

کاربرد نظریه آشوب و شبکه عصبی مصنوعی در بررسی و تخمین تبخیر از سطح آب دریاچه‌ها

سعید فرزین^{۱*} - رضا حاجی آبادی^۲ - محمد حسین احمدی^۳

تاریخ دریافت: ۱۳۹۴/۰۷/۲۹

تاریخ پذیرش: ۱۳۹۴/۱۲/۰۹

چکیده

ماهیت دینامیکی پدیده‌های هیدرولوژیکی و نیز محدودیت دسترسی ابزارهای ریاضیاتی مناسب، سبب گشته که اکثر مطالعات پیشین در این زمینه، منجر به نگرشی تصادفی و احتمالاتی گردد. بررسی قطعی و یا تصادفی بودن فرآیند دینامیکی مقادیر تبخیر از سطح آب دریاچه‌ها، به منظور انتخاب روش مناسب شبیه‌سازی و بررسی قابلیت پیش‌بینی، موضوع مهم و بحث برانگیزی است که در این تحقیق به آن پرداخته شده است. در این راستا، با توجه به قابلیت فراوان نظریه آشوب و مدل هوشمند شبکه عصبی در مطالعه رفتار سیستم‌های غیرخطی پویا مقادیر ماهانه تبخیر سطح آب دریاچه ارومیه در شمال غربی ایران، طی یک دوره آماری ۴۰ ساله (۱۳۴۶-۱۳۸۶) با استفاده از مفاهیم این دو روش مورد بررسی و پیش‌بینی قرار گرفته است. نتایج بررسی شاخص‌های تعیین ماهیت آشوبناکی داده‌های تبخیر؛ نمای لیاپانوف مثبت و مقدار غیرصحت شیب نمودار بعد همبستگی در مقابل شعاع همبستگی، همگی نشانگر رفتار کاملاً آشوبناک سری زمانی تحت بررسی می‌باشد. نتایج صحت‌سنجی حاکی از دقت بالای نظریه آشوب و مدل شبکه عصبی مصنوعی - اندکی دقت بالاتر - می‌باشد به طوریکه میانگین خطای مطلق (MAE) و جذر میانگین مربعات خطا (RMSE) در شبکه عصبی مصنوعی نسبت به نظریه آشوب به ترتیب ۲/۵۱ و ۲/۲۵ میلی‌متر کاهش یافته‌اند. همچنین نتایج مربوط به ارتفاع تجمعی تبخیر در دوره صحت‌سنجی حاکی از برتری ۳/۸ درصدی شبکه عصبی مصنوعی نسبت به نظریه آشوب دارد.

واژه‌های کلیدی: پیش‌بینی، پدیده‌های هیدرولوژیکی، دریاچه ارومیه، نمای لیاپانوف

مقدمه

تغییرات وسیع زمانی و مکانی فرآیندهای هیدرولوژیکی، وابسته بودن آنها به مؤلفه‌های متعدد می‌باشد که از جمله می‌توان به پارامترهای هواشناسی، خاکشناسی، توپوگرافی و اقلیم‌شناسی اشاره نمود. این امر سبب گشته که اکثر تحقیقات گذشته در زمینه مدل‌سازی‌های هیدرولوژیکی منجر به نگرشی تصادفی و احتمالاتی گردد (۲۲).

با توجه به قرار گرفتن ایران در نواحی خشک و نیمه خشک، مقدار بارندگی و نزولات جوی ایران به اندازه کافی نیست. همچنین این ریزش‌های جوی دارای پراکنندگی مناسب و یکنواختی در سطح کشور نمی‌باشد. مشکل آب در کشور ما علاوه بر کمبود ریزش‌های جوی، زیاد بودن میزان تبخیر است چرا که بخش اعظمی از این نزولات و منابع آب سطحی ناشی از بارندگی در اثر تبخیر از دسترس خارج می‌شود و به همین دلیل تبخیر به خصوص از منابع آب سطحی در کشور ما از اهمیت ویژه‌ای برخوردار است و نقش مهمی در پدیده‌های هیدرولوژیکی و مدیریت منابع آب ایفا می‌کند.

دریاچه ارومیه در کشور ما نیز از جمله دریاچه‌هایی است که در طول سال‌های اخیر عوامل اقلیمی و انسانی آن را دستخوش تغییرات کرده به طوریکه تبخیر از سطح این دریاچه در سال‌های اخیر باعث تغییر شدید اکوسیستم و همچنین افزایش غلظت نمک دریاچه شده

به طور کلی یک مدل، نمایشی ساده از یک سیستم پیچیده بوده و در مدل ریاضی رفتار یک سیستم به وسیله یک سری معادلات ریاضی همراه با جملات منطقی، ارتباط بین متغیرها و پارامترها را بیان می‌کند. علیرغم آنکه تاکنون مدل‌های ریاضیاتی متعددی برای مدل‌سازی فرآیندهای هیدرولوژیکی پیشنهاد گردیده است، اما هنوز رویکرد ریاضیاتی یکسان و واحدی وجود ندارد. علت این امر را می‌توان به تغییرپذیری قابل توجه زمانی و مکانی فرآیندهای هیدرولوژیکی و نیز محدودیت دسترسی ابزارهای ریاضیاتی مناسب برای استخراج ساختار فرآیندهای هیدرولوژیکی، نسبت داد. علت

۱- استادیار، گروه مهندسی آب و سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه سمنان

*- نویسنده مسئول: (Email: saeed.farzin@semnan.ac.ir)

۲- دانشجوی دکتری، گروه مهندسی و مدیریت منابع آب، دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران

۳- دانشجوی دکتری، گروه آب، دانشکده مهندسی عمران، دانشگاه تبریز

است و به تبع آن سطح و کیفیت آب دریاچه در شرایط نامطلوبی قرار گرفته است (۱۰). اهمیت و ماهیت دریاچه ارومیه به عنوان یک میراث طبیعی و جهانی از یک سو و مدیریت جامع منابع آب از دیگر سو، سبب جلب توجه محققان نقاط مختلف دنیا گردیده است. دریاچه ارومیه به عنوان بزرگ‌ترین دریاچه داخلی کشور و دومین دریاچه آب شور جهان محسوب می‌شود. این دریاچه زیستگاه جانداران بسیاری بوده و از منظرهای مختلف اقتصادی، اجتماعی و زیست محیطی اهمیت بالایی در کشور و منطقه دارد. این دریاچه به عنوان یکی از مهمترین زیستگاه‌های طبیعی در سطح منطقه مطرح بوده و به دلیل ویژگیهای منحصر به فرد خود به وسیله سازمان یونسکو به عنوان پارک ملی شناخته شده است. طی سالیان اخیر به علل مختلف تراز آب دریاچه‌ی ارومیه ۶ متر کاهش یافته است (۱۰ و ۱۱). با توجه به اهمیت تبخیر از سطح دریاچه ارومیه در این تحقیق پیش‌بینی تبخیر از سطح دریاچه با استفاده از نظریه آشوب و مدل هوشمند شبکه عصبی مصنوعی مورد بررسی قرار گرفته است.

نظریه آشوب و مدل شبکه عصبی مصنوعی امروزه به روش‌های مناسبی جهت پیش‌بینی پدیده‌های هیدرولوژیکی تبدیل شده‌اند و محققان زیادی از این ابزارها در پژوهش‌های خود بهره برده‌اند. استهلک (۲۴) به بررسی آشوب‌پذیری دبی روزانه رودخانه پرداخت. در این تحقیق با توجه به مفهوم تاخیر زمانی، دو سری از داده‌های دبی رودخانه اولریسکا در جمهوری چک، با مدت تاخیر زمانی مختلف، جهت بررسی امکان رفتار آشوبی داده‌ها و برآورد تاثیر مدت زمان تاخیر در ماهیت جاذب‌های متناظر تجزیه و تحلیل شدند. سولوماتین و همکاران (۲۳) تخمین سطح آب دریای شمال را با استفاده از نظریه آشوب و شبکه عصبی مصنوعی انجام دادند. نتایج، برتری نظریه آشوب را نسبت به مدل‌های خطی همچون خود همبستگی و مدل ARIMA، در تخمین سطح موج آب در منطقه ساحلی نشان دادند. ریگوند و همکاران (۲۰) داده‌های جریان سه رودخانه در مقیاس‌های زمانی مختلف روزانه، پنج روزه و هفت روزه را از نظر آشوب‌پذیری بررسی نمودند. تعدادی از سری داده‌ها رفتار آشوبناک و برخی رفتار تصادفی نشان دادند. خان و همکاران (۱۶) امکان وجود سیگنال‌های آشوبی در سری‌های زمانی محدود را بررسی نموده و نشان دادند که داده‌های هیدرولوژیکی محدود هم می‌توانند رفتار آشوبناکی از خود نشان دهند. کوجاک و همکاران (۱۸) با استفاده از مدل پیش‌بینی موضعی تئوری آشوب، پیش‌بینی جریان ماهانه سد یاملا را مورد مطالعه قرار دادند که پیش‌بینی‌های کوتاه مدت، نتیجه بهتری نسبت به روش‌های دیگر نشان داد. داملا و یالچین (۴) به پیش‌بینی سیلاب‌ها با استفاده از نظریه آشوب پرداختند و نشان دادند که مقادیر پیش‌بینی شده با نظریه آشوب نسبت به مقادیر پیش‌بینی شده با مدل سری‌های زمانی، دقت قابل ملاحظه‌ای دارد. ان جی و همکاران (۱۹) کاربرد تکنیک‌های تحلیلی آشوبناک را بر روی سری‌های جریان

