



دانشگاه آزاد اسلامی واحد اهر  
فصلنامه‌ی علمی-پژوهشی فضای جغرافیایی

سال هجدهم، شماره‌ی ۶۳  
پاییز ۱۳۹۷، صفحات ۱۲۴-۱۰۷

\*سیدمصطفی بی‌آزار<sup>۱</sup>  
محمدعلی قربانی<sup>۲</sup>  
صابره دربندی<sup>۳</sup>

## استفاده از روش‌های نوین برای تعیین ورودی‌های موثر در تخمین تبخیر از تشت

تاریخ پذیرش: ۱۳۹۵/۱۱/۱۰

تاریخ دریافت: ۱۳۹۵/۰۹/۰۳

### چکیده

در این تحقیق تخمین تبخیر از تشت سه ایستگاه سینوپتیک آستارا، کیشهر و تالش واقع در استان گیلان با استفاده از شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) انجام گرفته است. از دو روش تحلیل مؤلفه اصلی (PCA) و آزمون گاما (GT) برای پیش‌پردازش داده‌ها و تعیین ورودی مدل‌ها استفاده گردید. با توجه به نتایج، برای ایستگاه تالش ۶ متغیر ورودی و برای ایستگاه کیشهر و آستارا ۵ متغیر ورودی توسط آزمون گاما انتخاب شد. در روش تحلیل مؤلفه‌های اصلی نیز برای ایستگاه سینوپتیک آستارا و کیشهر، پنج مؤلفه اصلی و برای ایستگاه تالش چهار مؤلفه اصلی انتخاب شده است. نتایج مدل‌سازی حاکی از این است که مدل شبکه عصبی مصنوعی مبتنی بر تحلیل مؤلفه اصلی (PCA-ANN) در ایستگاه‌های آستارا و تالش به ترتیب با مجذور میانگین مربعات خطای ۰/۹۵۷ و ۱/۰۰۴، ضریب نش-ساتکلیف ۰/۸۱۵ و ۰/۷۵۶ و ضریب همبستگی ۰/۹۰۳ و ۰/۸۷۰ و مدل ماشین بردار پشتیبان مبتنی بر آزمون گاما (GT-SVM) در ایستگاه کیشهر با مجذور میانگین مربعات خطای ۱/۲۹۵، ضریب نش ساتکلیف ۰/۶۸۳ و ضریب همبستگی ۰/۸۲۵ را می‌توان به‌عنوان مدل‌های منتخب برای ایستگاه‌های مذکور انتخاب کرد. در نهایت با توجه به نتایج می‌توان چنین نتیجه گرفت که روش‌های استفاده شده پیش‌پردازش داده‌ها در این تحقیق برای پیش‌بینی

E-mail: seyedmostafa.b@gmail.com

\*۱- دانشجوی دکتری علوم و مهندسی آب دانشگاه تبریز. (نویسنده مسئول).

۲- عضو هیات علمی گروه مهندسی آب دانشگاه تبریز.

۳- عضو هیات علمی گروه مهندسی آب دانشگاه تبریز.

تبخیر از تشت با یکدیگر اختلاف چندانی ندارند و هر دو روش به خوبی عمل کرده‌اند. همچنین مدل SVM در تمام تخمین‌ها نسبت به مدل ANN عملکرد قابل قبول‌تری داشته است.

**کلید واژه‌ها:** استان گیلان، آزمون گاما، تبخیر از تشت، تحلیل مؤلفه اصلی، شبکه عصبی مصنوعی، ماشین بردار پشتیبان.

#### مقدمه

تبخیر یکی از مهم‌ترین پارامترهایی است که متأثر از متغیرهای زیادی همچون بارندگی، سرعت باد، ساعت آفتابی، رطوبت نسبی و ... می‌باشد (Sing and Xu, 1997: 318). تخمین تبخیر در همه مناطق که دارای منابع آب سطحی می‌باشند، به دلیل تأثیرگذاری آن بر روی دریاچه سد، مدل‌سازی بارش-رواناب، عملکرد حوضه رودخانه، مدیریت آب-آبیاری برای محاسبه میزان آب مورد نیاز گیاه و برنامه‌ریزی آن و ... بسیار مهم است. تبخیر می‌تواند به طور قابل توجهی در بیلان آب مربوط به رودخانه یا مخزن اثر بگذارد و شاید در پایین آمدن سطح آب نیز مؤثر باشد (McCuen, 1998: 840). با توجه به اینکه پیچیدگی سیستم‌های هیدرولوژیکی از نظر تعیین تمام پارامترهای دخیل و نقص اطلاعات آماری، امکان مدل‌سازی کامل سیستم‌های هیدرولوژیکی را غیرممکن می‌سازد. در چنین شرایطی استفاده از مدل‌سازی سیستمی که مبتنی بر روابط ریاضی باشد، مورد توجه قرار می‌گیرد (Kisi et al, 2016: 114).

از مطالعات صورت گرفته در این زمینه می‌توان به موارد زیر اشاره نمود: (Seifi et al (2013) تحقیقی در زمینه معرفی و کاربرد حداقل مربعات ماشین بردار پشتیبان در برآورد تبخیر-تعرق مرجع و تحلیل عدم قطعیت نتایج آن در محدوده شهر کرمان انجام دادند. در این تحقیق از روش حداقل مربعات ماشین بردار پشتیبان مبتنی بر آزمون گاما با هسته‌های تابع پایه شعاعی، خطی و چندجمله‌ای برای محاسبه تبخیر-تعرق لایسیمیتری استفاده شده است. نتایج با دو مدل شبکه عصبی مصنوعی ( $ANN^4$ )، سیستم استنتاجی تطبیقی-عصبی فازی و داده‌های لایسیمیتری مقایسه گردید. نتایج حداقل مربعات ماشین بردار پشتیبان با هسته تابع پایه شعاعی بیانگر برتری این مدل نسبت به سایر مدل‌ها بوده است. همچنین تحلیل عدم قطعیت در این تحقیق نشان داد که مدل حداقل مربعات ماشین بردار پشتیبان عدم قطعیت کم‌تری نسبت به مدل‌های دیگر دارد. (Shikho Ileslami et al (2013) تبخیر و تعرق گیاه مرجع را با استفاده از روش آنالیز مؤلفه‌های اصلی ( $PCA^5$ ) و توسعه مدل رگرسیون خطی چندگانه در استان مشهد بررسی کردند. در این تحقیق از داده‌های ایستگاه سینوپتیک مشهد در مقیاس روزانه و در دوره آماری (۲۰۰۵-۱۹۹۱) استفاده شده است. آن‌ها تأثیر نسبی پارامترهای دما، رطوبت نسبی، ساعت آفتابی و سرعت باد در ارتفاع دومتری از سطح زمین را بر این پدیده با دو مدل رگرسیون خطی چندگانه و رگرسیون خطی چندگانه مبتنی بر تحلیل مؤلفه اصلی، مورد بررسی قرار دادند. نتایج نشان داد که مدل رگرسیون خطی چندگانه مبتنی بر تحلیل مؤلفه اصلی دارای عملکرد مناسب‌تری نسبت به مدل رگرسیون

