوره آماری داده‌ها ۱۳۸۳ تا ۱۳۹۴ برای ایستگاه رشت و ۱۳۸۳ تا ۱۳۹۳ برای ایستگاه منجیل می‌باشد. داده‌های اخذ شده شامل تبخیر، سرعت باد در ارتفاع دو متری، دما (حداقل، حداکثر و متوسط)، رطوبت (حداقل، حداکثر و متوسط)، ساعت آفتابی و بارندگی بوده است. جدول ۱ خصوصیات آماری داده‌های دو ایستگاه سینوپتیک مورد مطالعه را نشان می‌دهد. در این پژوهش از ۴۰۶۷ رکورد ثبت شده برای ایستگاه رشت و ۳۶۵۲ رکورد ثبت شده برای ایستگاه منجیل استفاده شده است. از این تعداد داده، ۸۰ درصد برای آموزش و ۲۰ درصد برای صحت‌سنجی مدل استفاده شده است.

دسترس موفق‌تر دیده شدند. قربانی و همکاران (۱۰) در پژوهشی عملکرد شبکه عصبی مصنوعی تابع پایه شعاعی و پرسپترون چندلایه<sup>۱</sup> را با ماشین بردار پشتیبان بر روی جریان رودخانه مقایسه کردند. آنها عملکرد این مدل‌ها را در ایستگاه‌های هیدرومتری صفاخانه، سننه و پولانیان در زرينه رود مورد ارزیابی قرار دادند. نتایج نشان‌دهنده عملکرد بهتر شبکه عصبی پرسپترون چندلایه و تابع پایه شعاعی نسبت به مدل ماشین بردار پشتیبان بوده است. کیشی و همکاران (۱۵) برای مدل‌سازی تبخیر روزانه از روش‌های اثر متقابل آشکارساز کای اسکور خودکار<sup>۲</sup>، شبکه عصبی مصنوعی، طبقه‌بندی<sup>۳</sup> و رگرسیون درختی<sup>۴</sup> در آنکارا و پلاتی در ترکیه استفاده کردند. نتایج نشان‌دهنده کارایی بهتر شبکه عصبی نسبت به سایر مدل‌ها بوده است. براساس بررسی به‌عمل آمده توسط مولفین تحقیقی در خصوص تخمین عدم قطعیت مدل‌های هوشمند جهت برآورد تبخیر با روش به کار رفته در این تحقیق انجام نشده و از آن جهت این امر نوآوری تحقیق را می‌رساند. با توجه به موارد ذکر شده و اهمیت تبخیر در این پژوهش سعی شده است عدم قطعیت شبکه عصبی مصنوعی همراه با پیش‌پردازش داده‌ها در تخمین تبخیر روزانه در دو ایستگاه رشت و منجیل مورد ارزیابی قرار گیرد.

### مواد و روش‌ها داده و منطقه مورد مطالعه

استان گیلان به مرکزیت رشت در شمال کشور قرار



شکل ۱- موقعیت ایستگاه‌های سینوپتیک مورد مطالعه  
Figure 1. The study area Location

1- Multilayer Perceptron  
3- Classification

2- Chi-Squared Automatic Interaction Detector (CHAID)  
4- Regression Tree

جدول ۱- خصوصیات آماری مقادیر داده‌ها در بازه زمانی ۱۳۸۳-۱۳۹۴ برای ایستگاه رشت و برای ایستگاه منجیل در بازه زمانی ۱۳۸۳-۱۳۹۳  
Table 1. The statistical properties of the data values for period of 2005-2016 on Rasht station and 2005-2014 for the Manjil

ایستگاه	متغیرها	شاخص‌ها			
		ضریب تغییرات	انحراف معیار	میانگین	حداقل
رشت	تبخیر (mm/day)	۰/۷۹	۱/۹	۲/۴۱	۰
	تابش خورشیدی (hr)	۰/۸۸	۴/۲	۴/۸۱	۰
	سرعت باد (m/sec)	۰/۴۳	۱/۸	۴/۲۸	۰
	بارندگی (mm)	۳/۱۴	۱۰/۹	۳/۴۷	۰
	رطوبت نسبی متوسط (%)	۰/۱۰	۹/۸	۱۰۰	۱۶
	رطوبت نسبی حداقل (%)	۰/۲۶	۱۷/۰۲	۶۵/۰۲	۷
	رطوبت نسبی حداکثر (%)	۰/۰۵	۵/۱۸	۹۶/۱۵	۲۰
	دمای متوسط (c°)	۰/۴۶	۷/۷۰	۱۶/۷۳	-۵/۲
	دمای حداقل (c°)	۰/۶۰	۷/۴۶	۱۲/۴۹	-۱۲/۸
	دمای حداکثر (c°)	۰/۴۰	۸/۴۴	۲۰/۹۶	-۱/۴
منجیل	تبخیر (mm/day)	۰/۷۳	۴/۸۲	۶/۶۴	۰
	ساعت آفتابی (hr)	۰/۴۷	۳/۵۷	۷/۵۸	۰
	سرعت باد (m/sec)	۰/۴۶	۵/۲۹	۱۱/۴۷	۰
	بارندگی (mm)	۴/۰۸	۲/۴۹	۰/۶۱	۰
	رطوبت نسبی متوسط (%)	۰/۱۹	۱۲/۰۳	۶۱/۸۳	۱۰
	رطوبت نسبی حداقل (%)	۰/۳۵	۱۵/۲۲	۴۲/۹۹	۲
	رطوبت نسبی حداکثر (%)	۰/۱۵	۱۱/۷۰	۷۹/۸۸	۱۸
	دمای متوسط (c°)	۰/۴۵	۸/۱۵	۱۸/۰۲	-۲/۵
	دمای حداقل (c°)	۰/۶۲	۸/۱۰	۱۳	-۶/۸
	دمای حداکثر (c°)	۰/۳۸	۸/۶۸	۲۳/۰۳	-۱/۶

### آزمون گاما

آزمون گاما یک روش غیر خطی است که نتایج آن صرف نظر از روش‌های خاص برای مدل‌سازی به کار برده می‌شود (۲۵). فرض می‌شود مجموعه داده‌های مشاهداتی به صورت زیر است:

$$\{(x_i - y_i)\}, 1 \leq i \leq M \quad (1)$$

که در آن  $x_i$  بردار مشاهداتی ورودی (مانند رواناب، بارش، درجه حرارت هوا یا تاخیرهای مختلف و هر متغیر موثر دیگر)،  $y_i$  خروجی مشاهداتی (مانند میانگین دبی رواناب روزانه) و  $M$  تعداد کل مشاهدات می‌باشد. از بردار  $x_i$  (در فضای  $m$  بعدی) برای مدل‌سازی  $y_i$  (در فضای  $R$ ) استفاده می‌شود. بنابراین، با توجه به فرض فوق رابطه بین ورودی و خروجی به شرح زیر در نظر گرفته می‌شود:

$$y = f(x) + r \quad (2)$$

که در آن  $f(x)$  یک تابع هموار و  $r$  متغیر تصادفی نشان‌دهنده خطا بوده، همچنین فرض شده است میانگین توزیعی که  $r$  از آن پیروی کرده، صفر و واریانس خطا  $Var(r)$  کران‌دار است. به این ترتیب، مدل نشان داده شده با رابطه ۲ به مدلی هموار با مشتقات جزئی مرتبه اول محدود می‌گردد و آماره گاما ( $\Gamma$ )، واریانس بخشی از داده‌ها که تابع