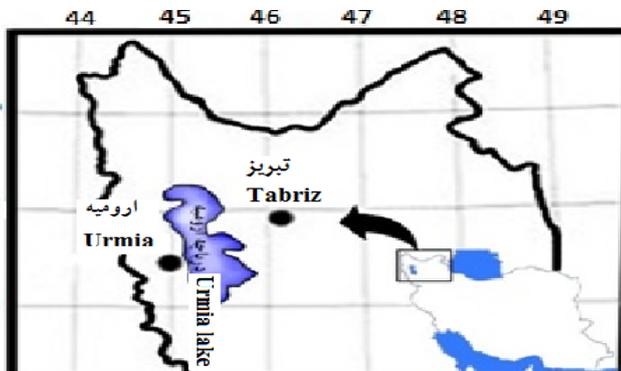
نویزدار روزانه بررسی نمودند. وو و همکاران (۲۷) از مدل آشوب و مدل هندسی فرکتال برای تخمین سری زمانی کیفیت آب با داده‌های کم استفاده و نتایج را با مدل خاکستری و مدل سری زمانی AR مقایسه نموده، به این نتیجه رسیدند که دقت تخمین مدل آشوب بالاتر از مدل خاکستری و مدل سری زمانی AR است. شانگ و همکاران (۲۱) تکنیک‌های مدلسازی سری زمانی غیرخطی را جهت تحلیل داده‌های رسوبات معلق بکار گرفتند. نتایج نشان داد که خصوصیات آشوبناک در پدیده انتقال رسوب وجود دارد و تکنیک‌های برپایه دینامیک فضای حالت می‌تواند برای تحلیل و پیش‌بینی غلظت رسوبات معلق استفاده شود. خطیبی و همکاران (۱۴) نوسانات ساعتی تراز آب بندر هیلاری بوت در غرب استرالیا را در سال‌های ۲۰۰۰ تا ۲۰۰۲ با استفاده از نظریه آشوب و برنامه‌ریزی ژنتیک مورد بررسی و پیش‌بینی قرار دادند. نتایج حاکی از دقت بالای روش برنامه‌ریزی ژنتیک و نظریه آشوب- اندکی دقت بیشتر- در پیش‌بینی می‌باشد. خطیبی و همکاران (۱۵) به منظور پیش‌بینی رطوبت نسبی روزانه در دو ایستگاه در کالیفرنیا آمریکا از شبکه عصبی مصنوعی و برنامه‌ریزی ژنتیک استفاده کردند. نتایج آنها نشان داد که هر دو مدل از توانایی بالایی برای پیش‌بینی رطوبت نسبی برخوردار هستند. ترزی (۲۶) نیز برای پیش‌بینی تبخیر روزانه دریاچه‌ای در جنوب غربی ترکیه از برنامه‌ریزی ژنتیک و شبکه عصبی مصنوعی استفاده کرد و نتایج حاکی از برتری مدل برنامه‌ریزی ژنتیک نسبت به شبکه عصبی مصنوعی است. کیم و همکاران (۱۷) از سه مدل متفاوت شبکه عصبی مصنوعی شامل MLP و GRN و ANFIS جهت پیش‌بینی تبخیر روزانه دو ایستگاه در کره جنوبی استفاده کردند و نشان دادند هر سه مدل دقت بالایی دارند. دونگ و همکاران (۵) با استفاده از ترکیب تئوری آشوب در شبکه عصبی فازی موجب بهبود دقت و کارایی این مدل در تخمین رواناب رودخانه ای در ویتنام شدند. ذونعمت و کیشی (۲۹) نیز از تئوری آشوب به منظور اثبات آشوبناکی مشخصات امواج ثبت شده در خلیج فارس استفاده کردند. مشخصات این امواج توسط سه ایستگاه واقع در مناطق مختلف خلیج فارس ثبت شده بود و نتایج حاکی از آشوبناکی بالای ارتفاع و دوره موج و آشوبناکی اندک امتداد و جهت موج بود.

در ایران نیز، حسن‌زاده و همکاران (۱۱) ماهیت آشوبناکی نوسانات روزانه تراز آب دریاچه ارومیه را مورد بررسی قرار دادند و نشان دادند این نوسانات آشوبناک هستند. قاهری و همکاران (۸) با استفاده از نظریه آشوب جریان روزانه رودخانه اهرچای را مورد بررسی و پیش‌بینی قرار دادند. نتایج آنها نشان از دقت قابل قبول نظریه آشوب در پیش‌بینی جریان رودخانه اهرچای دارد. حسن‌زاده و همکاران (۱۲) پس از نویززدایی SPI شهر تبریز در طول دوره آماری، ماهیت آشوبناکی سری زمانی حاصل را مورد بررسی قرار دادند و پس از تایید رفتار آشوبناک سیستم، با استفاده از نظریه آشوب شدت

قرار گرفته است. برای این منظور از سری زمانی ۴۰ ساله (۱۳۴۶-۱۳۸۶) داده‌های تبخیر ماهانه دریاچه ارومیه استفاده شده است. این داده‌ها از هفت ایستگاه تبخیرسنجی مجاور دریاچه ارومیه جمع‌آوری گردیده است و میانگین آنها به عنوان تبخیر متوسط از سطح دریاچه در نظر گرفته شده است (۱۰). به منظور صحت‌سنجی نتایج مدل‌ها از داده‌های ۱۰ سال پایانی (۱۳۷۶-۱۳۸۶) استفاده شده است، سپس تبخیر ماهانه ۴ سال بعدی نیز (۱۳۸۶-۱۳۹۰) پیش‌بینی شده است و توانایی مدل‌ها در پیش‌بینی مقادیر تبخیر در آینده و یا داده‌های ثبت نشده در گذشته مورد بررسی قرار می‌گیرد.

موقعیت و ویژگی‌های جغرافیایی دریاچه ارومیه

از نقطه نظر جغرافیایی، دریاچه ارومیه در حد گسترش نهایی خود حدود ۱۴۰ کیلومتر طول، ۵۵ کیلومتر عرض و با حداکثر ۱۸ متر عمق، در شمال غرب ایران واقع شده است. مساحت آن در طول سال‌های گذشته بین ۴۰۰۰ تا ۶۰۰۰ کیلومتر مربع در نوسان بوده است که میانگین مساحت آن حدود ۵۰۰۰ کیلومتر مربع برآورد می‌شود (۱۰). میانگین شوری آب آن بین ۲۲۰ تا ۳۰۰ گرم در لیتر است که نسبت به شرایط زمانی و مکانی مختلف متغیر است و سبب گشته است که دومین دریاچه فوق اشباع نمک در دنیا به حساب آید. شکل (۱) موقعیت جغرافیایی منطقه و دریاچه ارومیه را نشان می‌دهند.



شکل ۱- موقعیت جغرافیایی دریاچه ارومیه در شمال غرب ایران

Figure 1- Location of Urmia lake in northwestern Iran

هستند یعنی در هر لحظه برای هر سری زمانی اندازه‌گیری شده $X(t)$ ، سیستم را می‌توان به شکل زیر بیان کرد (۱۱):

$$X(t) = (x(t), x(t-\tau), x(t-2\tau), \dots, x(t-(k-1)\tau)) \quad (1)$$

که در آن t شاخصی اسکالر، نظیر زمان، برای بیان داده‌ها، k بعد سیستم و τ فواصل بین مشاهدات یا زمان تاخیر است. حال فرض کنید F تابع غیرخطی حاکم بر سیستم باشد به دلیل قطعی بودن سیستم برای هر $t+\tau$ می‌توان نوشت (۱۲):

خشکسالی شهر تبریز را برای ۳ سال آینده پیش‌بینی نمودند.

همانگونه که ذکر گردید مطالعه تبخیر و در پی آن تراز سطح آب اهمیت فراوانی در زمینه ارزش‌های اکولوژیکی دریاچه، کشاورزی، مدیریت منابع آب و بسیاری از مسائل دیگر دارد و بدین منظور مدل‌های مختلف تجربی، نیمه تجربی و هوشمند توسعه یافته‌اند. با توجه به تاثیرگذاری عوامل مختلف متغیر بر روی تبخیر می‌توان سیستم تغییرات تبخیر را به عنوان یک سیستم دینامیکی مطرح نمود و از آنجائی که تئوری آشوب به مطالعه سیستم‌های دینامیکی می‌پردازد، لذا تحلیل و پیش‌بینی تبخیر از سطح آب دریاچه ارومیه با استفاده از نظریه آشوب و مقایسه نتایج با نتایج حاصله از مدل هوشمند شبکه عصبی مصنوعی می‌تواند به عنوان روشی نوین مطرح گردد که تاکنون بحثی در این مقوله صورت نپذیرفته است. پیش‌بینی پدیده‌های هیدرولوژیکی یکی از موارد اساسی در طراحی و مطالعات مربوط به منابع آب به شمار می‌آید که می‌تواند کمک شایانی در برنامه‌ریزی، بهره‌برداری و مدیریت کمی و کیفی این منابع داشته باشد.

