



شبیه‌سازی فرآیند بارش رواناب در حوزه آبخیز ناورود با مدل ولترای مرتبه محدود و شبکه‌های عصبی مصنوعی

مهسا حسنیور کاشانی^۱، محمدعلی قربانی^۲، یعقوب دین پژوه^۲ و صداقت شهرماد^۲

۱- دانشجوی دکتری، دانشگاه تبریز، (نویسنده مسوول: mahsakashani2003@yahoo.com)

۲- دانشیار، دانشگاه تبریز

تاریخ دریافت: ۹۲/۱/۲ تاریخ پذیرش: ۹۲/۶/۱۷

چکیده

در این تحقیق، مدل‌سازی فرآیند غیرخطی بارش- رواناب با استفاده از مدل خطی ولترا انجام می‌شود. بدین منظور، داده‌های بارش و رواناب همزمان مربوط به پانزده رویداد از حوزه آبخیز ناورود واقع در شمال کشور جمع‌آوری گردیده و به ترتیب ۷۰٪ و ۳۰٪ رویدادها برای آموزش و تست مدل بکار برده شدند. در نهایت، عملکرد مدل ولترا با شبکه عصبی پرسپترون چند لایه و با استفاده از پنج معیار عملکرد مختلف مورد مقایسه قرار گرفت. نتایج نشان داد که مدل هوشمند شبکه عصبی از توانایی بالاتری نسبت به مدل ولترا در پیش‌بینی‌های رواناب حوزه آبخیز ناورود برخوردار بود. بطورکلی، مدل خطی ولترا همانند سایر مدل‌های خطی در شبیه‌سازی فرآیند غیرخطی بارش- رواناب کارایی بالایی نداشته و نیاز به تعمیم مدل به مرتبه‌های بالاتر و کاهش تعداد پارامترهای قابل تخمین آن می‌باشد.

واژه‌های کلیدی: مدل ولترا، شبکه عصبی مصنوعی، فرآیند بارش- رواناب، شبیه‌سازی

مقدمه

زمینه‌های مختلف از جمله پردازش سیگنال و شناسایی سیستم استفاده شده است. شناسایی یک سیستم شامل تعیین پارامترهای آن بر اساس اطلاعات ورودی- خروجی می‌باشد. دیسکین و بونه (۵)، سیستم رواناب سطحی را با مدل ولترای مرتبه دوم بررسی کرده و خصوصیات هسته‌های آن را استخراج نمودند. پاپازافیرو (۱۷)، با استفاده از روش توسعه هسته‌ها بصورت دنباله‌ای از چند جمله‌ای‌های متعامد پاسخ حوزه را با مدل غیرخطی مرتبه دوم تعیین نمود. لابات و همکاران (۹)، روابط تابعی بین بارش و رواناب را در حوزه‌های سه بعدی کارستیک^۳ با استفاده از مدل‌های خطی مرتبه یک و غیرخطی مرتبه دو ولترا و با بکارگیری داده‌های روزانه و نیم ساعته بارش و رواناب بررسی نمودند. ساجیکومار و تانداوسوارا (۱۹)، شبکه عصبی پس انتشار خطا را با مدل ولترا جهت مدل‌سازی بارش- رواناب ماهانه تحت شرایط کمبود داده مورد مقایسه قرار دادند. چاو (۳)، مدل ولترای مرتبه دوم، تبدیل موجک و مدل کالمن را جهت شبیه‌سازی فرآیند غیرخطی بارش- رواناب دو حوزه واقع در تایوان ترکیب نمود. ماهسواران و خوسا (۱۱)، تبدیل موجک را با مدل ولترا برای پیش‌بینی یک ماه قبل دبی رودخانه‌ای واقع در هند بکار بردند.

مدل‌های هوش مصنوعی نیز از جمله مدل‌های جعبه سیاه هستند که هیچ فرض از پیش تعیین شده‌ای برای ساختار مدل ندارند. این مدل‌ها به این دلیل هوشمند