$f(x)$  قادر به توجیه آن نیست را نشان می‌دهد. برای بردار ورودی  $x_i$ ، مجموعه  $N[i, k]$  ( $1 \leq k \leq p$ ) به نام مجموعه نزدیک‌ترین همسایگی است. پایه و اساس آزمون گاما بر مبنای مجموعه  $N[i, k]$  می‌باشد. به عنوان  $k$  امین نزدیک‌ترین همسایگی‌ها برای بردار مشاهداتی ورودی  $x_i$  تعریف شده به طوری که  $(1 \leq k \leq p)$  و  $(1 \leq i \leq M)$  می‌باشد.  $p$  حداکثر تعداد همسایگی‌ها است که معمولاً بین ۱۰ تا ۵۰ در نظر گرفته می‌شود (۶). به منظور به دست آوردن مقدار آماره گاما ( $\Gamma$ ) ابتدا مقدار  $\delta_M(k)$ ، با توجه به داده‌های ورودی به شرح زیر محاسبه می‌شود:

$$\delta_M(k) = \frac{1}{M} \sum_{i=1}^M |x_{N[i,k]} - x_i|^2, 1 \leq k \leq p \quad (3)$$

که در آن  $|.....|$  به عنوان فاصله اقلیدسی بردار  $x_{N[i,k]}$  از همسایگی‌های آن می‌باشد. همچنین مقدار آماره‌ی گامای کوچک  $\gamma_M(k)$  با استفاده از داده‌های خروجی به شرح زیر به دست می‌آید:

$$\gamma_M(k) = \frac{1}{2M} \sum_{i=1}^M |y_{N[i,k]} - y_i|^2, 1 \leq k \leq p \quad (4)$$

از طول داده‌های ورودی). نتایج آزمون  $M$  به مشخص کردن اینکه آیا تعداد داده‌های کافی برای تخمین تقریبی گاما و یک مدل قابل اعتماد وجود دارد، کمک می‌کند. آزمون  $M$  بر سری‌هایی که توابع آن‌ها دارای مقادیر حقیقی و مختلط هستند اعمال می‌شود و شبیه به آزمون مقایسه برای تعیین همگرایی سری از اعداد حقیقی و یا پیچیده است. در واقع رسم نمودار تغییرات مقدار آماره گاما و یا خطای استاندارد در مقابل تعداد داده‌ها می‌باشد. در نقطه‌ای که این دو نمودار تقریباً به حالت افقی و پایدار می‌رسند آن نقطه تعیین‌کننده تعداد نقاط کافی جهت استفاده در بخش آموزش مدل‌سازی می‌باشد (۱۴).

### شبکه عصبی پیشرو با آموزش لوبنبرگ - مارکوآرت

از اوایل دهه ۱۹۹۰ تاکنون، شبکه‌های عصبی مصنوعی در زمینه هیدرولوژی نیز به‌طور موفقیت‌آمیز به‌کار گرفته شده‌اند (۵). حدود ۹۰٪ شبکه‌هایی که در مسائل هیدرولوژی کاربرد دارد شبکه‌های پیشرو هستند (۴). معماری معمول این شبکه متشکل از سه لایه ورودی، پنهانی و خروجی است. تعداد نرون‌های موجود در لایه ورودی و خروجی بستگی به نوع مسئله دارد ولی تعداد گره‌های لایه پنهان با سعی و خطا به‌دست می‌آید. در شکل ۲،  $X = (x_1, \dots, x_n)$  بردار ورودی‌ها،  $w_{ij}$  وزن اتصالی از  $i$ امین گره به  $j$ امین گره در لایه بعد،  $b_j$  بایاس مربوط به گره  $j$ ام،  $z_j$ ها خروجی‌های هر لایه،  $Y$  خروجی نهایی شبکه عصبی مصنوعی است. در شبکه‌های پیشرو، اتصالاتی میان گره‌ها وجود دارد، که این اتصالات در لایه‌های متفاوت قرار دارند. همچنین ورودی‌ها در لایه ورودی شبکه نمایش داده شده و عمل تحریک از ورودی به سمت خروجی شبکه شروع می‌شود (۲). جهت اطلاعات بیشتر می‌توان به مرجع (۱۱) مراجعه نمود. لازم به ذکر است که در تحقیق حاضر از تعداد نرون‌های ۱ تا ۲۵ برای لایه پنهان شبکه استفاده گردید تا از این طریق تأثیر ساختار مختلف شبکه بر عملکرد آن در شبیه‌سازی مقادیر تبخیر را مورد ارزیابی قرار داد. از آنجا که متداول‌ترین نوع توابع محرک تابع تانژانت سیگموئید می‌باشد بنابراین در این مطالعه از آن برای نگاشت اطلاعات از لایه ورودی به لایه پنهان و همچنین برای نگاشت اطلاعات از لایه پنهان به لایه خروجی استفاده شد.

که در آن  $Y_{N[i,k]}$  مقدار خروجی نظیر  $k$  امین نزدیک‌ترین همسایگی برای بردار  $x_i$  می‌باشد. به این ترتیب  $p$  مقدار برای  $\delta_M(k)$  و  $p$  مقدار برای  $\gamma_M(k)$  به‌دست آورده می‌شود. سپس بین  $p$  زوج مرتب  $\{\delta_M(k), \gamma_M(k)\}$  رابطه رگرسیونی خطی ساده به‌شرح رابطه ۵ برقرار خواهد شد طوری که در آن  $\delta$  و  $\gamma$  به ترتیب به‌عنوان متغیرهای مستقل و وابسته در نظر گرفته شده است.


$$\gamma = A\delta + \Gamma \quad (5)$$

مقدار آماره‌ی  $\Gamma$  در واقع عرض از مبدا خط رگرسیون فوق می‌باشد.  $A$  شیب خط رگرسیون بوده که نشان‌دهنده پیچیدگی مدلی است که از روی داده‌های مشاهده‌ای ایجاد می‌شود. متغیر دیگری که معمولاً در آزمون گاما به‌کار برده می‌شود متغیر بدون بعد  $V_{ratio}$  نام دارد که مقدار آن بین صفر و یک بوده و مقدار آن از رابطه ۶ محاسبه می‌شود (۷):

$$V_{ratio} = \frac{\Gamma}{\sigma^2(y)} \quad (6)$$

که در آن  $\sigma^2(y)$  واریانس داده‌های مشاهده‌ای می‌باشد. هرچه مقدار  $V_{ratio}$  به صفر نزدیک‌تر باشد ترکیب انتخابی برای مدل‌سازی، ترکیب مناسب‌تری است. ثابت شده است که اگر این مقدار از یک کم شود مقدار ضریب تبیین مدل به‌دست می‌آید.