مواد و روش‌ها

در تحقیق حاضر دقت مدل هوشمند شبکه عصبی مصنوعی و نظریه آشوب در پیش‌بینی تبخیر از سطح دریاچه ارومیه مورد بررسی

نظریه آشوب

آشوب، رفتاری است غیرخطی در محدوده‌ای بین رفتار نوسانی (periodic) و رفتار تصادفی (random). این نوع سیستم‌ها به شرایط اولیه و وضعیت شروع رفتار به شدت حساس می‌باشند. در نگاه اول برخی از سیستم‌های آشوبناک ممکن است کاملاً نظامند و تناوبی و یا حتی برخی تصادفی به نظر آیند؛ در هر یک از این حالت‌ها هر دوی این فرض‌ها (تناوبی بودن و تصادفی بودن) مردود هستند. به طور مشخص می‌توان گفت سیستم‌های آشوبناک، سیستم‌هایی قطعی

$\Pr(S(t+T))$ به ترتیب احتمالات $S(t)$ و $S(t+T)$ می‌باشند. Pr نیز مقدار تابع احتمال است که میتوان از هیستوگرام مربوط به داده‌ها استخراج کرد.

در گام دوم برای تعیین بعد نشاننده یا d میتوان روشی را که توسط Cao ابداع شده است، به کاربرد؛ طبق رابطه زیر (۳):

$$E1(d) = \frac{E(d+1)}{E(d)} \quad (5)$$

در رابطه (۵)، $E(d)$ به صورت زیر محاسبه می‌شود:

$$E(d) = \frac{1}{N-dT} \sum_{t=0}^{N-dT-1} \frac{\|y_{d+1}(t) - y_{d+1}^{NN}(t)\|}{\|y_d(t) - y_d^{NN}(t)\|} \quad (6)$$

که در آن علامت $\|\dots\|$ اندازه اختلاف دو بردار است. N معرف طول سری داده‌ها، d بعد نشاننده و NN نمایانگر نزدیک‌ترین بردار همسایه به بردار دیگر است که توسط معیار زیر تعریف می‌شود:

$$\|y_d(t) - y_d^{NN}(t)\| = \max_{0 \leq j \leq d-1} |s(t+jT) - s^{NN}(t+jT)| \quad (7)$$

با افزایش مقدار d ، $E1(d)$ به سمت یک نزدیک‌تر می‌شود. مناسب‌ترین مقدار d ، مقداری است که در آن روند افزایشی $E1(d)$ دچار یک پیچ‌خوردگی شده و بعد از آن، روند نمودار به سمت ثابت شدن پیش رود.

شاخص‌های تعیین ماهیت آشوبناکی

برای آنالیز داده‌ها اولین گام تشخیص آشوبناک یا تصادفی بودن سیستم مورد مطالعه می‌باشد. در ادامه شاخص‌هایی معرفی خواهد شد که با محاسبه آنها با استفاده از نرم افزار OpenTSTOOL نسخه ۲.۱ در سال ۲۰۰۹ و کد نویسی انجام پذیرفته در Matlab می‌توان به این امر پاسخ داد.

الف) بعد همبستگی (Correlation Dimension)

الگوریتم بعد همبستگی در سال ۱۹۸۳ توسط گراسبرگر و پروکاسیا ابداع گردید (۱۳). این الگوریتم برپایه مفهوم بعد فراکتالی - مفهومی که از هندسه فراکتالی در رابطه با خود شبیهی نشات گرفته‌است - کاربردهای زیادی در مشخص‌سازی و توصیف پدیده‌های آشوبناک دارد. شبیه‌سازی به معنای تقلید است و یک مدل شبیه‌ساز باید بتواند ساختار سیستم را تقلید کند و بگونه‌ای رفتار آن را ایجاد کند. ایجاد رفتار فقط به این معنی نیست که مدل تجربه گذشته را تولید نماید بلکه باید بتواند به رویدادها و سیاست‌های کاملاً جدید پاسخ دهد. همبستگی بین متغیرها نشان دهنده وضعیت سیستم در گذشته است (۲۵). بعد همبستگی یکی از روش‌های مرسوم تعیین آشوبناکی سیستم و همچنین کمی کردن آشوب می‌باشد. این کمیت برای سامانه‌های آشوبناک عددی غیر صحیح خواهد بود. اگر کره‌ای با

$$F: \mathbb{R}^k \rightarrow \mathbb{R}^k \quad (2)$$

$$x(t+\tau) = F(X(t)) + p(t)$$

به دلیل وجود خطاهایی نظیر گردکردن، سرشکنی و خطاهای موجود در اندازه‌گیری متغیر احتمال $p(t)$ ، با میانگین صفر، در نظر گرفته شده است. در سیستم‌های قطعی خطای موجود (اختلاف بین هر دو حالت مجاور) یا بسیار کم باقی می‌ماند (سیستم‌های پایدار و عادی) یا به صورت نمایی رشد می‌کند (سیستم‌های آشوبناک). در حالی که در سیستم‌های تصادفی این خطا و اختلاف به صورتی کاملاً اتفاقی و تصادفی توزیع می‌شود (۷).

ابعاد نشاننده (Embedding Dimensions)

از آن جایی که سیستم‌های آشوبناک، سیستم‌هایی هستند که رفتار هر لحظه از سیستم به پارامترهای متعددی بستگی دارد در رابطه (۱)، k مقدار بزرگی خواهد بود. از طرفی با افزایش پارامترهای دخیل در رفتار یک سیستم، حجم داده‌ها و عملیات محاسباتی به شدت افزایش می‌یابد از این رو برای k های بزرگتر از ۱۰ مناسب‌تر خواهد بود از همان مدل‌های متغیر تصادفی برای بیان سیستم استفاده شود (به نقل از ۱۱). شیوه‌های مختلفی برای تقلیل بعد سیستم و انتخاب پارامترهایی که رفتار سیستم را با خطای قابل قبولی توضیح می‌دهند، وجود دارد. یکی از کلیدی‌ترین این روش‌ها قضیه ابعاد نشاننده تیکن (Takens embedding dimensions) است (۳). در این قضیه با کاهش بعد سیستم از k به d به جای بردار $x(t)$ بردار $y(t)$ در نظر گرفته میشود. این قضیه را به صورت زیر می‌توان نوشت:

$$s(t) = h(x(t)) \quad \mathbb{R}^k \rightarrow \mathbb{R} \quad (3)$$

$$y(t) = [s(t), s(t+T), s(t+2T), \dots, s(t+(d-1)T)]$$

که در آن $T = m\tau$ $m = (1, 2, 3, \dots)$ فاصله زمانی یا تاخیر نامیده می‌شود. بر طبق این قضیه با افزایش d ، بردار $y(t)$ بسیاری از خاصیت‌های دینامیکی مهم $x(t)$ را بازتولید می‌کند. بنابراین برای تحلیل بسیاری از ویژگی‌های سیستم، دیگر نیازی به $x(t)$ نخواهد بود. برای به کار بردن این قضیه به صورت موثر دو گام باید طی شود: در گام اول مقدار تاخیر یا همان T تعیین می‌شود و در گام دوم مقدار d یا همان بعد نشاننده (۱). در گام اول برای محاسبه تاخیر زمانی (T) می‌توان از تابع اطلاعات متقابل (Mutual Information) استفاده کرد (رابطه ۴). طبق آنچه که در مرجع (۷) آورده شده است T مناسب برابر است با اولین مینیمم این تابع.

$$I(\tau) = \sum_{s(t), s(t+\tau)} \Pr(s(t), s(t+\tau)) \log \left[\frac{\Pr(s(t), s(t+\tau))}{\Pr(s(t)) \Pr(s(t+\tau))} \right] \quad (4)$$

که در آن t ، تعداد کل داده‌های سری زمانی، $\Pr(S(t))$ و

پیش‌بینی

بطور کلی استفاده از تئوری‌های ریاضی در ارزیابی آشوبناکی پدیده‌های هیدرولوژیکی و سپس پیش‌بینی این پدیده‌ها می‌تواند کمک شایانی در برنامه ریزی مدیریت منابع آب داشته باشد. پیش‌بینی ابزاری است برای کمک به تصمیم‌گیری، بنابراین باید بتوان به کمک پیش‌بینی پاسخ سوال‌های تصمیم‌گیرنده را به دست آورد. ارزش پیش‌بینی به میزان سودمندی آن در زمان اتخاذ تصمیم بستگی دارد.