4- Artificial Neural Network

5- Principal component analysis

خطی چندگانه می‌باشد. (Ghareman and Gharakhani (2013) مقایسه روش‌های شبکه عصبی مصنوعی و رگرسیون چندگانه را در برآورد تبخیر از تشت مورد بررسی قرار دادند. برای تعیین مهم‌ترین عوامل هواشناسی موثر در تخمین تبخیر از روش تحلیل مولفه‌های اصلی استفاده نمودند. در این تحقیق تخمین از تشت در چهار ایستگاه سینوپتیک کرج، اهواز، شیراز و تبریز در بازه زمانی (۱۹۸۶ تا ۲۰۰۵) به کمک مدل‌های مذکور انجام شده است. نتایج روش شبکه عصبی مصنوعی مبتنی بر تحلیل مولفه اصلی نشان داد که مقادیر برآوردی با مقادیر مشاهداتی تطابق مناسبی داشته است. روش رگرسیون چندگانه نیز نتایج قابل قبولی در برآورد تبخیر از تشت در هر چهار ایستگاه مورد مطالعه را نشان داده است. درکل مدل رگرسیون چندگانه عملکرد بهتری نسبت به مدل شبکه عصبی مصنوعی داشته است. (Seyedian (2014) از روش‌های نوین در تعیین پارامترهای موثر بر آبشستگی پایه پل استفاده کرد. او با استفاده از سه روش آزمون گاما، تحلیل مولفه اصلی و رگرسیون گام‌به‌گام پارامترهای موثر بر آبشستگی را از بین کل پارامترها انتخاب کرده است. سپس با استفاده از مدل ماشین بردار پشتیبان ( $SVM^1$ ) اقدام به شبیه‌سازی و تخمین عمق آبشستگی با استفاده از پارامترهای تعیین شده توسط سه روش ذکر شده نمود. نتایج نشان داد مدل SVM قابلیت بالایی در تخمین عمق آبشستگی دارد. (Hooshangi et al (2014) در تحقیقی بهینه‌سازی تعداد پیرومترها در پیش‌بینی سطح آب‌های زیرزمینی با روش‌های PCA و زمین‌آمار را مورد بررسی قرار دادند. ابتدا با اخذ مشاهدات ۷۵ چاه مشاهداتی مربوط به سفره آزاد دشت تبریز و ارزیابی عملکرد پنج روش مختلف درون‌یابی به این نتیجه رسیدند که روش کریجینگ عمومی نتایج بهتری به دست آورده است. آن‌ها در مرحله دوم با دو روش خطای اعتبار سنجی متقابل نقاط و تحلیل مولفه اصلی، تعدادی از نقاط را از چرخه تشکیل سطح، خارج و در نهایت با توجه به مجذور میانگین مربعات خطا سطوح ایجاد شده عملکرد دو روش را با هم مقایسه نمودند. بررسی‌ها نشان داد که روش PCA در مقایسه با روش خطای اعتبار سنجی متقابل از اعتبار بیشتری برخوردار بوده است. (Noori et al (2010) روش آزمون گاما و تحلیل مولفه‌های اصلی را بر روی عملکرد شبکه عصبی مصنوعی در پیش‌بینی تولید پسماند جامد هفتگی در شهر مشهد مورد ارزیابی قرار دادند. هدف آن‌ها توسعه یک مدل شبکه عصبی مصنوعی با ساختار ساده و دقت مناسب بوده است. در این تحقیق از روش تحلیل مولفه‌های اصلی و آزمون گاما برای کاهش تعداد متغیرهای ورودی استفاده شده است. نتایج مقایسه مدل‌های شبکه عصبی مصنوعی و شبکه عصبی مصنوعی-تحلیل مولفه اصلی و شبکه عصبی مصنوعی-آزمون گاما نسبت به مدل شبکه عصبی مصنوعی مؤثرتر بوده‌اند. (Azid et al (2014) آستانه آلودگی هوا را با استفاده از شبکه عصبی مصنوعی و تحلیل مولفه اصلی در مالزی مورد بررسی قرار دادند. آن‌ها هشت پارامتر کیفیت هوا را برای ده ایستگاه از سازمان محیط‌زیست برای هفت سال (۲۰۰۵-۲۰۱۱) اخذ نمودند. در این تحقیق از ترکیب شبکه عصبی مصنوعی و تحلیل مولفه اصلی برای تخمین شاخص آلوده کننده هوا (API) استفاده شده است. نتایج نشان دهنده عملکرد مناسب مدل شبکه عصبی مصنوعی-تحلیل مولفه اصلی بوده است. (Tezal and Buyukyildiz (2015) با استفاده از شبکه

عصبی مصنوعی و ماشین بردار پشتیبان تبخیر ماهانه ایستگاه هواشناسی بیسپهر را پیش‌بینی نمودند. در این تحقیق از داده‌های دما، رطوبت نسبی، سرعت باد و بارندگی در دوره آماری (۱۹۷۲ تا ۲۰۰۵) استفاده شده است. آن‌ها از مدل ماشین بردار پشتیبان با هسته تابع پایه شعاعی و از شبکه عصبی پرسپترون چند لایه استفاده نمودند. نتایج نشان‌دهنده عملکرد مناسب مدل شبکه عصبی پرسپترون چند لایه با الگوریتم آموزش گرادینان مزدوج کوچک بوده است. Tian et al (2016) عمق آب زیرزمینی را با استفاده از مدل‌های داده محور به کمک آزمون گاما تخمین زده‌اند. در این تحقیق از سه مدل داده محور برای تخمین عمق آب زیرزمینی در دشت شیجانگ (مرکز استان هبیه در شمال چین) استفاده شده است. مدل‌ها شامل، مدل تابع قدرت (PFM<sup>v</sup>) شبکه عصبی مصنوعی پرسرو و ماشین بردار پشتیبان با دو هسته تابع خطی و تابع پایه شعاعی بوده است. در این تحقیق از آزمون گاما برای مشخص کردن پارامترهای ورودی موثر استفاده شده است. نتایج نشان‌دهنده عملکرد مناسب ماشین بردار پشتیبان با هسته تابع پایه شعاعی می‌باشد. با توجه به مطالعات صورت گرفته تاکنون مقایسه‌ای بین مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان همراه با پیش‌پردازش داده‌ها با روش‌های ذکر شده در تخمین تبخیر از تشت، صورت نگرفته است. هدف از این تحقیق تخمین تبخیر از تشت با استفاده از مدل‌های هوشمند شبکه عصبی مصنوعی و ماشین بردار پشتیبان همراه با کاهش پیچیدگی مدل‌سازی به وسیله پیش‌پردازش داده‌ها با روش‌های تحلیل مؤلفه اصلی و آزمون گاما می‌باشد.