مدل‌سازی روابط بارش- رواناب از اقدامات مهم در انجام پروژه‌های منابع آب می‌باشد. رابطه بارش- رواناب بدلیل وجود خصوصیات متغیر زمانی و مکانی حوزه آبخیز و الگوهای زمانی و مکانی بارش از پیچیدگی و درجه غیرخطی بالایی برخوردار است. مدل‌های بارش- رواناب بر اساس میزان بازنمایی فرآیند فیزیکی تحت مطالعه، به سه دسته مدل‌های فیزیکی، مدل‌های مفهومی و مدل‌های جعبه سیاه تقسیم‌بندی می‌شوند (۱۴). مدل‌های فیزیکی و مفهومی فرآیند بارش- رواناب را با استفاده از خصوصیات هواشناسی و فیزیکی حوزه آبخیز شبیه‌سازی می‌کنند که معمولاً بدلیل نبود اطلاعات و داده‌های کافی، محققین در بکارگیری این مدل‌ها با محدودیت مواجه می‌شوند. از اینرو، هیدرولوژیست‌ها جهت مقابله با این مشکل استفاده از مدل‌های جعبه سیاه را پیشنهاد نمودند. از جمله مدل‌های جعبه سیاه، سری انتگرالی ولترا^۱ می‌باشد. طبق اظهارات سینگ (۲۰)، آموروکو و اورلب (۱) احتمالاً اولین محققینی بودند که از سری انتگرالی ولترا برای آنالیز سیستم‌های هیدرولوژی با معرفی مدل‌های سری تابعی (FSM)^۲ استفاده کردند. اطلاعات بیشتر در خصوص بکارگیری FSM در فرآیند بارش- رواناب را می‌توان در مطالعه موفوگلو (۱۲) کسب کرد. مدل ولترا یک مدل ریاضی چندجمله‌ای غیرخطی است که به ازای یک سری ورودی یک خروجی تولید می‌کند (۱۳). مدل ولترا در

شبهه‌سازی فرآیند بارش- رواناب حوزه‌ای واقع در ایلیونیز جنوبی مورد مقایسه قرار دادند.

هدف این تحقیق، ارزیابی عملکرد مدل خطی ولترای مرتبه اول در شبهه‌سازی فرآیند غیرخطی بارش- رواناب حوزه آبخیز ناورود و مقایسه آن با مدل غیرخطی شبکه عصبی مصنوعی می‌باشد. لازم به ذکر است که در برخی مطالعات انجام یافته نیز به مقایسه توانایی مدل‌های خطی با مدل‌های غیرخطی در شبهه‌سازی بارش- رواناب پرداخته شده است (۱۷، ۹، ۸).

مواد و روش‌ها

مفهوم مدل ولترا

مدل ولترا در علم ریاضی اولین بار توسط ولترا در سال ۱۸۸۷ معرفی شد (۱۴). سری ولترا یک سیستم غیرخطی ثابت زمانی را مدل‌سازی می‌کند. مدل ولترا که به انتگرال تلفیق تعمیم یافته غیرخطی معروف است بشرح زیر تعریف می‌گردد:

$$y_k = y_{0k} + \int_{-\infty}^{\infty} h(k; j)u(j)dj + \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(k; i, j)u(i)u(j)didi + \dots \quad (1)$$

یکی از مزایای مدل‌های ولترا اینست که خروجی سیستم رابطه خطی با هسته‌های ولترا دارد. عبارت دیگر، می‌توان با داشتن ورودی و خروجی‌های سیستم، هسته‌های ولترا را با حل چند معادله خطی تعیین نمود (۳). از جمله محدودیت‌های کاربرد مدل ولترا رشد سریع تعداد پارامترها با افزایش مرتبه و طول حافظه مدل می‌باشد که باعث بروز مشکلاتی زمانی که سیستم مورد نظر بشدت غیرخطی باشد می‌گردد. از اینرو، استفاده از ولترای با مرتبه محدود توصیه شده است (۶). از آنجایی که مدل‌های خطی نتایج نسبتاً خوبی می‌دهند (۳)، لذا در این تحقیق، عملکرد مدل ولترای خطی مرتبه اول برای مدل‌سازی فرآیند غیرخطی بارش- رواناب بررسی می‌شود. مدل ولترای مرتبه اول به‌صورت زیر بیان می‌شود:

$$y_k = \sum_{j=1}^{m_1} h(j)u_{k-j} + \varepsilon_k \quad (3)$$

شناسایی مدل ولترا:

یکی از مهم‌ترین اقدامات در مدل‌سازی ولترا از سیستم‌ها، تعیین هسته‌های آن می‌باشد. تاکنون، روش‌های مختلفی برای تعیین هسته‌های ولترا توسعه داده شده‌اند که از جمله این روش‌ها می‌توان به روش توابع اسپیلاین^۳ روش انتخاب^۴ (مانند روش بهینه‌سازی مستقیم مولفه‌ها^۵ و روش چند جمله‌ای‌های اورتونرمال^۶ و روش مفهومی‌سازی^۷)، روش حداقل مربعات و روش‌های مختلف هوش مصنوعی اشاره نمود. در این مطالعه، از روش حداقل