با توجه به رفتار آشوبناک سری زمانی تبخیر از سطح آب دریاچه ارومیه، امکان و قابلیت پیش‌بینی این نوسانات در گذر زمان وجود دارد. بدون شک تعیین مقادیر تبخیر از سطح آب دریاچه ارومیه موضوع با اهمیتی است که یک پیش‌بینی می‌تواند در برنامه ریزی و ارائه راهکارهای مدیریتی آتی مفید باشد. این امر با استفاده از الگوریتم نزدیکترین همسایگی در نرم افزار OpenTSTOOL صورت پذیرفته است.

مدل هوشمند شبکه عصبی مصنوعی

تئوری و طراحی شبکه‌های عصبی مصنوعی از چند دهه پیش شروع به گسترش کرده است و ماهیت غیرخطی بودن آنها سبب شده است که در بسیاری از مسائل پیچیده عملکرد مناسبی از خود نشان دهند. یکی از ساده‌ترین و کارآمدترین چیدمان‌های پیشنهادی برای استفاده در مدل‌سازی عصب‌های واقعی، مدل پرسپترون چند لایه یا به اختصار MLP (Multi Layers Perceptron) می‌باشد که از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه پنهان تشکیل شده است. در این ساختار تمام نرون‌های یک لایه به تمام نرون‌های لایه بعد متصل می‌باشند. در شکل (۲) نمونه‌ای از شبکه پرسپترون چند لایه (با یک لایه پنهان) مشاهده می‌گردد. همانطور که در شکل (۲) مشاهده می‌شود بر روی هر کدام از لایه‌ها تعدادی نرون به عنوان واحدهای پردازنده وجود دارند که با اتصالاتی وزن‌دار به یکدیگر متصل می‌شوند. نحوه اتصال نرون‌ها و چگونگی تنظیم پارامترهای آنها که از آن به عنوان الگوریتم یادگیری یاد می‌شود، منجر به نتایج متفاوتی از شبکه می‌شود (۲۸). طی فرآیند آموزش، وزن‌ها و مقادیر ثابتی که با آنها جمع می‌شوند و اصطلاحاً بایاس (Bias) نامیده می‌شوند، به طور پی‌درپی تغییر می‌کنند تا اینکه خطا به کمترین مقدار خود برسد. مدل عمومی شبکه‌های پرسپترون، شبکه‌های جلو رونده (Feed Forward) با روال آموزش انتشار به عقب (Back Propagation Training) است (شکل ۲). در شکل (۲) Xp ها و Yp ها به ترتیب ورودی‌های و خروجی‌های شبکه هستند. شکل (۳) نیز نحوه فرآیند و محاسبات انجام شده توسط یک نرون مصنوعی منفرد را نشان می‌دهد.

شعاع R را حول نقاط مشخصی از داده‌ها در نظر بگیریم، در این صورت تعداد نقاطی را که درون کره قرار می‌گیرند، بدون در نظر گرفتن مرکز کره، می‌توان به صورت زیر بیان کرد (۱۳):

$$C(R) = \frac{1}{N(N-1)} \sum_{i=0}^{(N-dT-1)} \sum_{j=0, j \neq i}^{(N-dT-1)} \Theta(R - |x(i) - x(j)|) \quad (8)$$

که در آن N معرف طول دامنه داده‌ها و $\Theta(x)$ عبارت است از تابع مشخصه هویساید:

$$\Theta(x) = \begin{cases} 0 & x < 0 \\ 1 & x \geq 0 \end{cases} \quad (9)$$

هنگامی که مقادیر R به صفر نزدیک می‌شود برای محاسبه نرخ تغییر $C(R)$ می‌توان نوشت:

$$C(R) = \lim_{R \rightarrow 0} kR^{D_C} \quad (10)$$

با حل رابطه بالا مقدار D_C بدست می‌آید:

$$D_C = \lim_{R \rightarrow 0} \frac{\ln C(R)}{\ln R} \quad (11)$$

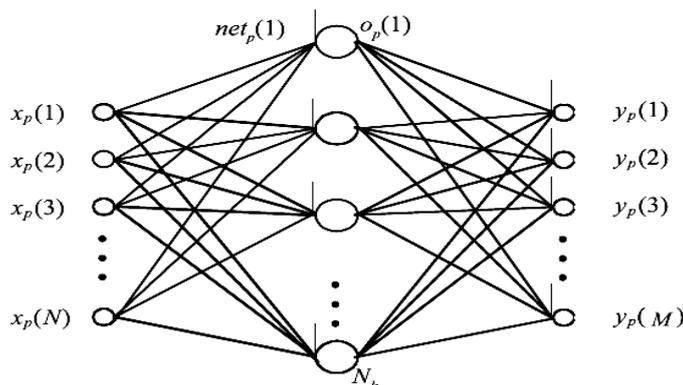
در این رابطه D_C بیانگر بعد همبستگی است. از آنجائیکه مجموعه داده‌ها پیوسته نخواهد بود، مقادیر R نمی‌تواند زیاد به صفر نزدیک شود (هیچ نقطه‌ای درون کره یافت نمی‌شود). به منظور بررسی آشوب‌پذیری و تخمین بعد همبستگی مناسب می‌توان دیاگرام $\ln C(R)$ نسبت به $\ln R$ را رسم کرد؛ شیب قسمت خطی این دیاگرام مقدار D_C را بدست می‌دهد. اگر D_C عددی غیر صحیح باشد، در این حالت یکی از معیارهای مهم آشوبناک بودن سیستم مورد بررسی بروز می‌کند (۹).

ب) نمای لیاپانوف

یک مشخصه مهم سیستم آشوبناک، حساسیت نسبت به شرایط اولیه است. برای نشان دادن میزان حساسیت پاسخ سیستم به تحریک‌های کوچک، این کمیت را ارزیابی می‌کنند (۲). نمای لیاپانوف λ_m با میانگین نرخ افزایشی به صورت زیر تعریف می‌شود (۲):

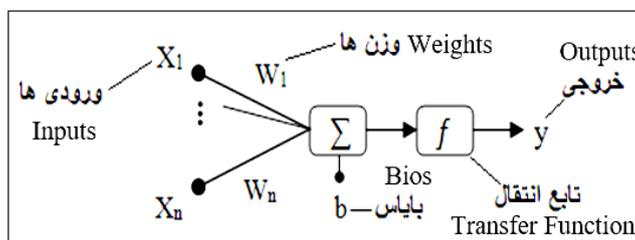
$$\lambda_m = \frac{1}{N\Delta t} \sum_{t=0}^{N-1} \ln \left| \frac{s(t+\Delta t) - s'(t+\Delta t)}{s(t) - s'(t)} \right| \quad (12)$$

در معادله (۱۲)، N تعداد کل داده‌ها، $S(t)$ تابع اسکالر بازسازی شده توسط بعد نشاننده، $S'(t)$ تابع اسکالر نزدیک به $S(t)$ و Δt بازه زمانی می‌باشد. مثبت بودن نمای لیاپانوف، نشان دهنده آشوب است (۲ و ۱۲). هر چه حساسیت به شرایط اولیه بیشتر باشد یا به عبارتی سیستم آشوبناک‌تر باشد، آنگاه دو نقطه با همسایگی بینهایت کوچک درحالت اولیه (بعد کم)، با افزایش بعد نشاننده به شدت از یکدیگر فاصله می‌گیرند.



شکل ۲- شبکه پرسپترون چند لایه با یک لایه پنهان (۲۸)

Figure 2- Multi-layer perceptron network with a hidden layer (28)



شکل ۳- مدل غیرخطی یک نرون مصنوعی منفرد

Figure 3- Nonlinear model of a simple neuron

معیارهای ارزیابی مدل‌ها

برای ارزیابی نتایج نظریه آشوب و شبکه عصبی مصنوعی در پیش‌بینی مقادیر تبخیر، از سه معیار خطا به شرح زیر استفاده می‌گردد: (الف) میانگین خطای مطلق (Mean Absolute Error):

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_{oi} - e_{pi}| \quad (15)$$

جزر میانگین مربعات خطا (Root Mean Squared Error):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (e_{oi} - e_{pi})^2} \quad (16)$$

ضریب تبیین (Determination Coefficient):

$$R^2 = \left[\frac{\sum_{i=1}^n (e_{oi} - \bar{e}_o)(e_{pi} - \bar{e}_p)}{\sum_{i=1}^n (e_{oi} - \bar{e}_o)^2 \sum_{i=1}^n (e_{pi} - \bar{e}_p)^2} \right]^2 \quad (17)$$

در این روابط n تعداد داده‌ها، e_{oi} مقدار تبخیر مشاهده شده، e_{pi} مقدار تبخیر پیش‌بینی شده، \bar{e}_o میانگین تبخیر مشاهداتی و \bar{e}_p میانگین تبخیر پیش‌بینی شده است. ضریب تبیین یک معیار

فرآیند صورت گرفته توسط این نرون را می‌توان از نظر ریاضی به صورت رابطه (۱۳) بیان نمود.