#### منطقه مورد مطالعه

استان گیلان به مرکزیت رشت در شمال کشور قرار 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 ایجاب 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 (Isazadeh, 2017: 612).

#### مواد و روش‌ها

در این مطالعه از داده‌های سه ایستگاه سینوپتیک آستارا، کياشهر و تالش که واقع در نوار ساحلی دریای خزر هستند (شکل ۱) استفاده شده است. دوره آماری داده‌ها برای ایستگاه سینوپتیک تالش و آستارا از سال (۱۳۸۴ تا ۱۳۹۳) و برای ایستگاه سینوپتیک کياشهر از سال (۱۳۸۵ تا ۱۳۹۳) 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 سه ایستگاه سینوپتیک مورد مطالعه را نشان می‌دهد.



شکل ۱: منطقه و ایستگاه‌های مورد مطالعه

جدول ۱- خصوصیات آماری داده‌ها

ایستگاه	استارا			کیاشهر			تالش
	متوسط	حداقل	حداکثر	متوسط	حداقل	حداکثر	
تبخیر (mm/day)	۲/۴۶	۰	۱۰/۰۱	۶/۱	۰	۱۸	۲/۴
سرعت باد (m/sec)	۴/۴	۰	۲۰	۴/۳۷	۱	۲۰	۴/۱۶
ساعت آفتابی (hr)	۵/۱۷	۰	۵/۳۵	۷/۷/۴	۰	۱۳/۳	۴/۴
بارندگی (mm)	۳/۴۲	۰	۱۳۰	۳/۷/۵	۰	۱۰۶/۹	۲/۹
رطوبت متوسط (%)	۷۸/۱۲	۳۲	۱۰۰	۸۰/۲	۲۵	۹۹	۷۷
رطوبت حداقل (%)	۶۳/۶	۸	۱۰۰	۶۷/۳۳	۱۷	۹۸	۶۷/۴۲
رطوبت حداکثر (%)	۹۲/۳۲	۵۱	۱۰۰	۹۲/۷۸	۳۰	۱۰۰	۷۸/۵۳
دمای متوسط (C)	۱۵/۹۵	۳/۶	۳۱/۳	۱۶/۹۹	-۲/۶	۳۰/۷	۱۶/۳
دمای حداقل (C)	۷/۲/۸	-۷/۸	۷۸	۱۳/۳/۸	-۷	۷/۶/۸	۱۲/۸
دمای حداکثر (C)	۱۹/۸۲	-۱/۶	۳۸/۶	۲۰/۶/۱	-۱	۲۸	۱۹/۸

ادامه جدول ۱- خصوصیات آماری داده‌ها

ایستگاه	حدائق	حدائق
بارانمیر	حدائق	حدائق
تبخیر (mm/day)	۰	۱۷/۲
سرعت باد (m/sec)	۰	۲۵
ساعت آفتابی (hr)	۰	۱۲/۱
بارندگی (mm)	۰	۱۵۵
رطوبت متوسط (٪)	۱۹	۹۹
رطوبت حداقل (٪)	۱۰	۹۸
رطوبت حداکثر (٪)	۲۳	۱۰۰
دمای متوسط (°C)	-۷/۳	۳۰/۱
دمای حداقل (°C)	-۱	۲۸
دمای حداکثر (°C)	-۰/۴	۳۷

## - تحلیل مؤلفه‌های اصلی

تحلیل مؤلفه‌های اصلی یکی از روش‌های آماری چند متغیره می‌باشد. می‌توان از تحلیل مؤلفه‌های اصلی هنگامی که حجم وسیعی از اطلاعات در اختیار است، برای کاهش پیچیدگی متغیرهای ورودی استفاده کرد (Camdevyren, 2005: 583). تحلیل مؤلفه‌های اصلی متغیرهای ورودی را به مؤلفه‌های اصلی که ترکیب مستقل و خطی از متغیرهای ورودی هستند تغییر می‌دهد (Lu et al, 2003: 243). به‌جای استفاده مستقیم از متغیرهای ورودی، می‌توان آن‌ها را به مؤلفه‌های اصلی تبدیل و سپس از آن‌ها همانند متغیرهای ورودی استفاده کرد. در این روش، اطلاعات متغیرهای ورودی با حداقل تلفات در مؤلفه‌های اصلی ارائه خواهد شد (Helena et al, 2000: 811). برای دسترسی به اطلاعات بیش‌تر می‌توان به منابع (Tabachnick, B. G., Fidell, Nouri, 2007: 58; 2001: 634, Wackernagel, 1995: 351) مراجعه کرد.

در این تحقیق از مجموعه مؤلفه‌های اصلی اولی که حداقل نود درصد واریانس کل داده‌ها را دارا هستند، به‌عنوان ورودی مدل‌های تخمین‌گر استفاده شده است.

## - آزمون گاما

آزمون گاما یک روش غیرمتغیری است که نتایج آن صرف نظر از روش‌های خاص برای مدل‌سازی به‌کار برده می‌شود (Isazadeh et al, 2018: 1; Sharifi et al, 2013: 6) فرض می‌شود مجموعه داده‌های مشاهداتی به‌صورت زیر است.

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

رابطه (۱)

که در آن بردار مشاهداتی ورودی (مانند رواناب، بارش، درجه حرارت هوا با تأخیرهای مختلف و هر متغیر دیگر موثر)،  $y_i$  خروجی مشاهداتی (مانند میانگین دبی رواناب روزانه) و  $M$  تعداد کل مشاهدات می‌باشد (Biazar et al, 2018: 540).