هستند که آنها با استفاده از بخشی از داده‌های یک سری زمانی قادر به شناسایی روابط بین داده‌ها می‌باشند. مدل شبکه عصبی مصنوعی^۱ از جمله مدل‌های هوشمند می‌باشد که در سال‌های اخیر نقش مهمی در حل سیستم‌های هیدرولوژیکی پیچیده‌ای که کسب اطلاعات یا درک کامل از آنها امکان‌پذیر نمی‌باشد، داشته است. شبکه‌های عصبی قادر به یادگیری روابط غیرخطی بین نمونه داده‌ها طی فرآیند آموزش می‌باشند. هاف و همکاران (۷)، یک شبکه عصبی پیشخور سه لایه با استفاده از هیتوگراف‌های بارش و هیدروگراف‌های رواناب طراحی کردند. ژو و فوجیتا (۲۳)، عملکرد شبکه عصبی پیشخور را با مدل فازی در مدل‌سازی بارش- رواناب مقایسه نمودند. پس از آن، مطالعات زیادی در رابطه با بکارگیری شبکه عصبی در شبهه‌سازی بارش- رواناب صورت گرفته است (۲۲، ۲۱، ۴). ناپیروکوسکی و پیوتروسکی (۱۵)، عملکرد مدل ولترا را با دو نوع از شبکه‌های عصبی مصنوعی در

که در آن، u و y به ترتیب ورودی (باران) و خروجی (دبی) مدل در زمان $k = -\infty, \dots, \infty$ ، $i, j = -\infty, \dots, \infty$ متغیرهای زمانی انتگرال، y_{0k} تابع مرتبه صفر و نشان‌دهنده وجود چاه یا منبع داخلی است که معمولاً حذف می‌شود. جمله دوم تابعی مرتبه اول یا انتگرال تلفیق متداول یک بعدی است و نشان‌دهنده یک عنصر خطی در سری تابعی است. این مشابه نمایش عمل سیستم خطی است که در آن $h(k; j)$ هیدروگراف واحد لحظه‌ای (IUH)^۲ یا هسته مرتبه یک را تشکیل دهد. جمله سوم تابعی مرتبه دوم یا انتگرال تلفیق دو بعدی است که یک عنصر غیرخطی را نشان می‌دهد. این تابع دارای هسته $g(k; i, j)$ مرتبه دوم است. جمله $m+1$ ام انتگرال تلفیق تعمیم یافته n بعدی است که در آن $h_n(t; s_1, s_2, s_3, \dots, s_n)$ یک IUH تعمیم یافته با بعد n می‌باشد (۲۰). فرم پیش‌گسسته ولترا بدین صورت تعریف می‌شود:

$$y_k = \sum_{j=1}^{m_1} h(j)u_{k-j} + \sum_{i=1}^{m_2} \sum_{j=1}^{m_2} g(i, j)u_{k-i}u_{k-j} + \dots + \varepsilon_k = y_{1k} + y_{2k} + \dots + \varepsilon_k \quad (2)$$

که در آن $h(j)$ و $g(i, j)$ به ترتیب هسته‌های خطی و غیرخطی ولترا را نشان می‌دهند. m_1 و m_2 طول داده‌های قسمت خطی و غیرخطی ولترا، y_{1k} و y_{2k} خروجی قسمت‌های خطی و غیرخطی مدل ولترا و ε_k نویز با میانگین صفر می‌باشند (۳).

1- Artificial neural network (ANN)

2- Instantaneous unit hydrograph

3- Spline functions

4- Selection method

5- Direct optimization of the ordinates

6- Orthonormal polynomials

7- Conceptualization method

پژوهشنامه مدیریت حوزه آبخیز سال ششم/ شماره ۱۲/ پاییز و زمستان ۱۳۹۴ ۳
 از پرکاربردترین نوع شبکه عصبی پیشخور به نام شبکه پرسپترون چند لایه (MLP)^۲ استفاده خواهد شد.

منطقه مورد مطالعاتی

حوزه آبخیز ناورود یکی از حوزه‌های آبخیز مهم غرب استان گیلان بین طول جغرافیایی ۴۸ درجه و ۳۵ دقیقه تا ۴۸ درجه و ۵۴ دقیقه شرقی و عرض جغرافیایی ۳۷ درجه و ۳۶ دقیقه تا ۳۷ درجه و ۴۵ دقیقه شمالی قرار گرفته است (شکل ۱). سر منشا طولانی‌ترین شاخه‌های رودخانه ناورود از دامنه‌های شرقی سلسله جبال البرز شروع شده و در نهایت به دریای خزر می‌پیوندند. متوسط بارندگی سالانه حوزه ۸۵۲/۷ میلی‌متر می‌باشد. مساحت حوزه حدود ۲۷۴ کیلومتر مربع، طول آبراهه اصلی ۳۲/۵ کیلومتر و شیب متوسط حوزه حدود ۱۳/۱۶ درصد است. در کل، حوزه آبخیز ناورود جزو حوزه‌های جنگلی با دامنه‌های بسیار شیبدار می‌باشد (۲). داده‌های مورد استفاده در این مطالعه، شامل داده‌های بارش مؤثر و رواناب مستقیم ۱۵ رویداد بین سال‌های ۱۳۸۳-۱۳۷۴ می‌باشد که ۱۱ رویداد (۷۰٪) برای آموزش و ۴ رویداد (۳۰٪) برای تست مدل‌ها در نظر گرفته شدند. داده‌های بارش مؤثر با استفاده از شاخص Φ و نیز هیدروگراف‌های رواناب مستقیم با استفاده از جداسازی دبی پایه از هیدروگراف‌های سیل به روش دبی ثابت بدست آمدند.