اگر فرض شود که  $N$  تعداد متغیرهای ورودی موثر بر خروجی مدل باشد، در این صورت، تعداد  $2^N - 1$  حالت (ترکیب‌های مختلفی از متغیرهای ورودی) وجود دارد که می‌توان از هرکدام برای تهیه مدل استفاده کرد. از همه ترکیبات ممکن برای یافتن بهترین ترکیب ورودی به مدل بسیار وقت گیر و خسته‌کننده است. بنابراین، در شرایطی که تعداد متغیر ورودی زیاد باشد با استفاده از آزمون گاما می‌توان بهترین ترکیب از میان حالات ممکن را تشخیص داد. همچنین با استفاده از آزمون  $M$  تعداد بهینه داده‌های ورودی در بخش آموزش مدل‌سازی تشخیص داده می‌شود. آزمون  $M$  نشان‌دهنده سری‌های زمانی نامتناهی در توابع یکنواخت همگرا و کامل می‌باشد. در واقع برای تعیین مقدار داده‌های ورودی در دسترس برای پیش‌بینی مطلوب خروجی از آزمون  $M$  استفاده می‌شود (تکرار اجرای آزمون گاما با تعداد مختلف



شکل ۲- الف) شمای کلی شبکه‌های پیشرو سه لایه، ب) شمای زامین گره از آن  
Figure 2. A) General image Neural Network Leading three layers. B) imag image of jth node from it

### عدم قطعیت

در این تحقیق عدم قطعیت شبکه عصبی پرسپترون چندلایه مورد بررسی قرار گرفت. برای به کمیت در آوردن عدم قطعیت، ضرایب p-factor و d-factor پیشنهاد شده است. که به ترتیب برای به کمیت در آوردن قدرت واسنجی و تحلیل عدم قطعیت می‌باشند (۳). P-factor درصدی از داده‌های مشاهداتی است که در باند 95ppu قرار گرفته‌اند. مقدار ایده‌آل p-factor زمانی است که همه‌ی داده‌های مشاهداتی در باند 95PPU قرار بگیرند (P-factor → 1). از طرف دیگر d-factor برابر با میانگین فاصله بین حدود بالا و پایین باند 95PPU است که با تقسیم بر انحراف معیار داده‌های مشاهداتی نرمال شده است (۳). براساس تعریف d-factor، بدیهی است که مقدار آن مستقیماً به بزرگی عدم قطعیت خروجی‌های پیش‌بینی شده مرتبط می‌شود (۲۴). به عبارت دیگر بزرگی d-factor نشان‌دهنده بالا بودن عدم قطعیت مدل است. مناسب‌ترین مقدار برای d-factor زمانی است که به صفر نزدیک باشد (d-factor → 0). در این مطالعه از روش پیشنهادی (۱) در رابطه با تحلیل عدم قطعیت شبکه عصبی مصنوعی پرسپترون چندلایه استفاده گردید. همان‌طور که در بالا ذکر شد، برای بررسی عدم قطعیت، ابتدا باند اطمینان پیش‌بینی عدم قطعیت ۹۵٪ (95PPU) مدنظر قرار گرفت. سپس مقدار d-factor یا عرض متوسط باند اطمینان محاسبه شد. طریقه به‌دست آوردن آن در ذیل ذکر گردیده است. برای سنجش عرض متوسط باند اطمینان، شاخص فاکتور عرض باند (d-factor) مطابق رابطه زیر به‌دست می‌آید:

$$d - factor = \frac{\bar{d} x}{\sigma x} \quad (7)$$

که در آن  $\sigma x$  انحراف استاندارد متغیر مشاهده شده و  $\bar{d} x$  عرض متوسط باند اطمینان می‌باشد و به‌صورت زیر تعریف می‌شود (۱).


$$\bar{d} x = \frac{1}{n} \sum_{i=1}^K (X_U - X_L) \quad (8)$$

درصد داده‌های قرار گرفته در باند اطمینان ۹۵٪ نیز به‌صورت زیر محاسبه شده است:

$$\text{Bracketed by } 95\text{PPU} = \frac{1}{k} \text{count} (j | X_L^1 \leq X_{reg}^1 \leq X_U^1) * 100 \quad (9)$$

در رابطه بالا  $K$  تعداد داده‌های مشاهداتی،  $l$  نشان‌دهنده روز مورد نظر که از یک تا  $K$  در نظر گرفته می‌شود.  $X_L^1$  و  $X_U^1$  مشخص‌کننده حدود اطمینان در باند اطمینان ۲/۵٪ و ۹۷/۵٪  $X_{reg}^1$  مقدار ثبت‌شده در روز  $l$ ،  $j$  پارامتری است که در هر واحد زمانی با ثبت شدن هر متغیر در روز  $l$ ، واقع در بین باندهای عدم قطعیت افزایش می‌یابد. بیشترین مقدار برای  $j$  زمانی به‌دست می‌آید که  $i = k$  باشد. اگر همه مقادیر در داخل باند اطمینان عدم قطعیت قرار بگیرند  $\text{Bracketed by } 95\text{PPU} = 100$  خواهد شد (۹).

به‌طور کلی می‌توان مفهوم عدم قطعیت را در شکل ۳ نشان داد. همان‌طور که مشاهده می‌شود، پارامتر با مقدار واحد باعث ایجاد یک نتیجه واحد برای مدل می‌شود (شکل a). در صورتی که انتشار عدم قطعیت در پارامتر باعث ایجاد ناحیه‌ای از جواب می‌شود (شکل b). هنگامی که عدم قطعیت پارامترهای ورودی افزایش می‌یابد، عدم قطعیت خروجی نیز افزایش می‌یابد (شکل c). چنانچه حالت d رخ دهد مشکل واسنجی پارامترها نبوده و باید مدل مفهومی مورد ارزیابی مجدد قرار گیرد (۱).