$$y = f \left(\sum_{i=1}^n W_i X_i + b \right) \quad (13)$$

که در آن X_i ورودی و W_i وزن متناظر با هر ورودی، b بایاس، f تابع انتقال و y خروجی نرون است (۲۸). برای استفاده از شبکه عصبی مصنوعی ابتدا باید داده‌های ورودی نرمال‌سازی شوند و سپس شبکه آموزش داده شود. این نرمال‌سازی با استفاده از رابطه (۱۴) صورت گرفته است که داده‌های ورودی را به بازه [۰ و ۱] انتقال می‌دهد.

$$x_n = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (14)$$

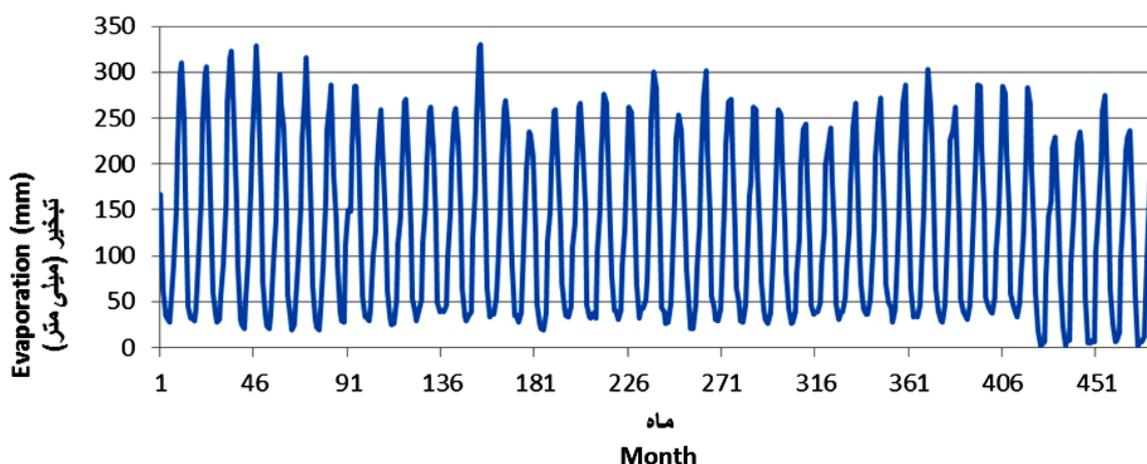
که در آن x_n داده نرمال شده و x_{\min} مینیمم داده در بازه مورد نظر و x_{\max} ماکزیمم داده در بازه مورد نظر و x_i داده نرمال نشده است. به منظور پیش‌بینی مقادیر تبخیر از سطح دریاچه ارومیه با استفاده از شبکه عصبی مصنوعی ابتدا شبکه با استفاده از بخشی از داده‌های تبخیر ثبت شده در گذشته آموزش داده می‌شود و پس از صحت‌سنجی نتایج در نهایت شبکه برای پیش‌بینی مقادیر تبخیر ماهانه از سطح دریاچه مورد استفاده قرار خواهد گرفت.

برای استفاده از قضیه ابعاد نشاننده مقدار تاخیر زمانی (T)، برابر با اولین مینیمم تابع اطلاعات متقابل در نظر گرفته می‌شود (شکل ۵). با توجه به شکل (۵)، زمان تاخیر داده‌ها برابر با ۵ ماه بدست می‌آید. همچنین مقادیر E1(d) محاسبه شده است (شکل ۶). با توجه به شکل (۶)، E1(d) تا مقدار مشخصی بالا رفته و سپس در d=۳ دچار یک پیچ‌خوردگی شده است، بنابراین بعد نشاننده برابر ۳ می‌شود. برای بررسی آشوبناک بودن این سیستم در ادامه به ترتیب مقادیر نمای لیاپانوف (شکل ۷) و بعد همبستگی (شکل ۸) آورده شده است. با توجه به شکل (۷)، بوضوح مشخص است که نمای لیاپانوف مثبت می‌باشد و این امر حاکی از رفتار کاملاً آشوبی سیستم و حساسیت آن نسبت به شرایط اولیه می‌باشد.

اندازه‌گیری برای نکویی برازش نتایج مدل ارائه شده می‌باشد. حداکثر مقدار این ضریب یک می‌باشد که نشان دهنده تناسب کامل نتایج مدل با داده‌های مشاهداتی است و حداقل مقدار آن نیز برابر با صفر است.

نتایج و بحث

تبخیر از سطح دریاچه، مهم‌ترین عامل خروج آب از دریاچه است که مقادیر ماهانه آن طی دوره شاخص مورد بررسی و برآورد قرار می‌گیرد. سری زمانی مقادیر ماهانه ارتفاع تبخیر از سطح دریاچه ارومیه طی یک دوره ۴۰ ساله در شکل (۴) رسم شده است. در جدول (۱) نیز خصوصیات آماری مقادیر تبخیر مورد استفاده در این تحقیق ارائه گردیده است.



شکل ۴- سری زمانی تبخیر ماهانه از سطح دریاچه ارومیه طی دوره ۴۰ ساله (۱۳۴۶-۱۳۸۶) (۱۰)

Figure 4- Monthly evaporation series of Urmia lake in the 40 years period (1967-2007) (10)

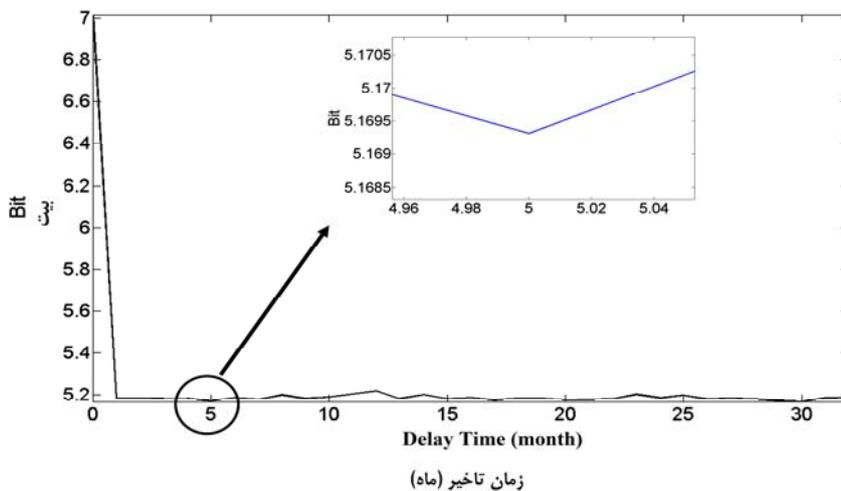
جدول ۱- مشخصات آماری مربوط به تبخیر ماهانه دریاچه ارومیه ۱۳۴۶-۱۳۸۶

Table 1- Statistical parameters of monthly evaporation of Urmia lake 1967-2007

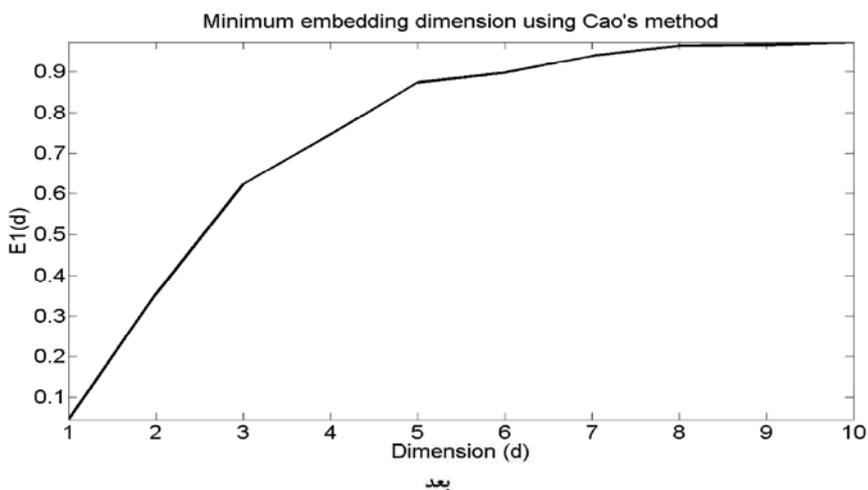
تعداد داده‌ها	میانگین (mm)	انحراف معیار (mm)	مقدار بیشینه (mm)	مقدار کمینه (mm)
Number of Data	Average	Standard Deviation	Maximum	Minimum
480	127.27	90.74	329.67	2.58

بنابراین رفتار سیستم غیر تصادفی است و سیستم قابلیت پیش‌بینی در گذر زمان را دارا می‌باشد. جهت پیش‌بینی تراز تبخیر توسط نظریه آشوب از الگوریتم پیش‌بینی موضعی، استفاده گردیده است. همچنین مقادیر تبخیر با استفاده از مدل شبکه عصبی مصنوعی مورد بررسی و پیش‌بینی قرار گرفته است. سپس به منظور صحت‌سنجی، نتایج حاصل از هر دو مدل با داده‌های مشاهداتی موجود مورد مقایسه قرار گرفته است.