مقایسه عملکرد مدل‌ها

بمنظور ارزیابی عملکرد مدل‌های بکار رفته در این تحقیق از معیارهای عملکرد زیر استفاده گردید:
 ضریب کارایی ((CE)^۳:

$$CE = 1 - \frac{\sum_{i=1}^n (Q_i - \bar{Q})^2}{\sum_{i=1}^n (Q_i - Q)^2} \quad (7)$$

که در آن، \bar{Q}_i دبی هیدروگراف شبیه‌سازی شده در پی‌ریود زمانی t_i ، Q_i دبی هیدروگراف مشاهداتی در پی‌ریود زمانی t_i ، \bar{Q} دبی متوسط هیدروگراف مشاهداتی در پی‌ریود زمانی t و n تعداد داده‌ها می‌باشد.
 جذر میانگین مربع خطا ((RMSE)^۴:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_i - \bar{Q})^2}{n}} \quad (8)$$

$$y_k = u_{1k}^T h + \varepsilon_k \quad (4)$$

که در آن $u_{1k} = [u_{k-1}, u_{k-2}, \dots, u_{k-m_1}]^T$ می‌باشد. مدل ولترا بیان شده در معادله (۴) در واقع مدل رگرسیون خطی می‌باشد که برای تخمین پارامتر خطی می‌باشد که روش OLS بکار برده می‌شود. این روش، معادله فوق را با مینیمم نمودن مربعات خطای بین خروجی‌های مشاهداتی (y_k) و محاسباتی (\hat{y}_k) حل می‌کند. تابع هدف F به صورت زیر تعریف می‌گردد:

$$F = \sum_{k=1}^n (y_k - \hat{y}_k)^2 \quad (5)$$

با حداقل نمودن مقدار تابع هدف، پارامتر هسته به صورت زیر برآورد می‌شود:


$$\hat{h} = [u_{1k} u_{1k}^T]^{-1} [u_{1k} y_k] \quad (6)$$

که در آن، u_{1k} ترانهاده u_{1k} می‌باشد. به منظور اجرای مدل ولترا، از آنجاییکه هیچ نرم‌افزاری در این خصوص وجود ندارد، لذا نویسندگان این مقاله اقدام به برنامه‌نویسی در محیط نرم‌افزار Maple که از قدرتمندترین نرم‌افزارهای ریاضی می‌باشد نمودند.
شبکه‌های عصبی مصنوعی (ANN):

ایده اصلی شبکه‌های عصبی بر مبنای شبیه‌سازی عملکرد مغز انسان بوده و همانند آن دارای قدرت یادگیری می‌باشد. در شبکه‌های عصبی سعی می‌شود بر اساس روابط ذاتی ما بین داده‌ها، نگاشتی غیرخطی ما بین متغیرهای مستقل و وابسته برقرار گردد. هر شبکه عصبی از تعداد زیادی گره (نرون) و پیوندهای جهت‌دار (وزن) که گره‌ها را به هم ارتباط می‌دهد، تشکیل شده است. این گره‌ها در لایه‌های ورودی، لایه پنهان و لایه خروجی قرار گرفته‌اند. الگوریتم یادگیری شبکه باید به گونه‌ای باشد که در طی آن مقادیر وزن‌ها، گام به گام تا به حداقل رسیدن مقدار خطای پیش‌بینی شبکه تعدیل شود. شبکه‌های عصبی بر اساس ساختار خود دارای انواع مختلفی می‌باشند. در این مطالعه،

1- Ordinary Least Squares (OLS)
 3- Coefficient of Efficiency

2- Multi-layer feed-forward perceptron (MLP)
 4- Root mean square error



شکل ۱- موقعیت حوزه آبخیز ناورود

به‌صورت سری بهم متصل شده و به‌عنوان ورودی مدل جهت کالیبراسیون بکار رفتند. تعداد پارامترهای مدل با استفاده از روش سعی و خطا جهت رسیدن به کمترین مقدار تابع هدف (F) برابر ۷۱ (طول هسته) انتخاب گردید. متغیرهای ورودی مدل، داده‌های باران مؤثر در زمان‌های $(t-1)$ ، $(t-2)$ ، ... $(t-71)$ و متغیر خروجی مقادیر رواناب در زمان t بودند. شکل ۲ هسته مرتبه اول حاصل از مدل ولترای کالیبره شده با روش OLS را نشان می‌دهد. با توجه به شکل می‌توان مشاهده نمود که روش OLS هسته کاملاً یکنواختی ارائه نمی‌دهد. منحنی هسته با یک اوج تند شروع شده سپس به سرعت شروع به کاهش کرده و در آخر یک روند بالارونده از خود نشان داده است. هسته‌های مرتبه اول بدست آمده برای ولترای مرتبه اول توسط لابات و همکاران (۹) با استفاده از روش‌های شناسایی مختلف نیز با یک اوج تند شروع شده که پس از کاهش ناگهانی، نوساناتی حول صفر در آخر منحنی داشتند.