از بردار  $x_i$  (در فضای  $m$  بعدی) برای مدل‌سازی  $y_i$  (در فضای  $R$ ) استفاده می‌شود. بنابراین، با توجه به فرض فوق رابطه‌ی بین ورودی و خروجی به شرح زیر در نظر گرفته می‌شود.

$$(x) + r y = f \quad \text{رابطه (۲)}$$

که در آن  $f$  یک تابع هموار و  $r$  متغیر تصادفی نشان‌دهنده‌ی خطا بوده، همچنین فرض شده است میانگین توزیعی که  $r$  از آن پیروی کرده، صفر و واریانس خطا،  $\text{Var}(R)$  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  $f$  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.  $x_{N[i, k]}$  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 (Durrant, 2001). به منظور به دست آوردن مقدار آماره گاما ( $\Gamma$ )، ابتدا مقدار  $(\delta_M(K))$ ، با توجه به داده‌ی ورودی به شرح زیر محاسبه می‌شود.

$$1 \leq k \leq p, \delta_M(k) = \frac{1}{M} \sum_{i=1}^M \left| x_{N[i, k]} - x_i \right|^2 \quad \text{رابطه (۳)}$$

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

$$1 \leq k \leq p, \gamma_M(k) = \frac{1}{2M} \sum_{i=1}^M \left| y_{N[i, k]} - y_i \right|^2 \quad \text{رابطه (۴)}$$

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  $\gamma_M(K)$  به دست آورده می‌شود. سپس بین  $p$  زوج مرتب  $\{\delta_M(k), \gamma_M(k)\}$  رابطه رگرسیونی خطی ساده به شرح رابطه (۵) برقرار خواهد شد طوری که در آن  $\delta$  و  $\gamma$  به ترتیب، به عنوان متغیرهای وابسته و مستقل در نظر گرفته شده است.

$$\Gamma \gamma = A \delta + \quad \text{رابطه (۵)}$$

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 مشاهداتی ایجاد می‌شود. متغیر دیگری که معمولاً در آزمون گاما به کار برده می‌شود.

- شبکه عصبی پیشرو با آموزش لوانبرگ-مارکورات

از اوایل دهه (۱۹۹۰) تاکنون، این شبکه‌های عصبی مصنوعی در زمینه هیدرولوژی نیز به‌طور موفقیت‌آمیز به کار گرفته شده‌اند (Dawson et al, 2006: 396; Mohammadi et al, 2017:80). حدود ۹۰٪ شبکه‌هایی که در مسائل هیدرولوژی کاربرد دارد شبکه‌های پیشرو هستند (Coulibaly et al, 2000: 246). 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 به دست می‌آید (ASCE, 2000: 116).

لازم به ذکر است که در تحقیق حاضر از تعداد نرون‌های ۱ تا ۲۰ برای لایه پنهان شبکه استفاده گردید تا از این طریق بتوان تأثیر ساختار مختلف شبکه بر عملکرد آن در شبیه‌سازی مقادیر تبخیر از تشت 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.

- ماشین بردار پشتیبان

اولین کاربرد این روش در مسائل آب توسط Dibike et al, 2001 با شبیه‌سازی بارش-رواناب ارائه شد. ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرای کمینه‌سازی خطا ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می‌گردد. برای اطلاعات بیشتر می‌توان به منابع Kavzoglu and Colkesen, 2009: 354; Ashrafzadeh et al, 2018: 3 مراجعه کرد.

لازم به ذکر است فرآیند محاسبات ماشین بردار پشتیبان، بر اساس کدنویسی در محیط متلب انجام و پارامترهای تابع کرنل از طریق سعی و خطا بهینه شدند.

- 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 نش-ساتکلیف (NS) می‌باشند که به ترتیب، در روابط (۱۲، ۱۳ و ۱۴) آورده شده‌اند. دقیق‌ترین مدل با توجه به این معیارها، مدلی خواهد بود که مقدار این سه معیار برای آن به ترتیب، نزدیک به یک، صفر و یک باشد.



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

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{y})^2}{N}} \quad (13)$$

$$NS = 1 - \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{y})^2}{\sum_{i=1}^N (x_i - \bar{x})^2}} \quad (14)$$

در روابط بالا  $x_i$  و  $\bar{x}$  به ترتیب، مقادیر مشاهداتی تبخیر از تشت 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 ۱-۰/۷۵، ۰/۳۶-۰/۷۵ و کم‌تر از ۰/۳۶ برای مقدار این شاخص در یک شبیه‌سازی به ترتیب نشان‌دهنده عملکرد بسیار خوب، رضایت‌بخش و ضعیف مدل مورد استفاده می‌باشند (Nash and Sutcliffe, 1970; Deo et al, 2018: 312, 286). در ابتدا داده‌های منطقه مورد مطالعه جمع‌آوری شده و داده‌های پرت حذف گردید. سپس برای کاهش پیچیدگی مدل‌ها از دو روش پیش‌پردازش داده‌ها استفاده شد. به وسیله آزمون گاما ورودی‌های منتخب برای مدل‌سازی انتخاب گردید. با روش تحلیل مولفه اصلی نیز تعداد مولفه اصلی اولی که در تخمین تبخیر از تشت موثر بوده‌اند از داده‌ها انتخاب گردید. سپس با استفاده از نتایج مرحله قبل مدل‌سازی با استفاده از دو مدل SVM و ANN به‌طور جداگانه برای هر دو روش انجام شد.

### یافته‌ها و بحث

ابتدا برای بررسی این‌که داده‌ها از توزیع نرمال پیروی می‌کنند یا خیر از آزمون کولموگروف-اسمیرنوف استفاده شد. نتایج نشان داد که داده‌ها از توزیع نرمال پیروی نمی‌کنند. همچنین تصادفی بودن داده‌ها با استفاده از آزمون ران تست مورد بررسی قرار گرفت. نتایج مشاهده شده از این آزمون بیانگر تصادفی بودن داده‌ها بوده است. پس از تعیین ساختار هر یک از مدل‌ها و تعیین ترکیب‌های ورودی با دو روش پیش‌پردازش ذکر شده، هر یک از دو مدل شبکه عصبی مصنوعی و ماشین بردار پشتیبان به ازای داده‌های آموزش مورد واسنجی قرار گرفته و سپس عملکرد مدل‌های آموزش دیده به ازای داده‌های بخش صحت‌سنجی ارزیابی گردیده است. در ادامه نتایج مربوط به هر یک از دو مدل در تخمین هر یک از پارامترهای کیفی ارائه شده است.