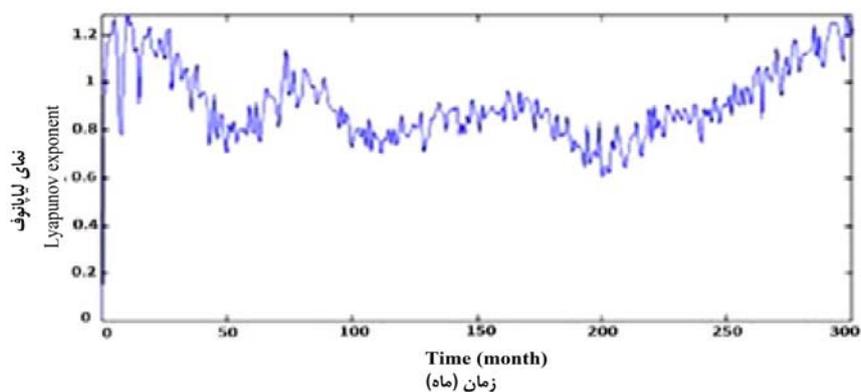
به منظور تعیین بعد همبستگی نیز، نمودار $\log C(R)$ در مقابل تغییرات $\log(R)$ در شکل (۸) رسم گردیده است. شیب قسمت خطی این دیاگرام با تقریب خوبی مقدار D_c را بدست می‌دهد. با توجه به شکل (۸) شیب نمودار بعد همبستگی، مقداری غیر صحیح (تقریباً برابر با ۲/۵) است که این امر نشانگر رفتار آشوبناک سیستم می‌باشد. در نهایت بررسی اجمالی شاخص‌های آشوب؛ نمای لیاپانوف مثبت و مقدار غیر صحیح (تقریباً برابر با ۲/۵) شیب نمودار بعد همبستگی، همگی نشانگر رفتار کاملاً آشوبناک این سیستم می‌باشد.



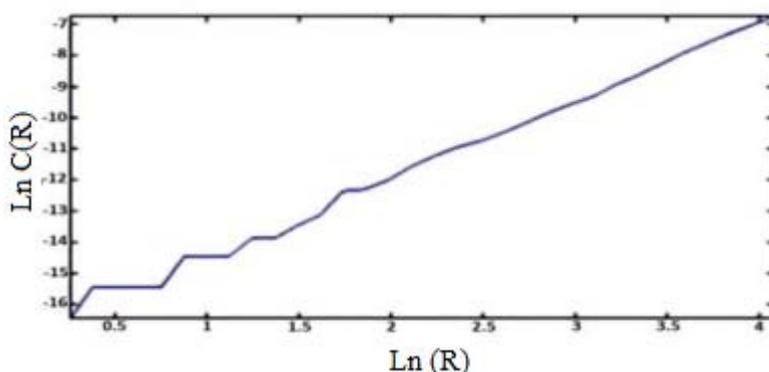
شکل ۵- تعیین زمان تاخیر با استفاده از تابع اطلاعات متقابل
 Figure 5- Determin delay time by mutual information function



شکل ۶- نمودار E1(d)
 Figure 6- E1(d) graph



شکل ۷- نمودار نمای لیاپانوف مثبت
 Figure 7- Positive Lyapunov exponent graph



شکل ۸- نمودار بعد همبستگی

Figure 8- Correlation dimension graph

تبخیر ماهانه با تبخیرهای ماه قبل، دو ماه قبل، یازده ماه قبل و دوازده ماه قبل به ترتیب برابر با ۰/۸۴، ۰/۴۶، ۰/۸۳ و ۰/۹۷ می‌باشد.

در مدل شبکه عصبی مصنوعی از ترکیبات متفاوتی از ورودی‌ها برای پیدا کردن بهترین ترکیب استفاده شده است. هم چنین در هر ترکیب با استفاده از سعی و خطا بهترین تعداد نرون لایه مخفی تعیین شده است (جدول ۲). در تمام موارد تعداد نرون‌های لایه مخفی بر اساس کمترین مقدار خطا تعیین شده است. همانطور که در جدول (۲) مشاهده می‌شود ترکیب هفتم دارای کمترین مقدار خطا و در نتیجه بهترین جواب می‌باشد. همچنین پس از بررسی سری زمانی تبخیر توسط نظریه آشوب مقادیر تبخیر ماهانه در یک بازه ده ساله (۱۳۷۶-۱۳۸۶) نیز با استفاده از این نظریه به منظور مقایسه با نتایج شبکه عصبی مصنوعی مورد پیش‌بینی قرار گرفت. نتایج حاصل از نظریه آشوب و بهترین ترکیب در مدل شبکه عصبی مصنوعی در جدول (۳) و شکل (۹) نشان داده شده‌اند.

در مدل شبکه عصبی مصنوعی انتخاب تعداد نرون‌های لایه مخفی از اهمیت زیادی برخوردار است. تا به حال تئوری خاصی برای تعیین نمودن تعداد نرون‌های لایه مخفی ارائه نشده است. معماری و هندسه شبکه نیز وابسته به تعداد نرون‌های لایه مخفی است. در این تحقیق از یک مدل شبکه عصبی مصنوعی پرسپترون سه لایه استفاده شده است و تعداد نرون‌های لایه مخفی با استفاده از سعی و خطا تعیین شده است. برای مقایسه بهتر بین مدل شبکه عصبی مصنوعی و نظریه آشوب، تنها از خود داده‌های تبخیر به عنوان ورودی برای شبکه عصبی مصنوعی استفاده شده است. با توجه به نوع داده‌های تبخیر ماهانه و بر اساس ضریب همبستگی بین مقادیر تبخیر با تاخیرهای آن، چهار تاخیر به عنوان ورودی برای مدل شبکه عصبی در نظر گرفته شده است. این چهار تاخیر شامل تبخیر ماه قبل و دو ماه قبل و تبخیر در یازده و دوازده ماه قبل می‌باشد. دلیل انتخاب این چهار متغیر ضریب همبستگی بالای آنها با مقادیر تبخیر ماهانه نسبت به دیگر تاخیرها است. به طوری که مقادیر ضریب همبستگی میان

جدول ۲- نتایج مدل‌های مختلف شبکه عصبی مصنوعی

Table 2- Results of artificial neural network models

مدل Model	ترکیبات ورودی Input Combinations	تعداد نرون در لایه پنهان Hidden Layer Neurons	RMSE	MAE	R ²
1	e_{t-1}, e_{t-2}	6	21.58	16.55	0.94
2	e_{t-1}, e_{t-11}	7	18.6	14.51	0.95
3	e_{t-1}, e_{t-12}	8	18.51	14.27	0.96
4	$e_{t-1}, e_{t-2}, e_{t-11}$	8	17.73	14.15	0.96
5	$e_{t-1}, e_{t-2}, e_{t-12}$	7	17.47	13.23	0.96
6	$e_{t-1}, e_{t-11}, e_{t-12}$	5	17.24	13.3	0.97
7	$e_{t-1}, e_{t-2}, e_{t-11}, e_{t-12}$	7	14.67	10.96	0.97

جدول ۳- نتایج نظریه آشوب و بهترین ترکیب شبکه عصبی مصنوعی

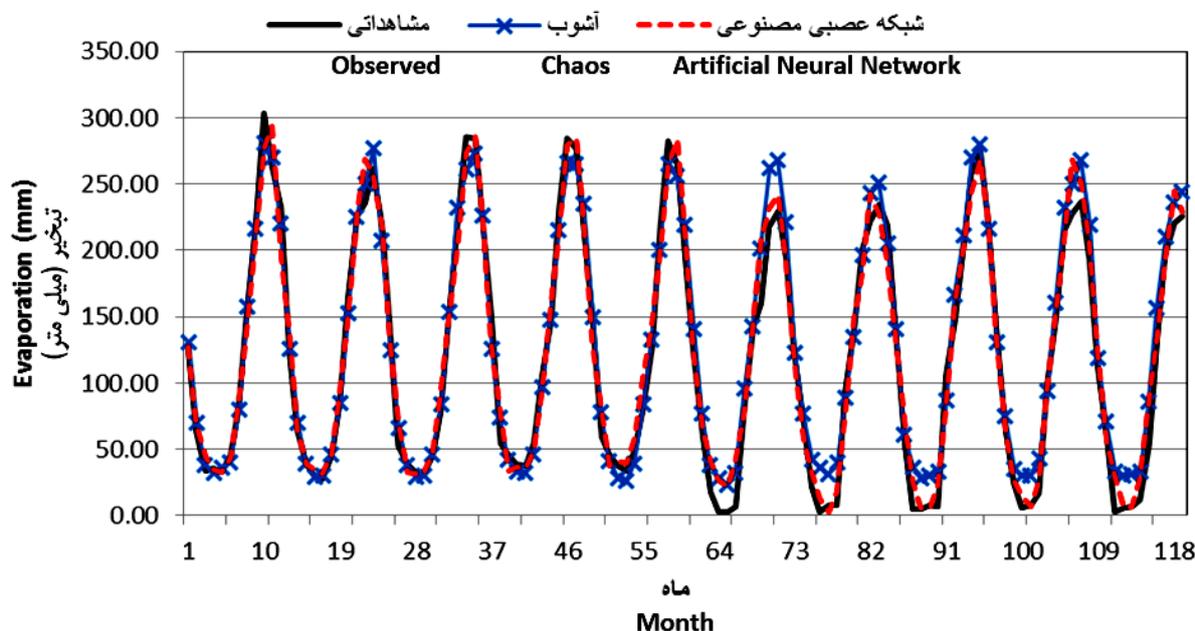
Table 3- Results of chaos theory and best combination of artificial neural network