خطای حجم کل (EV) :

$$V(\%) = \frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)}{\sum_{i=1}^n Q_i} \times 100\% \quad (9)$$

خطای دبی اوج (EQ_p (%)) :

$$EQ_p(\%) = \frac{Q_p - \hat{Q}_p}{Q_p} \times 100\% \quad (10)$$


که در آن \hat{Q}_p دبی اوج هیدروگراف شبه‌سازی شده و Q_p دبی اوج هیدروگراف مشاهداتی است. خطای زمان اوج (ET_p) :

$$ET_p = \hat{T}_p - T_p \quad (11)$$

که در آن \hat{T}_p زمان اوج هیدروگراف شبه‌سازی شده و T_p زمان اوج هیدروگراف مشاهداتی می‌باشد.

نتایج و بحث


در این تحقیق، ۱۱ رویداد بارش در سطح حوزه آبخیز



شکل ۲- هسته مدل ولترا مرتبه اول کالیبره شده با ۱۱ رویداد بارش- رواناب با استفاده از روش OLS

دقت بالایی پیش‌بینی می‌نماید. مدل MLP دبی‌های اوج را با دقت بیشتری برآورد می‌کند. این مدل زمان اوج را نیز با دقت بالایی تخمین می‌زند. جدول ۱ مقادیر معیارهای عملکرد هر دو مدل را ارائه می‌دهد. با توجه به این جدول، ملاحظه می‌شود که مقدار CE مدل ولترا (۰/۵۱) تقریباً کم و مقادیر EV ، EQ_p و $RMSE$ (بترتیب برابر ۲۴/۷۱٪، ۵۹/۵۷٪ و ۸/۳۳) زیاد می‌باشند. با این حال، مقدار ET_p (۱) کم و قابل قبول است. در مورد مدل MLP، مقدار CE (۰/۷۱)، $RMSE$ (۶/۳۸) و ET_p (۰) مدل قابل قبول هستند. بطورکلی، مدل ولترا نتایج ضعیفی نسبت به مدل MLP در مرحله کالیبراسیون نشان می‌دهد.

جهت اجرای مدل شبکه عصبی MLP در نرم‌افزار MATLAB، ابتدا داده‌های بارش مؤثر و رواناب استاندارد گردیدند. سپس مدل MLP با استفاده از الگوریتم آموزشی LM^۱ آموزش داده شد. بهترین ساختار شبکه به صورت ۱-۱-۷۱ (لایه ورودی با ۷۱ نرون، لایه پنهان با ۱ نرون و تابع انتقال تانژانت سیگموئید و لایه خروجی با ۱ نرون و تابع انتقال خطی) با استفاده از روش سعی و خطا و معیارهای عملکرد تعیین گردید. شکل ۳ نتایج کالیبراسیون مدل ولترا و MLP را نشان می‌دهد. با توجه به شکل مشاهده می‌گردد که مدل ولترا مقدار جریانات اوج را کم برآورد کرده ولی زمان‌های اوج را کم و بیش با



شکل ۳- نتایج کالیبراسیون حاصل از مدل‌ها با استفاده از ۱۱ رویداد و روش OLS


جدول ۱- معیارهای عملکرد مدل‌های ولترای مرتبه اول و MLP در مرحله آموزش

RMSE (m ³ /s)		CE		EV (%)		طول داده‌ها (ساعت)	رویداد
MLP	ولترا	MLP	ولترا	MLP	ولترا		
۶/۳۸	۸/۳۳	۰/۷۱	۰/۵۱	۰/۰۱	۲۴/۷۱	۱۵۸۲	۱۱ رویداد پیوسته
ET _p (hours)		EQ _p (%)				۱۵۸۲	۱۱ رویداد متصل بهم
MLP	ولترا	MLP	ولترا				
۰	۱	۶/۸۷	۵۹/۵۷				


: توجه: مقادیر قدر مطلق معیارهای عملکرد ارائه شده است.

می‌کند ولی مقدار دبی اوج رویدادهای ۱ و ۴ (شکل ۴ و ۷) کم برآورد شده‌اند. این مدل زمان اوج رویدادهای ۱، ۲ و ۴ (شکل ۴، ۵ و ۷) را دقیق‌تر از رویداد ۳ (شکل ۶) پیش‌بینی می‌کند. بطورکلی، مدل MLP و ولترا عملکرد یکسانی در پیش‌بینی زمان اوج رویدادهای ۱ تا ۳ نشان می‌دهند. هر دو مدل عملکرد ضعیفی در تخمین زمان اوج رویداد ۳ (شکل ۶) داشته‌اند. با این حال، مدل MLP در پیش‌بینی زمان اوج رویداد ۴ (شکل ۷) موفق‌تر از مدل ولترا عمل کرده است. مدل MLP دبی اوج رویداد ۱ و ۳ را بهتر از مدل ولترا تخمین می‌زند ولی برای رویدادهای ۲ و ۴ مدل ولترا توانایی بالایی در تخمین دبی‌های اوج نشان داده است.