### نتایج آزمون گاما

برای تعیین پارامترهای موثر جهت تخمین تبخیر از تشت از آزمون گاما برای هر ایستگاه به‌طور جداگانه استفاده شده است؛ بنابراین ابتدا آزمون گاما برای کل داده‌ها انجام گرفته (ردیف ۱) و سپس این آزمون براساس حذف هر یک از

متغیرها از کل هشت متغیر موجود صورت گرفته است (ردیف‌های ۲ تا ۹) که نتایج در (جدول ۲) نشان داده شده است. در ایستگاه سینوپتیک تالش ترکیب‌هایی که پارامترهای دمای حداکثر، دمای حداقل، رطوبت حداکثر و متوسط، بارندگی و ساعت آفتابی از آن‌ها حذف شده، دارای مقدار گامای بیش‌تری نسبت به حالتی که تمام متغیرها در ترکیب حضور دارند (ترکیب شماره ۱) می‌باشند؛ بنابراین بایستی از این متغیرها برای تخمین تبخیر از تشت در ایستگاه سینوپتیک تالش استفاده گردد. پارامترهای منتخب ورودی آزمون گاما برای تخمین تبخیر از تشت ایستگاه گیاشهر شامل دمای حداکثر و حداقل، حداقل رطوبت، بارندگی و ساعت آفتابی و برای ایستگاه سینوپتیک آستارا دمای حداقل، حداکثر رطوبت، حداقل رطوبت، رطوبت متوسط، بارندگی و ساعت آفتابی می‌باشند. همچنین نتایج نشان می‌دهد که پارامتر ساعت آفتابی (بیش‌ترین افزایش گاما بعد از حذف) مؤثرترین متغیر در تخمین تبخیر از تشت ایستگاه‌های تالش، گیاشهر و آستارا می‌باشد


جدول ۲- نتایج آزمون گاما برای ایستگاه‌های تالش، آستارا و گیاشهر

ردیف	متغیر غایب	تالش	گیاشهر	آستارا
		گاما	گاما	گاما
۱	-	۰/۰۵۷۱	۰/۰۵۸۸	۰/۰۴۰۹۹
۲	دمای حداکثر	۰/۰۵۹۴	۰/۰۶۶	۰/۰۴۰۹۶
۳	دمای حداقل	۰/۰۵۷۷	۰/۰۶۳	۰/۰۴۲۳
۴	دمای متوسط	۰/۰۵۷۰	۰/۰۵۸۵	۰/۰۴۰۹۴
۵	حداکثر رطوبت	۰/۰۵۷۳	۰/۰۵۸۵	۰/۰۴۳۷
۶	حداقل رطوبت	۰/۰۵۵۵	۰/۰۶۰	۰/۰۴۲۳
۷	رطوبت متوسط	۰/۰۵۹۱	۰/۰۵۷۰	۰/۰۴۱۷
۸	بارندگی	۰/۰۵۹۶	۰/۰۷۳۱۳	۰/۰۴۳
۹	ساعت آفتابی	۰/۰۶۵۹	۰/۰۷۳۱۴	۰/۰۴۶۴
۱۰	سرعت باد	۰/۰۵۶۵	۰/۰۵۰۸	۰/۰۴

- تعیین تعداد مؤلفه‌های اصلی ورودی

پس از تعیین مؤلفه‌های اصلی تبخیر از تشت ایستگاه‌های سینوپتیک تالش، گیاشهر و آستارا، درصد واریانس تجمعی مؤلفه‌های اصلی محاسبه گردیده است. سپس در هر ایستگاه تعداد مؤلفه‌های اصلی اولی که نود درصد واریانس کل داده‌ها را دارا باشند، تعیین شده‌اند (شکل ۲). با توجه به (شکل ۲) برای ایستگاه تالش مقدار اولین مؤلفه اصلی ۵۰/۹ درصد از کل واریانس داده‌ها و مؤلفه دوم ۲۱/۵۶ درصد از کل واریانس داده‌ها را شامل می‌گردد. این دو مؤلفه مجموعاً

۷۲/۴۶ درصد از پراکندگی داده‌های اصلی را شامل می‌شوند. برای ایستگاه کیشهر مؤلفه اول ۴۶/۴۰ و مؤلفه دوم ۲۰/۴۲ درصد واریانس داده‌ها را شامل شده‌اند. مؤلفه اول و دوم ایستگاه آستارا نیز به ترتیب ۵۰/۱۶ و ۱۸/۵۴ درصد از پراکندگی داده‌ها را شامل گردیده است. مؤلفه‌های اول ذکر شده برای هر ایستگاه مؤثرترین مؤلفه برای ورودی مدل‌ها محسوب می‌شود. همچنین با توجه به (شکل ۲) مؤلفه ۶، ۷، ۸ و ۹ برای ایستگاه‌های کیشهر، آستارا و تالش جز ورودی‌های تقریباً بی‌تأثیر می‌باشند و حتی ورود این مؤلفه‌ها به مدل امکان افزایش خطا را به همراه خواهد داشت. بنابراین با توجه به (شکل ۲) در این تحقیق جهت تخمین تبخیر از تشت ایستگاه‌های سینوپتیک تالش، کیشهر و آستارا با استفاده از روش PCA، به ترتیب از چهار، پنج و پنج مؤلفه اصلی اول استفاده شده است.



شکل ۲: درصد واریانس تجمعی مؤلفه‌های اصلی تبخیر از تشت ایستگاه‌های تالش (الف)، کیشهر (ب) و آستارا (پ)

#### - مدل‌سازی با GT-SVM و GT-ANN

در این بخش از ترکیب ورودی تعیین شده توسط آزمون گاما جهت تخمین تبخیر از تشت ایستگاه‌های مورد نظر استفاده شده است. نتایج تخمین تبخیر از تشت هر ایستگاه در دوره‌های واسنجی و صحت‌سنجی با استفاده از مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان در (جدول ۳) نشان داده شده است. با توجه به (جدول ۳) در ایستگاه آستارا مدل GT-ANN با مجذور میانگین مربعات خطای کم‌تر نسبت به مدل GT-SVM دارای عملکرد بهتری می‌باشد. تخمین تبخیر از تشت در ایستگاه کیشهر توسط هر دو مدل به خوبی صورت گرفته است. در این ایستگاه مدل GT-SVM با مجذور میانگین مربعات خطای ۱/۲۹۵ نسبت به مدل GT-ANN با مجذور میانگین مربعات خطای ۱/۳۵۶ دارای عملکرد مناسب‌تری بوده است.

در ایستگاه تالش نیز نتایج هر دو مدل به یکدیگر بسیار نزدیک بوده، ولی نتایج مدل GT-SVM نسبت به مدل GT-ANN دقیق‌تر بوده است. ضریب نش-ساتکلیف‌های به‌دست آمده برای ایستگاه‌های آستارا و تالش نشان‌دهنده عملکرد بسیار خوب مدل‌ها و در ایستگاه کیشهر نشان‌دهنده عملکرد رضایت‌بخش مدل‌ها بوده است.