شکل ۳- مفهوم عدم قطعیت  
Figure 3. The Concept of Uncertain

بود که مقدار این سه معیار برای آن به ترتیب، نزدیک به یک، صفر و یک باشد (۱۳).

$$CC = \sqrt{\frac{(\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y}))^2}{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad (10)$$

### معیارهای ارزیابی

با استفاده از روش‌های مختلفی می‌توان عملکرد مدل‌ها را مورد ارزیابی و مقایسه قرار داد، یکی از این روش‌ها استفاده از معیارهای ارزیابی می‌باشد. از جمله معیارهای ارزیابی پرکاربرد در علوم مهندسی آب، ضرایب همبستگی (CC)، ریشه میانگین مربعات خطا (RMSE) و معیار ناش-ساتکلیف (NS) می‌باشند که به ترتیب، در روابط ۱۰، ۱۱ و ۱۲ آورده شده‌اند. دقیق‌ترین مدل با توجه به این معیارها، مدلی خواهد

دمای متوسط، بارندگی، رطوبت نسبی متوسط، رطوبت نسبی حداکثر و رطوبت نسبی حداقل در مرتبه‌های بعدی می‌باشند. لازم به ذکر است که مقدم‌نیا و همکاران (۱۷) به قابلیت بالای آزمون گاما برای انتخاب پارامترهای بهینه در مدل‌سازی به‌منظور کاهش زمان و هزینه‌ها در مدل‌سازی اشاره کرده‌اند.

#### تعیین بهترین ترکیب

انتخاب ترکیب مناسب از پارامترهای ورودی یکی از مهم‌ترین مراحل ساخت و طراحی هر گونه مدل‌سازی ریاضی و هوشمند است. در این پژوهش با در نظر گرفتن نه پارامتر ورودی موثر بر تبخیر، تعداد ۵۱۱ ترکیب مختلف ایجاد شد. برای مدل‌سازی این پدیده با استفاده از شبکه عصبی پرسپترون چندلایه بررسی تک تک ترکیبات ایجاد شده برای یافتن بهترین ترکیب بسیار وقت‌گیر و خسته‌کننده است. بنابراین با استفاده از الگوریتم ژنتیک ترکیب‌های ممکن، ایجاد شده است (۲۶). با استفاده از الگوریتم بهینه‌سازی ژنتیک ترکیب‌های مختلف امتحان شده و با توجه به پارامترهای گاما، خطای استاندارد، شیب و نسبت  $V$  بهینه‌ترین ترکیب انتخاب شده است. تعداد بهینه تکرار ۱۰۰، جهش  $0.05$  و اندازه جمعیت ۱۵۰ به‌دست آمده است. نتایج حاصل برای چند ترکیب منتخب که دارای کمترین مقدار گاما هستند در جدول ۳ برای ایستگاه رشت و در جدول ۴ برای ایستگاه منجیل آورده شده است. براساس نتایج جدول ۳، ترکیبی که شامل پارامترهای ورودی دمای حداقل، دمای حداکثر، دمای متوسط، رطوبت نسبی حداکثر، ساعت آفتابی و سرعت باد برای ایستگاه رشت (ترکیب ۲) و دمای حداکثر، دمای حداقل، رطوبت نسبی حداکثر، رطوبت نسبی حداقل، ساعت آفتابی و سرعت باد (ترکیب ۲) و برای ایستگاه منجیل، دمای حداکثر، دمای حداقل، رطوبت نسبی حداکثر، رطوبت نسبی حداقل، ساعت آفتابی و سرعت باد (ترکیب ۲) با کمترین مقدار آماره گاما نسبت به سایر ترکیب‌های به‌عنوان بهترین ترکیب ورودی انتخاب شدند.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (11)$$

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (12)$$

در روابط بالا  $x_i$  و  $\bar{x}$  به‌ترتیب، مقادیر مشاهداتی جریان و میانگین مقادیر مشاهداتی،  $y_i$  مقادیر محاسباتی جریان،  $\bar{y}$  میانگین مقادیر محاسباتی و  $N$  تعداد داده‌ها می‌باشد. مقدار شاخص NS از ۱ تا منفی بی‌نهایت تغییر می‌کند. بازه‌های شاخص در یک شبیه‌سازی به‌ترتیب نشان‌دهنده عملکرد بسیار خوب، رضایت‌بخش و ضعیف مدل مورد استفاده می‌باشند (۱۸).

### نتایج و بحث

#### آزمون گاما

برای تعیین ترکیب ورودی جهت تخمین تبخیر از آزمون گاما استفاده شده است. بنابراین ابتدا آزمون گاما برای کل داده‌ها انجام گرفت (ردیف ۱) و سپس این آزمون براساس حذف هر یک از نه متغیر صورت گرفته است (ردیف‌های ۲ تا ۱۰) که در جدول ۲ نشان داده شده است. نتایج جدول ۲ بیانگر آن است که با حذف سرعت باد برای ایستگاه رشت، مقدار گاما دارای بیشترین مقدار می‌گردد. بنابراین با توجه به این آزمون، سرعت باد موثرترین پارامتر بر تبخیر در ایستگاه رشت می‌باشد. پارامترهای ساعت آفتابی، دمای متوسط، رطوبت نسبی حداکثر، دمای حداقل، دمای حداکثر، رطوبت نسبی حداقل، رطوبت نسبی متوسط و بارندگی به‌ترتیب در مرتبه‌های بعدی قرار دارند. همچنین برای ایستگاه منجیل، ساعت آفتابی موثرترین پارامتر بر تبخیر در این ایستگاه می‌باشد. پارامترهای سرعت باد، دمای حداقل، دمای حداکثر،