شکل‌های ۴ تا ۷ رواناب مشاهداتی و شبه‌سازی شده با استفاده از مدل ولترا و MLP را مقایسه می‌کنند. با توجه به شکل‌های ۴، ۶ و ۷ مشاهده می‌گردد که مدل ولترا دبی اوج را با دقت کمی پیش‌بینی می‌کند. با این حال، این مدل دبی و زمان اوج را برای رویداد شماره ۲ (شکل ۵) بطور موفقیت‌آمیزی تخمین می‌زند. همچنین، این مدل زمان اوج را برای رویدادهای ۱ و ۴ (شکل ۴ و ۷) نسبت به رویداد ۳ (شکل ۶) با دقت بالایی برآورد می‌کند. نکته قابل توجه این است که مدل ولترا برای رویدادهای ۱ و ۳ (شکل ۴ و ۶) اوج دومی را در انتهای هیدروگراف نشان می‌دهد. این ممکن است بدلیل شکل هسته مرتبه اول باشد که یک روند بالارونده‌ای در انتهای خود داشته است. در مورد مدل MLP، همانطور که از شکل‌های ۵ و ۶ مشاهده می‌گردد مدل دبی اوج را با دقت بالایی برآورد




شکل ۴- نتایج تست مدل‌ها برای رویداد ۱



شکل ۵- نتایج تست مدل‌ها برای رویداد ۲



شکل ۶- نتایج تست مدل‌ها برای رویداد ۳



شکل ۷- نتایج تست مدل‌ها برای رویداد ۴

معیار EQ_p برابر $0.33/0.1$ است که بیانگر اینست که مدل ولترا برای سیستم‌های محافظت و هشدار سیل خیلی مناسب نیست. مقدار معیار عملکرد ET_p (با میانگین $3/5$ ساعت) نشان می‌دهد که مدل زمان‌های اوج جریان را با دقت نسبتاً بالایی تخمین می‌زند. با توجه به جدول، مقدار CE مدل MLP (متوسط 0.67) نسبتاً قابل قبول است.

جدول ۲ مقادیر معیارهای عملکرد مدل‌ها را در مرحله تست نشان می‌دهد. با توجه به جدول، ملاحظه می‌گردد مقدار میانگین CE مدل ولترا (0.38) خیلی پایین است. مقدار متوسط $RMSE$ ($10/49$) نسبتاً بالا می‌باشد. با توجه به مقدار متوسط معیار EV ($24/82$) این مدل خطای حجم کل زیادی را نشان می‌دهد. مقدار میانگین

مدل برای سیستم‌های محافظت و هشدار سیل مناسب می‌باشد. مقدار ET_p (با متوسط ۳ ساعت) معلوم می‌سازد که مدل زمان‌های اوج را بصورت معقولی تخمین می‌زند.

مقدار متوسط معیار $RMSE$ (۶/۱۹) تقریباً ۸٪ زیاد می‌باشد. با توجه به مقدار متوسط EV (۲/۳۱٪)، مدل خطای حجم کل کمتری را نشان می‌دهد. بر اساس معیار EQ_p ، مقدار متوسط مدل برابر ۱۱۸/۹۳٪ است که نشان می‌دهد این

جدول ۲- معیارهای عملکرد مدل ولترای مرتبه اول و MLP در مرحله تست

رویداد	RMSE (m ³ /s)		CE		EV (%)	
	ولترا	MLP	ولترا	MLP	ولترا	MLP
۱	۲۱/۴۶	۹/۰۵	۰/۵۱	۰/۹۱	۲۴/۸۲	۲/۷۵
۲	۳/۷۷	۲/۷۳	۰/۳۳	۰/۶۴	۲۴/۸۳	۴/۰۳
۳	۱۵/۴۶	۱۱/۹۱	۰/۴۰	۰/۶۴	۲۴/۸۴	۰/۰۲
۴	۱/۲۸	۱/۰۹	۰/۲۸	۰/۴۸	۲۴/۸۱	۲/۴۶
میانگین	۱۰/۴۹	۶/۱۹	۰/۳۸	۰/۶۷	۲۴/۸۲	۲/۳۱
رویداد	ET _p (hours)		EQ _p (%)			
	ولترا	MLP	ولترا	MLP	ولترا	MLP
۱	۲	۲	۲۰/۳۶	۵۶/۳۹		
۲	۱	۱	۷/۲۸	۱/۳۱		
۳	۸	۸	۳/۲۸	۳۶/۸۱		
۴	۳	۱	۴۴/۸۱	۳۷/۵۵		
میانگین	۳/۵	۳	۱۸/۹۳	۳۳/۰۱		

توجه: مقادیر قدر مطلق معیارهای عملکرد ارائه شده است.