نتایج (جدول ۳) نشان می‌دهد که در حالت کلی مدل SVM در برآورد تبخیر از تشت ایستگاه‌های مدنظر دارای عملکرد بهتری نسبت به مدل شبکه عصبی مصنوعی بوده است. علت این امر را می‌توان اینگونه توجیه کرد که اگر گام‌های زمانی قبل از زمان مورد پیش‌بینی کم در نظر گرفته شود، شبکه عصبی قدر کافی با روند تغییرات آشنا نشده و درواقع در یادگیری دچار مشکل می‌شود، حتی ممکن است در حداقل‌های محلی گرفتار آید و موجب به خطا رفتن نتایج شود.

جدول ۳- نتایج مدل‌سازی با پیش‌پردازش آزمون گاما برای سه ایستگاه سینوپتیک آستارا، کیشهر و تالش

تعداد نرون بهینه	صحت سنجی			واسنجی			ایستگاه	مدل
	CC	RMSE (mm/day)	NS	CC	RMSE (mm/day)	NS		
۷	۰/۹۰۲	۰/۹۶۴	۰/۸۱۲	۰/۹۰۶	۰/۹۴۰	۰/۸۲۱	آستارا	GT-ANN
۱۷	۰/۸۱۱	۱/۳۵۶	۰/۶۵۲	۰/۸۶۰	۱/۱۴۳	۰/۷۴۰	کیشهر	
۱۳	۰/۸۶۹	۱/۰۰۶	۰/۷۵۵	۰/۸۷۱	۱/۰۰۶	۰/۷۵۹	تالش	
هسته تابع								GT-SVM
RBF	۰/۸۹۹	۰/۹۷۱	۰/۸۰۸	۰/۹۰۷	۰/۹۳۵	۰/۸۲۴	آستارا	
	۰/۸۲۵	۱/۲۹۵	۰/۶۸۳	۰/۹۰۳	۰/۹۶۸	۰/۸۱۴	کیشهر	
	۰/۸۷۰	۱/۰۰۵	۰/۷۵۵	۰/۸۷۴	۰/۹۹۵	۰/۷۶۴	تالش	

#### - مدل‌سازی با PCA-ANN و PCA-SVM

نتایج (جدول ۴) گویای مدل‌سازی با استفاده از داده‌های حاصل از پیش‌پردازش PCA می‌باشد. مدل‌سازی در این مرحله برای ایستگاه آستارا، کیشهر و تالش به ترتیب با پنج، پنج و چهار مؤلفه اصلی انجام شده است. با توجه به (جدول ۴) مدل PCA-ANN با مجذور میانگین مربعات خطای کم‌تر نسبت به مدل PCA-SVM در ایستگاه آستارا و تالش عملکرد بهتری در تخمین تبخیر از تشت داشته است. مقدار ضریب نش-ساتکلیف نیز حاکی از عملکرد بسیار مناسب هر دو مدل در هر دو ایستگاه مذکور بوده است.

مدل PCA-SVM نسبت به مدل PCA-ANN با مقدار مجذور میانگین مربعات خطای کمتر در تخمین تبخیر از تشت در این ایستگاه کیشهر مناسب‌تر تشخیص داده شده است. ضریب نش-ساتکلیف برای مدل PCA-SVM برابر با

۰/۶۶۶ و برای مدل PCA-ANN برابر با ۰/۶۳۴ بوده است که حاکی از عملکرد رضایت‌بخش هر دو مدل می‌باشد. در این بخش نیز مدل SVM دارای عملکرد مناسب‌تری نسبت به مدل ANN بوده است.

جدول ۴- نتایج مدل‌سازی با پیش‌پردازش تحلیل مؤلفه اصلی برای سه ایستگاه سینوپتیک آستارا، کیشهر و تالش

تعداد نرون بهینه	صحت سنجی			واسنجی			ایستگاه	مدل
	CC	RMSE (mm/day)	NS	CC	RMSE (mm/day)	NS		
۱۶	۰/۹۰۳	۰/۹۵۷	۰/۸۱۵	۰/۹۱۱	۰/۹۱۷	۰/۸۳۰	آستارا	5PCs-ANN
۱۵	۰/۷۹۷	۱/۳۹۲	۰/۶۳۴	۰/۸۲۵	۱/۲۶۷	۰/۶۸۱	کیشهر	5PCs-ANN
۲۰	۰/۸۷۰	۱/۰۰۴	۰/۷۵۶	۰/۸۶۹	۱/۰۱۷	۰/۷۵۴	تالش	4PCs-ANN
هسته تابع								
RBF	۰/۹۰۱	۰/۹۶۵	۰/۸۱۲	۰/۹۱۵	۰/۸۹۸	۰/۸۳۷	آستارا	5PCs-SVM
	۰/۸۱۶	۱/۳۲۹	۰/۶۶۶	۰/۸۶۲	۱/۱۴۱	۰/۷۴۱	کیشهر	5PCs-SVM
	۰/۸۶۷	۱/۰۱۷	۰/۷۵۰	۰/۸۷۲	۱/۰۰۶	۰/۷۶۰	تالش	4PCs-SVM

با توجه به نتایج (جدول ۴)، عملکرد مدل‌های PCA-ANN، GT-ANN، PCA-SVM و GT-SVM در تخمین تبخیر از تشت هر یک از ایستگاه‌های مورد بررسی بسیار نزدیک به یکدیگر می‌باشند. این شباهت نتایج ناشی از عملکرد روش‌های پیش‌پردازش تحلیل مؤلفه‌های اصلی و آزمون گاما می‌باشد. روش تحلیل مؤلفه‌های اصلی، متغیرهای ورودی را با استفاده از رابطه خطی بین کلیه متغیرهای ورودی به مؤلفه‌های اصلی مستقل از یکدیگر تبدیل می‌کند. در واقع این روش با تعیین ضریب کوچک‌تر برای متغیرهای ورودی که دارای اطلاعات مشابه هستند، اثر آن متغیر را در مؤلفه‌های اصلی ایجاد شده کم می‌کند. ولی در روش آزمون گاما، با توجه به ضریب گاما به‌دست آمده از ترکیب‌های ورودی مختلف، متغیری که تأثیر منفی بر روی خروجی تعیین شده دارد، شناسایی گردیده و از ترکیب ورودی نهایی حذف می‌گردد. همان‌طور که ذکر گردید ماهیت دو روش غیر خطی گاما و خطی PCA با یکدیگر متفاوت هستند. ولی هنگامی که روش PCA ضریب مربوط به متغیر حذف شده در آزمون گاما را بسیار کوچک در نظر بگیرد، ورودی‌های حاصل از دو روش پیش‌پردازش به یکدیگر نزدیک می‌گردند. این عامل می‌تواند یکی از علل نزدیکی نتایج مدل‌های تخمین‌گر به یکدیگر باشد؛ بنابراین نمی‌توان یکی از دو روش پیش‌پردازش PCA و گاما را بر دیگری ترجیح داد. به این ترتیب می‌توان نتیجه گرفت که در تخمین تبخیر از تشت ایستگاه‌های مذکور می‌توان از هر دو روش پیش‌پردازش برای تخمین تبخیر از تشت استفاده کرد.