جدول ۲- نتایج آزمون گاما برای دو ایستگاه رشت و منجیل

Table 2. Results of the gamma test for Rasht and Manjil stations

ایستگاه	شماره ترکیب	متغیر غایب در مدل	گاما	شیب	خطای استاندارد	نسبت V
رشت	۱	-	۰/۰۶۳۳	۰/۰۶۴۱	۰/۰۱۳۰	۰/۲۵۳۵
	۲	دمای حداکثر	۰/۰۶۸۵	۰/۰۳۷۶	۰/۰۰۸۸	۰/۲۷۴۱
	۳	دمای حداقل	۰/۰۶۹۶۳	۰/۰۲۶۸	۰/۰۰۵۶	۰/۲۷۴۰
	۴	دمای متوسط	۰/۰۷۰۳	۰/۰۲۲۳	۰/۰۰۸۲	۰/۲۸۱۵
	۵	رطوبت نسبی حداکثر	۰/۰۷۰۳	۰/۰۱۵۶	۰/۰۰۸۱	۰/۲۸۱۴
	۶	رطوبت نسبی حداقل	۰/۰۶۴۰	۰/۰۶۷۷	۰/۰۰۵۲	۰/۲۵۶۱
	۷	بارندگی	۰/۰۵۶۴	۰/۰۱۳۸	۰/۰۰۱۰	۰/۲۲۵۵
	۸	ساعت آفتابی	۰/۰۷۱۵	۰/۰۶۳۲	۰/۰۱۲۵	۰/۲۸۵۹
	۹	سرعت باد	۰/۰۸۱۴	۰/۰۱۰۷	۰/۰۰۵۴	۰/۳۲۵۹
	۱۰	رطوبت نسبی متوسط	۰/۰۶۲۰	۰/۰۷۸۰۰	۰/۰۰۴۶	۰/۲۴۸۰
منجیل	۱	-	۰/۰۳۷۰	۰/۰۱۹۰۱	۰/۰۰۹۱	۰/۱۱۰۱
	۲	دمای حداکثر	۰/۰۲۸۱	۰/۰۱۶۲	۰/۰۰۱۱	۰/۱۱۰۹
	۳	دمای حداقل	۰/۰۳۱۲	۰/۰۱۴۰	۰/۰۰۱۲	۰/۱۲۰۵
	۴	دمای متوسط	۰/۰۲۷۵	۰/۰۲۵۶	۰/۰۰۱۰	۰/۱۱۰۰
	۵	رطوبت نسبی حداکثر	۰/۰۲۶۳	۰/۰۳۹۲	۰/۰۰۳۱	۰/۱۰۴۵
	۶	رطوبت نسبی حداقل	۰/۰۲۶۲	۰/۰۳۱۴	۰/۰۰۲۲	۰/۱۰۴۳
	۷	بارندگی	۰/۰۲۳۳	۰/۰۲۶۲	۰/۰۰۰۹	۰/۱۱۰۱
	۸	ساعت آفتابی	۰/۰۳۳۰	۰/۰۰۹۱	۰/۰۰۲۱	۰/۱۳۳۲
	۹	سرعت باد	۰/۰۳۲	۰/۰۱۱۰	۰/۰۰۱۰	۰/۱۲۴۳
	۱۰	رطوبت نسبی متوسط	۰/۰۲۶۹	۰/۰۲۵۰	۰/۰۰۱۳	۰/۱۰۵۵

جدول ۳- نتایج آزمون گاما برای ترکیب‌های منتخب ایستگاه رشت

Table 3. Result of Gamma test for the compound selection Rasht station

ردیف	پارامترها	V	خطای استاندارد	شیب	گاما
۱	دمای حداقل، دمای حداکثر، دمای متوسط، رطوبت نسبی حداکثر، رطوبت نسبی حداقل، ساعت آفتابی، سرعت باد	۰/۲۰	۰/۰۰۵	۰/۲۰	۰/۰۵
۲	دمای حداقل، دمای حداکثر، دمای متوسط، رطوبت نسبی حداکثر، ساعت آفتابی، سرعت باد	۰/۱۸	۰/۰۱	۰/۳۸	۰/۰۴۶
۳	دمای حداقل، دمای متوسط، رطوبت نسبی حداکثر، ساعت آفتابی، سرعت باد، رطوبت نسبی متوسط	۰/۱۹	۰/۰۱	۰/۲۷	۰/۰۴۸
۴	دمای حداقل، رطوبت نسبی حداکثر، ساعت آفتابی، سرعت باد، رطوبت نسبی متوسط، رطوبت نسبی حداقل	۰/۱۹	۰/۰۰۵	۰/۲۶	۰/۰۴۹

جدول ۴- نتایج آزمون گاما برای ترکیب‌های منتخب ایستگاه منجیل


Table 4. Result of Gamma test for the compound selection Manjil station

ردیف	پارامترها	V	خطای استاندارد	شیب	گاما
۱	دمای حداکثر، دمای حداقل، دمای متوسط، رطوبت نسبی حداکثر، رطوبت نسبی متوسط، بارندگی، ساعت آفتابی، سرعت باد	۰/۱۰۴	۰/۰۰۲	۰/۰۳۱	۰/۰۲۶
۲	دمای حداکثر، دمای حداقل، رطوبت نسبی حداکثر، رطوبت نسبی حداقل، ساعت آفتابی، سرعت باد	۰/۱۰۳	۰/۰۰۲	۰/۰۴۹	۰/۰۲۵
۳	دمای حداکثر، رطوبت نسبی حداکثر، رطوبت نسبی حداقل، ساعت آفتابی، سرعت باد	۰/۱۰۴	۰/۰۰۲	۰/۰۸۰	۰/۰۲۶
۴	دمای حداکثر، دمای حداقل، رطوبت نسبی حداقل، رطوبت نسبی ماکزیمم، بارندگی، ساعت آفتابی، سرعت باد	۰/۱۰۵	۰/۰۰۱	۰/۰۳۶	۰/۰۲۶


### تعیین تعداد داده‌های مورد نیاز

یکی از چالش‌های اصلی در مدل‌سازی پدیده‌ها، ارزیابی اطلاعات موجود و کفایت داده‌ها است. به بیان دیگر، چه تعداد الگوار مجموعه الگوهای ورودی باید برای مدل‌سازی استفاده شود؟ اگرچه به‌طور کلی با افزودن اطلاعات بیشتر، عملکرد مدل در مرحله واسنجی بهبود می‌یابد، اما این افزایش به چه میزان می‌تواند عملکرد مدل را بهبود بخشد؟ علاوه بر آن، با استفاده از نمودار آزمون M می‌توان تعداد داده‌های معنی‌دار برای ایجاد یک مدل هموار (قابل اعتماد و غیر پیچیده) به‌منظور پیش‌بینی تبخیر روزانه و چگونگی تغییرات خطای

استاندارد را تشخیص و مقدار آماره گاما با افزایش تعداد داده‌ها را نشان داد (۹). با توجه به شکل ۴ می‌توان مشاهده نمود که آماره گاما و خطای استاندارد تقریباً در اطراف نقطه ۳۲۵۰ برای ایستگاه رشت و در شکل ۵ در نقطه ۱۶۰۰ به حالت پایدار می‌رسند که با افزایش تعداد داده‌ها منحنی گاما و خطای استاندارد، تغییرات چندانی به‌خود نمی‌بیند. بنابراین تعداد داده‌های معنی‌دار برای آموزش شبکه عصبی مصنوعی ۳۲۵۰ و ۱۶۰۰ مجموعه داده به ترتیب برای ایستگاه رشت و منجیل می‌باشد.