موفقیت آمیز بوده است. ساجی کومار و تانداوسوارا (۱۹) شبکه عصبی را به عنوان یکی از کارآمدترین مدل‌های جعبه سیاه در شبه‌سازی فرآیند بارش-رواناب تایید نمودند. در این تحقیق، منطقه مورد مطالعه یک حوزه جنگلی بود که در آن احتمال دارد میزان گیرش، نفوذ و تبخیر زیاد باشد لذا رابطه بین بارش و رواناب می‌تواند بشدت غیرخطی باشد. همچنین، ثابت شده است که هر چقدر سطح حوزه بزرگتر باشد، از غیرخطی بودن آن کاسته می‌شود (۱۸). حوزه آبخیز ناورود را می‌توان با توجه به مساحت آن حوزه نسبتاً کوچکی در نظر گرفت و بنابراین خاصیت غیرخطی بودن آن نسبتاً زیاد خواهد بود. از آنجایی که شبکه عصبی یک مدل غیرخطی است بنابراین، فرآیند غیرخطی بارش- رواناب را می‌تواند با دقت کافی مدل‌سازی کند. از آنجایی که فرآیند بارش- رواناب متغیر در مکان می‌باشد لذا قابل انتظار است که هر دو مدل ولترا و MLP که به‌عنوان مدل‌های گرده‌ای در این مطالعه بکار برده شدند، خطاهایی در پیش‌بینی‌های خود نشان دهند.

به‌منظور بهبود عملکرد مدل ولترا، نیکولاو و ماتنا (۱۶) از تبدیل موجک برای کاهش تعداد پارامترهای قابل تخمین مدل استفاده کردند. همچنین، لاترمن (۱۰) دریافت که تنها اضافه کردن ترم دوم به مدل هیدرولوژی

بطورکلی، مقدار متوسط CE مدل MLP بیشتر از مقدار متوسط CE مدل ولترا می‌باشد. مدل MLP بر اساس معیار $RMSE$ بهتر از مدل ولترا عمل می‌نماید. با توجه به معیار EV ، مدل MLP عملکرد موفقیت‌آمیزی از مدل ولترا داشته است. بر اساس مقادیر معیار EQ_p ، می‌توان گفت مدل MLP باعث بهبود در پیش‌بینی‌های دبی اوج گردیده است. مقادیر معیار ET_p نشان می‌دهند که مدل MLP زمان اوج را تا حدودی بهتر از مدل ولترا تخمین می‌زند.

همانطور که مشاهده گردید، مدل ولترای مرتبه اول خطی توانایی بالایی در شبه‌سازی فرآیند بارش- رواناب حوزه آبخیز ناورود از خود نشان نداد. این نتیجه بدست آمده با نتایج پایازافیرو (۱۷)، ساجی کومار و تانداوسوارا (۱۹) و لابات و همکاران (۹) مطابقت دارد. علت این امر می‌تواند بخاطر ساختار خطی مدل باشد که آن را به قدر کافی قادر به شبه‌سازی فرآیند غیرخطی بارش-رواناب نمی‌سازد. یکی دیگر از دلایل ضعف مدل ولترای خطی، مربوط به نوع روش شناسایی آن است. همانطور که چاو (۳) دریافت که روش‌های کلاسیک مانند OLS به علت وجود تعداد زیاد پارامترهای قابل تخمین در مدل ممکن است برای شناسایی مدل ولترا از دقت بالایی برخوردار نباشند. در این مطالعه، عملکرد مدل شبکه عصبی تقریباً

تشکر و قدردانی

از همکار گرامی آقای دکتر اسماعیل اسدی بخاطر در اختیار گذاشتن اطلاعات حوزه آبخیز ناورود کمال تشکر و قدردانی را می‌نماید.

خطی کافی است. لذا توصیه می‌گردد در تحقیقات آتی از مدل ولترای مرتبه دوم برای شبیه‌سازی فرآیند بارش-رواناب حوزه ناورود و نیز از تبدیل موجک برای کاهش تعداد پارامترهای قابل تخمین مدل استفاده گردد.