مدل Model	RMSE	MAE	R ²
شبکه عصبی مصنوعی Artificial Neural Network	14.67	10.96	0.97
نظریه آشوب Chaos Theory	16.92	13.47	0.97

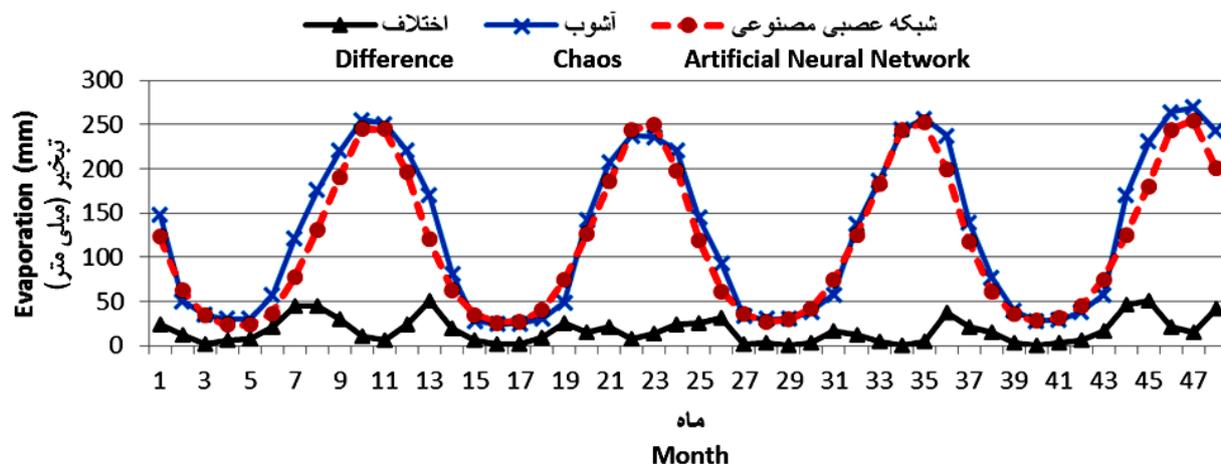
۴ سال (۱۳۸۶-۱۳۹۰) به صورت ماهانه در شکل (۱۰) نشان داده شده است. همچنین در نمودار شکل (۱۰) مقادیر اختلاف دو مدل ترسیم است. نتایج شکل (۱۰) نشان می‌دهد که رفتار دو مدل در ماکزیمم و مینیمم‌ها تا حدود زیادی شبیه به یکدیگر می‌باشد و اختلاف آنها ناچیز است. اما در دیگر نقاط اختلاف آنها بیشتر می‌شود و مدل شبکه عصبی مصنوعی مقادیر تبخیر را کمتر از مدل آشوب پیش‌بینی کرده است که این روند، در نمودار اختلاف رسم شده در شکل (۱۰) به خوبی نشان داده شده است. حداکثر و حداقل اختلاف پیش‌بینی در دو مدل شبکه عصبی مصنوعی و نظریه آشوب به ترتیب برابر با ۵۰/۵۴ و ۵۰ میلی‌متر است. همچنین مجموع ارتفاع تبخیر پیش‌بینی شده در کل بازه مورد بررسی در نظریه آشوب و شبکه عصبی مصنوعی به ترتیب برابر با ۶۱۲۶ و ۵۵۶۹ میلی‌متر است که تبخیر تجمعی نظریه آشوب ۵۵۷ میلی‌متر بیش از شبکه عصبی مصنوعی می‌باشد.

نتایج جدول (۳) و شکل (۹) حاکی از دقت قابل قبول و خوب نظریه آشوب و مدل شبکه عصبی مصنوعی - اندکی دقت بالاتر - در پیش‌بینی میزان تبخیر از سطح آب دریاچه دارد. هر دو مدل دارای ضریب تبیین ۰/۹۷ می‌باشند اما مقادیر میانگین خطای مطلق (MAE) و جذر میانگین مربعات خطا (RMSE) در نظریه آشوب به ترتیب از مقادیر ۱۳/۴۷ و ۱۶/۹۲ به مقادیر ۱۰/۹۶ و ۱۴/۶۷ در شبکه عصبی مصنوعی کاهش یافته است. همچنین مقدار مجموع ارتفاع کل تبخیر تخمین زده شده توسط شبکه عصبی مصنوعی و نظریه آشوب در طول بازه ده ساله (۱۳۷۶-۱۳۸۶) به ترتیب برابر با ۱۴۸۴۸ و ۱۵۳۹۱ میلی‌متر است در حالیکه که مقدار مشاهداتی آن برابر با ۱۴۲۹۰ میلی‌متر است که نشان دهنده دقت بالاتر شبکه عصبی مصنوعی دارد.

پس از صحت‌سنجی یک بازه ده ساله (۱۳۷۶-۱۳۸۶)، هر دو مدل برای پیش‌بینی یک بازه چهار ساله (۱۳۸۶-۱۳۹۰) مورد بررسی و مقایسه قرار گرفته‌اند. نتایج پیش‌بینی شده توسط هر دو مدل برای



شکل ۹- مقایسه صحت‌سنجی مدل‌ها با داده‌های مشاهداتی تبخیر (۱۳۷۶-۱۳۸۶)
Figure 9- comparison of models Results by observed evaporation data (1997-2007)



شکل ۱۰- پیش‌بینی سری زمانی تبخیر برای ۴ سال (۱۳۸۶-۱۳۹۰)
 Figure 10- Prediction of evaporation time series for 4 years (2007-2011)

نتیجه‌گیری کلی

که خطای مدل شبکه عصبی مصنوعی و نظریه آشوب در تخمین ارتفاع تجمعی تبخیر در انتهای بازه به ترتیب ۳/۹ و ۷/۷ درصد می‌باشد. در ادامه، مقادیر تبخیر از سطح دریاچه با استفاده از دو مدل برای ۴ سال آینده (۱۳۸۶-۱۳۹۰) پیش‌بینی گردیده است که نتایج نشان داد هر دو مدل در پیش‌بینی مقادیر تبخیر در آینده، به خصوص در تخمین مقادیر پیک و مینیمم، رفتاری تقریباً مشابه دارند اما در دیگر مقادیر دارای اندکی اختلاف هستند. همچنین مقادیر تجمعی تبخیر در طول بازه چهارساله نشان داد که نظریه آشوب مقدار تجمعی تبخیر را ۱۰ درصد نسبت به شبکه عصبی مصنوعی بیشتر پیش‌بینی کرده است. در این تحقیق سعی گردید که کارایی دو مدل با ماهیت کاملاً متفاوت در تخمین و پیش‌بینی تبخیر مورد توجه و مقایسه قرار گیرد و پیشنهاد می‌گردد نتایج حاضر با نتایج روش‌های دیگر نظیر مدل‌های سری زمانی نیز مقایسه شوند.

در این تحقیق امکان و دقت پیش‌بینی تبخیر ماهانه از سطح دریاچه ارومیه توسط دو مدل نظریه آشوب و شبکه عصبی مصنوعی مورد مطالعه و بررسی قرار گرفته است. به همین منظور از داده‌های یک دوره ۴۰ ساله (۱۳۴۶-۱۳۸۶) تبخیر ماهانه دریاچه ارومیه استفاده شده است. جهت صحت‌سنجی نتایج مدل‌ها از آمار ۱۰ سال پایانی (۱۳۷۶-۱۳۸۶) استفاده شده است. نتایج صحت‌سنجی حاکی از برتری اندک مدل شبکه عصبی مصنوعی نسبت به نظریه آشوب دارد به طوری‌که هر دو مدل دارای مقدار ضریب تبیین یکسان (۰/۹۷) هستند اما مقادیر میانگین خطای مطلق (MAE) و جذر میانگین مربعات خطا (RMSE) در مدل شبکه عصبی مصنوعی به ترتیب بیش از ۱۸ و ۱۳ درصد نسبت به نظریه آشوب بهبود یافته است. همچنین نتایج مربوط به بازه ده ساله صحت‌سنجی (۱۳۷۶-۱۳۸۶) نشان می‌دهد