شکل ۴- آزمون M مقادیر گاما برای مدل منتخب در ایستگاه رشت  
Figure 4. M test of the selection Model on Rasht station



شکل ۵- آزمون M مقادیر گاما برای مدل منتخب در ایستگاه منجیل  
Figure 5. M test of the selection Model on Manjil station

### نتایج عدم قطعیت

معماری پهنه مدل که در بخش قبل تعیین شده بود در این بخش مورد استفاده قرار گرفت. بررسی باند پیش‌بینی عدم قطعیت ۹۵٪ (95PPU) نشان می‌دهد که منجیل دارای p-factor ۴۵ درصد ورشت دارای p-factor ۲۵ درصد می‌باشد. همچنین مقدار d-factor برای منجیل ۰/۳۳ و برای رشت ۰/۳ به دست آمد که نتایج در جدول ۵ آورده شده است. در این مطالعه همان‌طور که ذکر شد مقادیر d-factor برای هر دو ایستگاه مقادیر کوچکی به دست آمد که نشان‌دهنده پایین بودن عدم قطعیت مدل مذکور می‌باشد. بنابر نتایج، مقدار p-factor پایین بوده است. به عبارت دیگر اکثر داده‌های اندازه‌گیری شده در باند 95PPU قرار نگرفته‌اند. دلایل آن را می‌توان به ترتیب اهمیت اشاره کرد:

- ۱- عدم قطعیت‌های کوچک در پارامترهای ورودی (۲۲).
- ۲- ضعف شبکه عصبی مصنوعی در پیش‌بینی تبخیر، کاهش عرض باند پیش‌بینی عدم قطعیت ۹۵ درصد شبکه عصبی با افزایش افق پیش‌بینی می‌باشد. این امر برخلاف اصول احتمالاتی بوده و نشان می‌دهد که شبکه عصبی در

### نتایج مدل شبکه عصبی مصنوعی - آزمون گاما

بر اساس نتایج پارامترهای موثر به دست آمده از روش آزمون گاما بهترین ترکیب از میان پارامترهای ورودی برای مدل شبکه عصبی مصنوعی - آزمون گاما مشخص گردید. ترکیب به کار رفته برای مدل شبکه عصبی مصنوعی - آزمون گاما در جدول ۳ برای ایستگاه رشت و در جدول ۴ برای ایستگاه منجیل آورده شده است. با توجه به جدول ۵ برای ایستگاه رشت مدل مذکور عملکرد مناسبی را نشان داده است. مجذور میانگین مربعات خطا در این ایستگاه ۰/۹۵، ضریب همبستگی ۰/۸۶ و ضریب ناش- ساتکلیف ۰/۷۴ بوده است. برای ایستگاه منجیل مدل دارای مجذور میانگین مربعات خطای ۱/۵۸، ضریب همبستگی ۰/۹۴ و ضریب ناش- ساتکلیف ۰/۸۹ بوده است. با توجه به ضرایب ناش- ساتکلیف می‌توان گفت که مدل مذکور دارای عملکرد بسیار خوبی در هر دو ایستگاه می‌باشد. همچنین با توجه به شکل‌های ۶ و ۷ می‌توان گفت که داده‌های مشاهداتی و داده‌های تخمین زده شده بسیار نزدیک به هم هستند، که نشان‌دهنده عملکرد مناسب مدل شبکه عصبی مصنوعی - آزمون گاما می‌باشد.


عرض بیشتری نسبت به ایستگاه رشت است. بنابراین d-factor آن از ایستگاه رشت بزرگتر می‌باشد. در واقع می‌توان گفت هرچه عرض باند پیش‌بینی عدم قطعیت ۹۵ درصد بیشتر باشد d-factor نیز بیشتر و هرچه عرض باند کمتر، d-factor نیز کمتر خواهد بود که همانند نتایج به‌دست آمده از تحقیق نوری و همکاران (۱۹) است. در حالت کلی می‌توان نتیجه گرفت که مقدار d-factor در مدل شبکه عصبی مصنوعی- آزمون گاما برای هر دو ایستگاه در مرحله صحت سنجی نزدیک به مقدار توصیه شده (صفر) بود. بنابراین مدل در پیش‌بینی تخبیر روزانه دارای عدم قطعیت پایینی می‌باشد. لازم به ذکر است که محاسبات مربوط به عدم قطعیت در نرم‌افزار متلب انجام شده است.

پیش‌بینی‌های بلندمدت دارای ضعف و نوعی بی‌تفاوتی به داده‌ها است (۸).

۳- ضعف در قدرت واسنجی مدل می‌باشد (۳).  
به‌طور کلی ساخت سدها، مخازن، جاده‌ها، تغییر کاربری اراضی، تغییر اقلیم، پوشش منطقه و... می‌تواند بر هیدرولوژی محلی منطقه در طولانی مدت تاثیر گذار باشد، این از مهم‌ترین و اغلب یکی از منابع فراموش شده عدم قطعیت در مدل‌سازی هیدرولوژیک مقیاس‌های بزرگ می‌باشد. همگام با افزایش توسعه در مدیریت منابع آب، مدل‌سازی هیدرولوژی سخت خواهد شد و به در دسترس بودن جزئیات فعالیت‌های مدیریتی وابسته خواهد بود. با توجه به شکل‌های ۶ و ۷ در بخش صحت‌سنجی برای ایستگاه منجیل باند 95PPU دارای

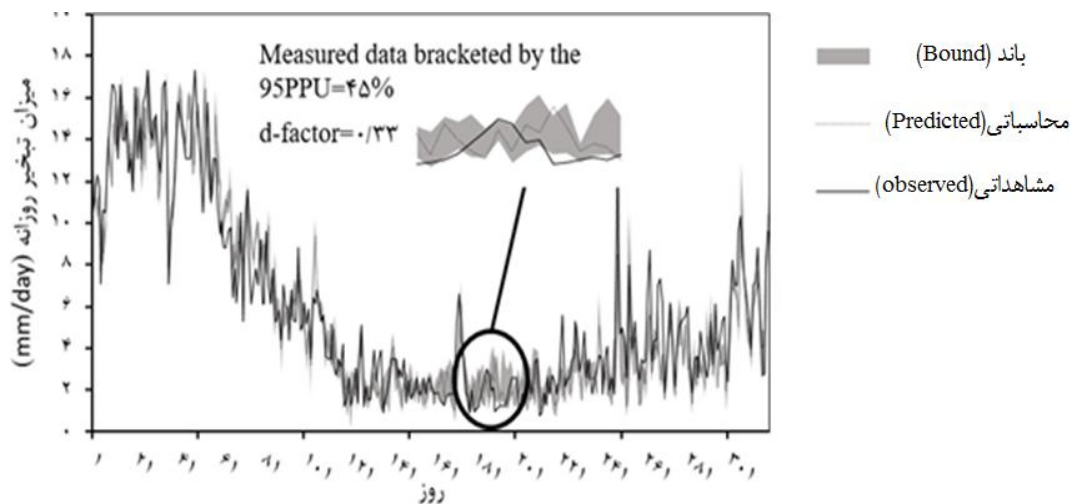
جدول ۵- نتایج مدل شبکه عصبی مصنوعی- آزمون گاما همراه با نتایج عدم قطعیت مدل  
Table 5. Results of ANN-GT Model with Results of Model's uncertainty