با توجه به نتایج به دست آمده چنین می‌توان نتیجه گرفت که مدل‌های PCA-ANN برای ایستگاه تالش و آستارا و مدل GT-SVM برای ایستگاه کیشهر عملکرد بهتری نسبت به سایر مدل‌ها داشته‌اند. پس این مدل‌ها به‌عنوان مدل منتخب برای مدل‌سازی تبخیر از تشت در ایستگاه‌های مذکور استفاده شده است. (جدول ۳ و ۴) نشان دهنده این موضوع نیز می‌باشند که آزمون گاما و تحلیل مولفه اصلی توانسته‌اند بیش برآزش داده‌ها را کنترل کنند. همچنین با توجه به نتایج (جدول‌های ۳ و ۴) در ایستگاه سینوپتیک کیشهر هرچند که روش تحلیل مولفه اصلی عملکرد مناسبی دارد ولی بهتر است که از روش آزمون گاما استفاده شود. در واقع این‌گونه می‌توان نتیجه گرفت که با توجه به آنالیز نتایج روش‌های تحلیل مولفه اصلی و آزمون گاما، استفاده از روش‌های مذکور بستگی به منطقه مورد مطالعه دارد و نتایج هر منطقه را نمی‌توان به مناطق دیگر تعمیم داد.

### نتیجه‌گیری

با توجه به اهمیت تبخیر در برنامه‌ریزی و مدیریت منابع آب و لزوم استفاده از روش‌های نوین در برآورد تبخیر از تشت، در این پژوهش از دو روش آزمون گاما و تحلیل مؤلفه اصلی برای پیش‌پردازش داده‌ها استفاده شد و مدل‌سازی با مدل‌های ANN و SVM انجام گرفت. پارامترهای انتخاب شده ورودی به مدل‌ها توسط آزمون گاما برای ایستگاه آستارا، شامل دمای حداقل، حداکثر رطوبت، حداقل رطوبت، بارندگی و ساعت آفتابی و برای ایستگاه کیشهر شامل دمای حداکثر، دمای حداقل، رطوبت حداقل، بارندگی و ساعت آفتابی و برای ایستگاه تالش شامل دمای حداکثر، دمای حداقل، حداکثر رطوبت، رطوبت متوسط، بارندگی و ساعت آفتابی بوده است. با توجه به نتایج تحلیل مؤلفه اصلی بر روی داده‌های سه ایستگاه آستارا، کیشهر و تالش به ترتیب از پنج، پنج و چهار مؤلفه اصلی اول برای مدل‌سازی در ایستگاه‌های مذکور استفاده شده است.

نتایج مدل‌سازی در بخش پیش‌پردازش داده‌ها توسط آزمون گاما، نشان می‌دهد که مدل GT-SVM برای ایستگاه تالش و کیشهر و مدل GT-ANN در ایستگاه آستارا دارای عملکرد مناسب‌تری بوده‌اند و برای بخش تحلیل مؤلفه اصلی می‌توان در ایستگاه تالش و آستارا از مدل PCA-ANN و برای ایستگاه کیشهر از مدل PCA-SVM استفاده نمود.

با توجه (جدول‌های ۳ و ۴) و مقایسه دو روش پیش‌پردازش در نحوه عملکرد مدل‌ها، مدل PCA-ANN را می‌توان به‌عنوان مدل منتخب برای ایستگاه سینوپتیک آستارا و تالش انتخاب کرد. برای ایستگاه سینوپتیک کیشهر، به دلیل پایین بودن مجذور میانگین مربعات خطای مدل GT-SVM نسبت به مدل‌های دیگر، می‌توان از مدل مذکور برای تخمین تبخیر از تشت در این ایستگاه استفاده نمود. همچنین نتایج به دست آمده نشان می‌دهد که تفاوت چندانی بین دو روش پیش‌پردازش داده‌ها در تخمین تبخیر از تشت با دو مدل ذکر شده در ایستگاه‌های آستارا، تالش و کیشهر وجود ندارد. که این یافته با نتایج (Shikholeslami et al (2013) که به پیش‌بینی تبخیر از تشت تبخیر پرداخته‌اند مطابقت دارد. در واقع با توجه به عملکرد مدل‌ها می‌توان از هر دو روش پیش‌پردازش برای انتخاب ورودی موثر در تخمین تبخیر استفاده نمود. در ضمن نتایج نشان داد که مدل SVM در تخمین تبخیر از تشت نسبت به مدل ANN با

هر دو روش پیش‌پردازش داده‌ها داری عملکرد نسبتاً مناسب‌تری بوده است که این نتیجه با نتایج Kisi et al (2015) در تخمین تبخیر از تشت با استفاده از داده‌های محلی و Seifi et al (2013) مطابقت دارد. در نهایت با توجه به موارد گفته شده و نتایج حاصله می‌توان چنین نتیجه گرفت که پیش‌پردازش داده‌ها با دو روش ذکر شده، برای تخمین تبخیر از تشت و کاهش پیچیدگی مدل‌ها موفقیت‌آمیز بوده است که این یافته نیز با نتایج Noori et al (2010) که بر روی پسماند هفتگی و در تحقیق Shikho Leslami (2013) بر روی تخمین تبخیر از تشت، مطابقت داشته است.