منابع

- 1- Abarbanel H. 1996. Analysis of observed chaotic data. Springer, Verlag, New York.
- 2- Banks J., Dragan V. and Jones A. 2003. Chaos, a mathematical introduction. Cambridge University Press.
- 3- Cao L. 1997. Practical method for determining the minimum embedding dimension of scalar time series. Physica D: Nonlinear Phenomena, 110:43-50.
- 4- Damle C., and Yalcin A. 2007. Flood prediction using time series data mining. Journal of Hydrology, 333:305-316.
- 5- Dong N.H., Nguyen T.H., Snasel V. 2015. A hybrid approach for predicting river runoff. Intelligent Data analysis and Applications, 370:61-71.
- 6- Elshorbagy A., Simonovic S.P., and Panu U.S. 2002. Estimation of missing stream flow data using principles of chaos theory. Journal of Hydrology, 255:123-133.
- 7- Frazier C., and Kockelman K. 2004. Chaos theory and transportation systems: An instructive example. Proc of 83th Annual Meeting of the Transportation Research Board, Washington D.C., USA.
- 8- Ghaheri A., Ghorbani M.A., Del Afrooz H., Malekani L. 2012. Evaluation of stream flow using chaos theory. Iran Water Research Journal, 6(10):177-186. (in Persian with English Abstract)
- 9- Grassberger P., Procaccia I. 1983. Characterization of strange attractors. Physical Review Letters, 50 (14):346-349.
- 10- Hassanzadeh, E. 2010. Partitioning impacts of climate and hydraulic structures on water level of Urmia

- lake (Master Thesis). University of Tabriz, Iran. (in Persian with English Abstract)
- 11- Hassanzadeh Y., Aalami M.T., Farzin S., Sheikholeslami S.R., Hassanzadeh E. 2012. Study of chaotic nature of daily water level fluctuations in Urmia lake. *Journal of Civil Engineering and Environment*, 42(1):9-20. (in Persian with English Abstract)
 - 12- Hassanzadeh Y., Lotfollahi-Yaghin M.A., Shahverdi S., Farzin S., Farzin N. 2013. De-noising and prediction of time series based on the wavelet algorithm and chaos theory (case study: SPI drought monitoring index of Tabriz city). *Iran-Water Resources Research*, 8(3):1-13. (in Persian with English Abstract)
 - 13- Hilborn R.C. 2000. *Chaos and Nonlinear Dynamics*. Oxford University Press.
 - 14- Khatibi R., Ghorbani M.A., Aalami M.T., Kocak K., Makarynskyy O., Makarynska D., and Aalinezhad M. 2011. Dynamics of hourly sea level at Hillarys Boat harbour, Western Australia: a chaos theory perspective. *Ocean Dynamics*, 61:1797-1807.
 - 15- Khatibi R., Naghipour L., Ghorbani M.A., Aalami M.T. 2013. Predictability of relative humidity by two artificial intelligence techniques using noisy data from two Californian gauging stations. *Neural Computing and Applications*, 23(7):2241-2252.
 - 16- Khan S., Ganguly A.R., and Saigal S. 2005. Detection and predictive Modeling of chaos in finite hydrological time series. *Nonlinear Processes in Geophysics*, 12: 41-53.
 - 17- Kim S., Shiri J., Kisi O., Singh V.P. 2013. Estimating daily pan evaporation using different data-driven methods and lag-time pattern. *Water Resources Management*, 27:2267-2286.
 - 18- Kocak K., Bali A., and Bektasoglu B. 2007. Prediction of monthly flows by using chaotic approach. p. 553-559. *International Congress on River Basin Management*, 22-24 March, Antalya, Turkey, 4 (117).
 - 19- Ng W., Panu U., Lenox W. 2007. Based analytical techniques for daily extreme hydrological observations. *International Journal of Hydrology*, 342:17-41.
 - 20- Regonda S.K., Sivakumar V., and Jain A. 2004. Temporal scaling in the river flow: Can it be chaotic? *Hydrological Sciences Journal*, 49(3):373-385.
 - 21- Shang P., Na X., and Kamae S. 2009. Chaotic analysis of time series in the sediment transport phenomenon. *Chaos Solitons and Fractals*, 41:368-379.
 - 22- Sivakumar B. 2000. Chaos theory in hydrology: important issues and interpretations. *Journal of Hydrology*, 227: 1-20.
 - 23- Solomatine D.P., Velickov S., and Wust J.C. 2001. Predicting water levels and currents in the north sea using chaos theory and neural networks. p. 1-11. *Proceeding of the Congress-International Association for Hydraulic Research*, 29th Iahr Congress, Beijing, China.
 - 24- Stehlik J. 1999. Deterministic chaos in runoff series. *Journal of Hydrology and Hydromechanics*, 47(4):271-287.
 - 25- Stermann J.D. 2000. *Business dynamics*. McGraw-Hill, Book Co, Boston.
 - 26- Terzi O. 2013. Daily pan evaporation estimation using gene expression programming and adaptive neural-based fuzzy inference system. *Neural Computing and Applications*, 23(3):1035-1044.
 - 27- Wu J., Lu J., and Wang J. 2009. Application of chaos and fractal models to water quality time series prediction. *Environmental Modeling & Software*, 24:632-636.
 - 28- Yu H.H., Jenq N.H. 2002. *Handbook of neural network signal processing*. CRC Press.
 - 29- Zounemat-Kermani M., Kisi O. 2015. Time series analysis on marine wind-wave characteristics using chaos theory. *Ocean Engineering*, 100:46-53.

Application of Chaos Theory and Artificial Neural Networks to Evaluate Evaporation from Lake's Water Surface

S. Farzin^{1*} - R. Hajiabadi² - M.H. Ahmadi³

Received: 21-10-2015

Accepted: 28-02-2016

Introduction: Dynamic nature of hydrological phenomena and the limited availability of appropriate mathematical tools caused the most previous studies in this field led to the random and the probabilistic approach. So selection the best model for evaluation of these phenomena is essential and complex. Nowadays different models are used for evaluation and prediction of hydrological phenomena. Damle and Yalcin (2007) estimated river runoff by chaos theory. khatibi et al (2012) used artificial neural network and gene expression programming to predict relative humidity. Zounemat and Kisi (2015) evaluated chaotic behavior of marine wind-wave system of Caspian sea. One of the important hydrological phenomena is evaporation, especially in lakes. The investigation of deterministic and stochastic behavior of water evaporation values in the lakes in order to select the best simulation approach and capable of prediction is an important and controversial issue that has been studied in this research.

Materials and Methods: In the present paper, monthly values of evaporation are evaluated by two different models. Chaos theory and artificial neural network are used for the analysis of stochastic behavior and capability of prediction of water evaporation values in the Urmia Lake in northwestern of Iran. In recent years, Urmia Lake has unpleasant changes and drop in water level due to inappropriate management and climate change. One of the important factors related to climate change, is evaporation. Urmia Lake is a salt lake, and because of existence valuable ecology, environmental issues and maintenance of ecosystems of this lake are very important. So evaporation can have an essential role in the salinity, environmental and the hydrological cycle of the lake.

In this regard, according to the ability of chaos theory and artificial neural network to analysis nonlinear dynamic systems; monthly values of evaporation, during a 40-year period, are investigated and then predicted. So that, 10 years of data are applied to model validation and a four-year time horizon is predicted by each model. In the present paper, a multi-layer perceptron network with a hidden layer are used. Number of neurons in the hidden layer is determined by try and error. Also different input combinations are used to find out the best artificial neural network model. Prediction accuracy of models is evaluated by three indexes. These three indexes are mean absolute error (MAE), root mean squared error (RMSE) and determination coefficient (R^2).

Results and Discussion: Results of chaotic parameters such as a positive lyapunov exponent and the correlation dimension non-integer slope indicate that evaporation values in the Urmia Lake have chaotic behavior. So these values have not stochastic behavior and can be predicted by suitable models. Chaos theory and artificial neural network are used for prediction in this paper. Values of MAE, RMSE and R^2 for validation data are 10.96, 14.67 and 0.97 for artificial neural network and 13.47, 16.92 and 0.97 for chaos theory, respectively. The determination coefficient is the same in the two models while the values of MAE and RMSE is lower in the artificial neural network. So error indexes indicate that the artificial neural network is slightly better than the chaos theory. In order to prediction by artificial neural network, The best input combination includes four time delays that they are values of a month ago, two months ago, eleven and twelve months ago. Because in the chaos theory only the evaporation time series is applied, in order to better comparison of artificial neural network and chaos theory, in the artificial neural network model only the evaporation time series is used. Results of the four-year time horizon indicate somewhat similar behavior of two models especially in the minimum and maximum values of time series. In the maximum and minimum value chaos theory and artificial neural network predict similar values while in the other values there are some difference and the artificial neural network model predicted values less than chaos theory.

Conclusions: The results obtained from the chaotic nature determination parameters of the evaporation data,

1- Assistant Professor, Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan University, Semnan, Iran

(*-Corresponding Author Email: saeed.farzin@semnan.ac.ir)

2- PhD Student, Department of Water Resources, Faculty of Civil Engineering, Iran University of Science and Technology, Tehran, Iran

3- PhD Student, Department of Hydraulics, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran

positive lyapunov exponent and the correlation dimension non-integer slope; indicate the chaotic behavior of study time series. Therefore, the system has a hidden pattern (i.e., the system isn't Stochastic). The verification results indicate the high accuracy of chaos theory and neural network models - a little more accurate - and it was found that both models have similar accuracy in prediction of the future evaporation values or data that haven't been recorded in the past.

Keywords: Hydrological phenomena, Lyapunov exponent, Prediction, Urmia lake