معماری شبکه	صحت سنجی				آموزش			مدل	ایستگاه	
	P-Factor/%	d-Factor	NS	RMSE	CC	NS	RMSE			CC
۶-۱۲-۱	۲۵	۰/۳	۰/۷۴	۰/۹۵	۰/۸۶	۰/۷۶	۰/۹۳	۰/۸۷	ANN-GT	رشت
۶-۱۲-۱	۴۵	۰/۳۳	۰/۸۹	۱/۵۸	۰/۹۴	۰/۹۰	۱/۵۶	۰/۹۵	ANN-GT	منجیل



شکل ۶- باند عدم قطعیت ۹۵ درصد مدل شبکه عصبی مصنوعی-آزمون گاما همراه با نمودار مشاهداتی و محاسباتی در دوره صحت‌سنجی (ایستگاه رشت)

Figure 6. 95PPU bound of ANN-GT Model with observed and predicted Chart in test period(Rasht station)



شکل ۷- باند عدم قطعیت ۹۵ درصد شبکه عصبی مصنوعی-آزمون گاما همراه با نمودار مشاهداتی و محاسباتی در دوره صحت‌سنجی (ایستگاه منجیل)

Figure 7. 95PPU bound of ANN-GT Model with observed and predicted chart in test period (Manjil station)

بررسی عدم قطعیت مدل شبکه عصبی مصنوعی- آزمون گاما جهت پیش‌بینی تبخیر روزانه در ایستگاه‌های رشت و منجیل صورت گرفت. بنابراین در مرحله بعد آنالیز عدم قطعیت مدل مذکور انجام شد. برای بررسی عدم قطعیت مدل از دو شاخص  $d$ -factor و  $p$ -factor استفاده گردید. همان‌طور که در جدول ۵ ذکر شده است مقدار  $d$ -factor برای هر دو ایستگاه مقادیر مطلوبی (نزدیک به صفر) به‌دست آمد که نشان‌دهنده عدم قطعیت پایین در مدل مفهومی می‌باشد که با نتایج قربانی و همکاران (۱۰) مبنی بر پایین بودن عدم قطعیت شبکه عصبی مصنوعی و عملکرد مناسبش مطابقت دارد. اما شاخص  $p$ -factor نشان داد که تعداد کمی از داده‌ها در داخل باند پیش‌بینی عدم قطعیت ۹۵ درصد قرار گرفته است همانند نتایج اشکول و عباسپور (۲۳) و فرخ‌نیا و مرادی (۸) که دلیل اصلی آن عدم قطعیت‌های کوچک در پارامترها می‌باشد. به‌طور کلی می‌توان بیان نمود که نتایج به‌دست آمده از این تحقیق نشان‌دهنده عدم قطعیت پایین و قابل قبول مدل مذکور بوده که بیانگر پایداری و اطمینان‌پذیری این مدل در برآورد تبخیر روزانه در ایستگاه‌های مذکور است. بنابراین می‌توان در آینده برای موارد مطالعاتی و کاربردی که در اختیار داشتن تبخیر مورد نیاز باشد، از مدل شبکه عصبی مصنوعی- آزمون گاما (ANN-GT) در دو ایستگاه مذکور استفاده نمود و همچنین می‌توان با افزایش دقت و بالا بردن کیفیت داده‌ها عملکرد این مدل را بهبود بخشید.

اندازه‌گیری تبخیر روزانه بسیار زمان‌بر و هزینه‌بردار است. به‌همین دلیل استفاده از مدلی که توانایی مدل‌سازی دقیق این پدیده دینامیک و پیچیده را داشته باشد به‌عنوان جایگزینی مناسب سال‌هاست که مدنظر محققان مختلف بوده است. در این راستا هدف اصلی مقاله حاضر ارایه مدلی برای این منظور در ایستگاه‌های مورد مطالعه رشت و منجیل بوده است. به منظور نیل به اهداف ذکر شده ابتدا مدل ANN-GT با استفاده از اطلاعات موجود مراجع علمی، توسعه داده شد. از آنجایی که ورود همه ترکیبات به مدل‌های برآورد کننده مشکل و وقت‌گیر است، در این تحقیق از آزمون گاما به‌منظور تعیین بهترین ترکیب در پیش‌بینی تبخیر روزانه استفاده گردید. بر اساس داده‌های موجود ترکیب شامل پارامترهای ورودی دمای حداکثر، دمای متوسط، رطوبت نسبی حداکثر، ساعت آفتابی و سرعت باد برای ایستگاه رشت و برای ایستگاه منجیل دمای حداکثر، دمای حداقل، رطوبت نسبی حداکثر، رطوبت نسبی حداقل، دمای حداقل، رطوبت نسبی حداکثر، رطوبت نسبی حداقل، ساعت آفتابی و سرعت باد با کمترین مقدار آماره گاما نسبت به سایر ترکیب‌ها به‌عنوان بهترین ترکیب ورودی به مدل انتخاب گردیدند. نتایج به‌دست آمده برای شبکه عصبی مصنوعی-آزمون گاما نشان داد که مدل همچون تحقیق سیفی و همکاران (۲۳) و شریفی و همکاران (۲۵) از دقت کافی برخوردار بوده است. نکته دیگر مشکل وجود عدم قطعیت در ارایه نتایج است که در این مقاله،

## منابع

1. Abbaspour, K.C., J. Yang, I. Maximov, R. Siber, K. Bogne, J. Mieleitne, J. Zobrist and R. Srinivasan. 2007. Modeling hydrology and water quality in the pre-alpine/alpine Thur watershed using SWAT. *Journal of Hydrology*, 333: 413-430.
2. ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. 2000. Artificial Neural Networks in Hydrology. I: Preliminary Concepts, *Journal of Hydrology Engineering*, 2: 115-123.
3. Alizadeh, A., A. Eizad, K. Davar, A.N. Ziaie, S. Akhavan and Z. Hamidi. 2013. Estimation of actual evapotranspiration at regional-annual scale using SWAT. *Iranian Journal of Irrigation and Drainage*, 2: 243-258 (In Persian).