## References

- 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.
- Azid, A., Juahir, H., Toriman, M. E., Kamarudin, M. K. A., Hasnam, C. N., Abdul Aziz, N. A., Azman, F., Latif, M.T., Zainuddin, S. F. M., Osman, M. R., (2014), "Prediction of the level of air pollution using principal component analysis and Artificial Neural Network Techniques: a case study in Malaysia", *Water Air Soil Pollution*, 225, 2063: 2077.
- Ashrafzadeh, A., Malik, A., Jothiprakash, V., Ghorbani, M. A., Biazar, S. M., (2018), "Estimation of daily pan evaporation using neural networks and meta-heuristic approaches", *ISH Journal of Hydraulic Engineering*, 17: 1-9.
- Biazar, S., ghorbani, M., Darbandi, S, (2018), "Used from Entropy theory and Gamma test in the determination input variables for daily evaporation estimation", *Iranian Journal of Ecohydrology*, 5 (2): 535-549. [In Persian].
- Camdevyren, H., Demyr, N., Kanik, A., Keskyn, S., (2005), "Use of principal component scores in multiple linear regression models for prediction of Chlorophyll- an in reservoirs", *Ecological Modelling*, 181: 581-589.
- Coulibaly, P., Anctil, F., Bobée, B., (2000), "Daily reservoir inflow forecasting using artificial neural networks with stopped training approach", *Journal of Hydrology*, 230: 244-257.
- Dawson, C.W., Abrahart, R. J., Shamseldin, A. Y., Wibly, R. L., (2006), "Flood estimation at ungauged sites using artificial neural networks", *Journal of Hydrology*, 319: 391-409.
- Dibike, Y., Velickov, S., Solomatine, D., Abbott, M., (2001), "Model induction with of support vector machines. Introduction and applications", *Journal of Computing in Civil Engineering*, 15: 208- 216.
- 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.
- Deo, R. C., Ghorbani, M. A., Samadianfard, S., Maraseni, T., Bilgili, M., Biazar, M., (2018), "Multi-layer perceptron hybrid model integrated with the firefly optimizer algorithm for windspeed prediction of target site using a limited set of neighboring reference station data" *Renewable energy*, 116: 309-323.
- Eskandari, A., Nouri, R., Meraji, H., Kiaghadi, A., (2012), "Developing a proper model for online estimation of the 5-day biochemical oxygen demand based on artificial neural network and support vector machine", *Journal of Environmental Studies*, 38 (1): 71-82. [In Persian].
- Ghareman, N., Gharakhani, A., (2013), "Comparison of artificial neural network and multiple regression methods in estimating evaporation from coffees and determining the most important meteorological meteorological elements by main component analysis", *Research Watershed research (research and construction)*, 28 (106): 42-51. [In Persian].
- Helena, B., Pardo, R., Vega, M., Barrado, E., Fernandez, J. M., Fernandez, L., (2000), "Temporal evolution of groundwater composition in an alluvial aquifer (Pisuerga River, Spain) by principal component analysis", *Water Research*, 34: 807-816.
- Hooshangi, N., Al Sheikh , A. A., Nadiri, A., (2014), "Optimizing the number of piezometers in predicting groundwater level using PCA and geostatistical methods", *Water and Soil Knowledge (Agricultural Knowledge)*, 25 (4): 53-66. [In Persian].



- Isazadeh, M., Biazar, S. M., Ashrafzadeh, A., (2017), "Support vector machines and feed-forward neural networks for spatial modeling of groundwater qualitative parameters", *Environmental Earth Sciences*, 76 (17): 610-627.
- Isazadeh, M., Biazar, S., Ashrafzadeh, A., Khanjani, R., (2018), "Estimation of aquifer qualitative parameters of guilans plain with using gamma test and support vector machine and artificial neural network models", *Journal of Environmental Science and Technology*, - doi: 10.22034/jest.2018.21197.3034, 78 (1): 50-65. [In Persian].
- Kavzoglu, T., Colkesen, I., (2009), "A kernel functions analysis for support vector machines for land cover classification", *International Journal of Applied Earth Observation and Geoinformation*, 11: 352-359.
- Kisi, O., Genc, O., Dinc, S., Zounemat-Kermani, M., (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.
- Kisi, O., (2015), "Pan Evaporation modeling using least square support vector machine, multivariate adaptive regression splines and M5 model tree", *Journal of Hydrology*, 528: 312-320.
- Lu, W. Z., Wang, W. J., Wang, X. K., Xu, Z. B., Leung, A.Y.T., (2003), "Using improved neural network to analyze RSP, NO<sub>x</sub> and NO<sub>2</sub> levels in urban air in Mong Kok, Hong Kong", *Environmental Monitoring and Assessment*, 87: 235-254.
- McCuen, R. H., (1998), "*Hydrologic analysis and design*", Prentice Hall, Englewood Cliffs, New Jersey.
- Mohammadi, B., Biazar, S. M., Asadi, E., (2017), "Performance of hybrid particle swarm algorithm to simulate water level (Case study: Ardabil aquifer)", *Journal of Rainwater Catchment Systems*, 5 (2): 77-87. [on line]: <http://jircsa.ir/article-1-242-en.html>. [In Persian].
- Nash, J. E., Sutcliffe, I.V., (1970), "River flow forecasting through conceptual models, Part I, A discussion of principles", *Journal of Hydrology*, 10: 282-290.
- Nouri, R., Karachian, R., Khodadai, D. A., Shakibaie Nia, A., (2007), "Evaluation of the importance of river monitoring quality streams using main components analysis and Factor analysis, case study: Karoon River", *Water and Wastewater*, 18 (3): 60-69. [In Persian].
- Noori, R., Karbassi, A., Sabahi, M., (2010), "Evaluation of PCA and gamma test techniques on ANN operation for weekly solid waste prediction", *Journal of Environmental Management*, 91: 767-771.
- Singh, V. P., Xu, C.Y., (1997), "Evaluation and generalization of 13 mass transfer equations for determining free water evaporation", *Hydrological Process*, 11: 311-324.
- Seifi, A., Mirlatifi, S. M., Reyahi, H., (2013), "Introduction and application of least square support vector machine in estimating reference evapotranspiration and analysis of uncertainty of results. Case study of Kerman city", *Iranian Irrigation and Water Engineering*, 13 (4): 67-79. [In Persian]
- Sharifi, A., Dinipazhu, Y., Fakhriifard, A., Moghaddamnia, A., (2013), "Optimal combination of variables for runoff simulation in Amameh watershed using gamma test", *Water and Soil Knowledge*, 23 (4): 59-72. [In Persian]
- Shikho Leslami, N., Mosaedi, A., Davari, K., Mohaghpour, M., (2013), "Propagation of Reference and Evapotranspiration (ETO) using main component analysis (PCA) and multi-linear regression modeling (MLR-PCA) (case study: Mashhad Station)", *Water and Soil (Agriculture Sciences and Technology)*, 28 (2): 420-429. [In Persian]
- Seyedian, S. M., (2014), "Use of new methods to determine the effective parameters for bridge brushed scour", *Iran Irrigation and Water Engineering Society*, 5 (3): 1-16. [In Persian]

- Tian, J., Li, C., Liu, J., Yu, F., Cheng, S., Zhao, N., Jaafar, W., (2016), " Groundwater depth prediction using data-driven models with the assistance of Gamma test", *Sustainability*, 8: 1076-1085.
- Tabachnick, B. G., Fidell, L. S., (2001), "*Using multivariate statistics*", Third Ed, Allyn and Bacon, Boston, London.
- Tezal, G., Buyukyildiz, M., (2015), "Monthly evaporation forecasting using artificial neural networks and support vector machines", *Journal of Theoretical and Applied Climatology*, 124: 69-80.
- Wackernagel, H., (1995), "*Multivariate geostatistics: an Introduction with Applications*", Second Ed, Springer, New York and London,.