4. Coulibaly, P., F. Anctil and B. Bobée. 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach, *Journal of Hydrology*, 230: 244-257.
5. Dawson, C.W., R.J. Abrahart, A.Y. Shamseldin and R.L. Wibly. 2006. Flood estimation at ungauged sites using artificial neural networks, *Journal of Hydrology*, 319: 391-409.
6. Durrant, P.J. 2001. Win\_gamma TMA non-linear data analysis and modeling tool with applications to flood prediction. Ph.D. Thesis, Department of Computer Science, Cardiff University Wales, UK, 254 pp.
7. Evans, D. and A.J. Jones. 2002. A proof of the gamma test. *Proceedings of Royal Society, Series A*, 458: 2759-2799.
8. Farokhnia, A. and S. Morid. 2010. Uncertainty analysis of artificial neural networks and neuro-fuzzy models in river flow forecasting. *Journal of Iran Water Resources Research*, 3: 14-27 (In Persian).
9. Ghobaie Sogh, M.A., A. Mosaedi and A.A. Dehghani. 2010. Solar radiation data and their intelligent modeling based on gamma test with evaluation of calibrated empirical equations. *Journal of Water and Soil Conservation*, 18: 208-185.
10. Ghorbani, M.A., H. Ahmadzadeh, M. Isazadeh and O. Terzi. 2016. A comparative study of artificial neural network (MLP, RBF) and support vector machine models for river flow prediction. *Environmental Earth Science*, 75: 476-490.
11. Ghorbani, M.A., R. Khatibi, B. Hosseini and M. Bilgili. 2013. Relative importance of parameters affecting wind speed prediction using artificial neural networks. *Theoretical and Applied Climatology*, 114: 107-115.
12. Goyal, M.K., B. Bharti, J. Quilty, J. Adamowski and A. Pandey. 2014. Modeling of daily pan evaporation in sub-tropical climates using ANN, LS-SVR, Fuzzy Logic, and ANFIS. *Expert System with Application*, 41: 5267-5276.
13. Isazadeh, M., H. Ahmadzadeh and M.A. Ghorbani. 2016. Assessment of kernrl functions performance in river flow estimation using support vector machine. *Journal of Water and Soil Conservation*, 23: 69-89 (In Persian).
14. Jones, A.J. 2004. New tools in non-linear modeling and prediction. *Computational Management Science*, 1: 109-149.
15. Kisi, O., O. Genc, S. Dinc and M. Zounemat-Kermani. 2016. Daily pan evaporation modeling using chi-squared automatic interaction detector, neural networks. *Classification and Regression tree Computers and Electronics in Agriculture*, 122: 112-117.
16. Malik, A. and A. Kumar. 2015. Pan evaporation simulation based on daily meteorological data using soft computing techniques and multiple linear regression. *Water Resource Management*, 29: 1859-1872.
17. Moghaddamnia, A., M. Ghafari Gousheh, J. Piri, S. Amin and D. Han. 2009. Evaporation estimation using artificial neural networks and adaptive neurofuzzy inference system techniques. *Advance. Water Resource Management*, 32: 88-97.
18. Nash, J.E. and I.V. Sutcliffe. 1970. River flow forecasting through conceptual models, Part I, A discussion of principles, *Journal of Hydrology*, 10:282-290.
19. Noori, R., G. Hoshyaripour, K. Ashrafi and B. Nadjar Araabi. 2010. Uncertainty analysis of developed ANN and ANFIS models in prediction of carbon monoxide daily concentration. *Atmospheric Environment*, 44: 476-482.
20. Nourani, V. and M.S. Fard. 2012. Sensitivity analysis of the artificial neural network outputs in simulation of the evaporation process at different climatologic regimes. *Advance Engineering Software*, 47: 127-146.
21. Ribot, J.C., A.R. Magalhães and S. Panagides. 2005. *Climate variability, climate change and social vulnerability in the semi-arid tropics*, cambridge university press, 170 pp.
22. Schuol, J. and K.C. Abbaspour. 2006. Calibration and uncertainty issues of a hydrological model SWAT applied to West Africa. *Advances in Geoscience*, 9: 137-143.
23. Seifi, A., S.M. Mirlifi and H. Riahi. 2012. Introduction and application of least square support vector machine (LSSVM) for simulation of reference evapotranspiration and uncertainly analysis of results (case study: Kerman city). *Journal of Irrigation and Water*, 13: 67-79 (In Persian).
24. Shafieai, M., H. Ansari, K. Davari and B. Ghahreman. 2012. Calibration and uncertainty analysis of a semi-distributed model in a semi-arid area, case study Neyshabur watershed. *Journal of Science and Technology of Agriculture and Natural Resources, Soil and Water Sciences*, 64: 137-148 (In Persian).
25. Sharifi, A., Y. Dinpazhouh, A. Fakheryfard and A. Moghadamni. 2012. Optimum combination of variables for run off simulation in Amameh watershed using gamma test. *Journal of Knowledge of Soil and Water*, 4: 59-72 (In Persian).
26. Zamanian, M., R. Fatahi, A. Fatahi and F. Hossein Pour. 2011. Input parameters preprocessing in artificial neural network and adaptive neuro-fuzzy inference system using stepwise regression and gamma test techniques for estimation of daily evaporation. *Journal of Irrigation and Water*, 9: 63-78 (In Persian).

## Uncertainty of Artificial Neural Networks for Daily Evaporation Prediction (Case Study: Rasht and Manjil Stations)

Seyed Mostafa Biazar<sup>1</sup>, Mohammad Ali Ghorbani<sup>2</sup> and Kaka Shahedi<sup>3</sup>

---

1- M.Sc. Student of Water Resources, University of Tabriz (Corresponding author: seyedmostafa.b@gmail.com)

2- Associate Professor of Water Resources, University of Tabriz

3- Associate Professor of Watershed, Sari of Agricultural Sciences and Natural Resources University

Received: October 18, 2016

Accepted: May 3, 2017

---

### Abstract

This research uses the multilayer perceptron (MLP) model to predict daily evaporation at two synoptic stations located in Rasht and Manjil, Guilan province, in north-west of Iran. Initially the most important combinations of climatic parameters for both of the stations were identified using the gamma test; and daily evaporation were modeled based on the obtained optimal combination. The results of the artificial neural network- Gamma Test (ANN-GT) model are evaluated using the root mean square errors (RMSE), correlation coefficient and Nash-Sutcliffe (NS) criteria. The results showed that the ANN-GT model for Rasht station with a correlation coefficient 0.86, root mean square error 0.95 and Nash-Sutcliffe criteria 0.74 and for Manjil station with correlation coefficient 0.94, root mean square error 1.58 and Nash-Sutcliffe criteria 0.89 has an acceptable performance in predicting daily evaporation. To evaluate the uncertainty, we considered a percentage of data which were included in 95 percent of uncertainty (p-factor) and the average width of the 95ppu band (d-factor). Regarding the uncertainty results, the average width of 95PPU bound were obtained as 0.33 and 0.3 for the Manjil and Rasht stations, respectively. This shows the low uncertainty level of the ANN-GT model for predicting daily evaporation at both of the stations. Furthermore, the percentage of the observed data at 95PPU band was low and equal to %25 and %45 for the Rasht and Manjil stations, respectively. The reason for these low values can be due to low uncertainty in the parameters.

**Keywords:** Artificial neural network, Daily evaporation, Gamma test, Guilan, Uncertainty