منابع

1. Amoroch, J. and G.T. Orlob. 1961. Non-linear Analysis of Hydrologic Systems. Water Resources Center. University of California (Berkeley) U.S.A Contrib.40, 147 pp. Illus.
2. Asadi, E. 2010. Development of a conceptual Tank-Hybrid-Channel model for rainfall-runoff process simulation (case Study: Navrood Basin). Ph.D. Thesis. Department of Water Engineering. Faculty of Agriculture. University of Tabriz. (In Persian)
3. Chou, C.M. 2007. Efficient nonlinear modeling of rainfall-runoff process using wavelet compression. *Journal of Hydrology*. 332: 442-455.
4. Dibike, Y.B. and D.P. Solomatine. 2001. River flow forecasting using artificial neural networks. *Physics and Chemistry of the Earth (B)*. 26: 1-7.
5. Diskin, M.H. and A. Boneh. 1972. Properties of the kernels for time invariant, initially relaxed, second order, surface runoff systems. *Journal of Hydrology*. 17: 115-141.
6. Hacıoglu, R. and G.A. Williamson. 2001. Reduced Complexity Volterra Models for Nonlinear System Identification. *EURASIP Journal on Applied Signal Processing*. 4: 257-265.
7. Halff, A.H., H.M. Halff and M. Azmoodeh. 1993. Predicting Runoff from Rainfall using Neural Networks. In *Engineering Hydrology*, Kuo CY (ed.), Proceedings of the Symposium sponsored by the Hydraulics Division of ASCE, San Francisco, CA, ASCE: New York, 760-765.
8. Harun, S., N.I. Ahmat Nor and A.H.M. Kassim. 2002. Artificial neural network model for rainfall-runoff relationship. *Journal Technology*, 37: 1-12.
9. Labat, D., R. Ababou and A. Mangin. 1999. Linear and nonlinear input/output models for karstic springflow and flood prediction at different time scales. *Stochastic Environmental Research and Risk Assessment*. 13: 337-364.
10. Lattermann, A. 1991. *System-Theoretical Modelling in Surface Water Hydrology*. Springer. Germany. 200 pp.
11. Maheswaran, R. and R. Khosa. 2012. Wavelet-Volterra coupled model for monthly stream flow forecasting. *Journal of Hydrology*. 450-451: 320-335.
12. Muftuoglu, R.F. 1984. New models for non-linear catchment analysis. *Journal of Hydrology*. 73: 335-357.
13. Muftuoglu, R.F. 1991. Monthly runoff generation by non-linear models. *Journal of Hydrology*. 125: 277-291.
14. Napiórkowski, J.J. 1986. Application of Volterra series to modeling of rainfall-runoff systems and flow in open channels. *Hydrological Sciences Journal*. 31, 2, 6: 187-203.
15. Napiórkowski, J.J. and A. Piotrowski. 2005. Artificial neural networks as an alternative to the volterra series in rainfall-runoff modeling. *Acta Geophysica Polonica*. 53: 459-472.
16. Nikolaou, M. and D. Mantha. 2000. Efficient nonlinear modeling using wavelet compression. In: *Progress in Systems and Control Theory*. vol. 26. Boston.
17. Papazafiriou, Z.G. 1976. Linear and nonlinear approaches for short-term runoff estimations in time invariant open hydrologic systems. *Journal of Hydrology*. 30: 63-80.
18. Rui, X.F. 2004. *The Principle of Hydrology*. China Water Power Press. Beijing. 143-152.)
19. Sajikumar, N. and B.S. Thandaveswara. 1999. A non-linear rainfall-runoff model using an artificial neural network. *Journal of Hydrology*. 216: 32-55.
20. Singh, V.P. 1988. *Hydrologic Systems. Rainfall-Runoff Modeling*, 1, Prentice Hall Englewood Cliffs. New Jersey. 480 pp.
21. Suhaimi, S. and R.A. Bustami. 2009. Rainfall-runoff modelling using radial basis function neural network for Sungai Tinjar catchment, Miri, Sarawak. *J Civil Eng*. 1: 1-7.
22. Tokar, A.Z. and P.A. Johnson. 1999. Rainfall-runoff modeling using artificial neural network. *Journal of Hydrologic Engineering ASCE*. 4: 232-239.
23. Zhu, M.L. and M. Fujitha. 1994. Comparison between fuzzy reasoning and neural networks methods to forecast runoff discharge. *Journal of Hydrosience and Hydraulic Engineering*. 12: 131-141.

Rainfall-Runoff Simulation in the Navrood River basin using Truncated Volterra Model and Artificial Neural Networks

Mahsa Hasanpour Kashani¹, Mohammad Ali Ghorbani², Yaghoub Dinpazhouh² and Sedaghat Shahmorad²

1-Ph.D. Student, University of Tabriz (Corresponding author: mahsakashani2003@yahoo.com)

2- Associate Professor, University of Tabriz

Received: March 22, 2013 Accepted: September 8, 2013

Abstract

This study evaluates the performance of the linear first-order Volterra model for simulating nonlinear rainfall-runoff process. For this end, fifteen storm events over the Navrood River basin were collected. 70% and 30% of the events were used to calibrate and test the suitability of the model. Finally, the performance of the model was compared with the artificial neural networks (multilayer perceptron (MLP)) using five performance criteria namely; coefficient of efficiency, root mean square error, error of total volume, relative error of peak discharge and error of time for peak to arrive. Results indicated that the intelligent MLP models outperformed the Volterra model. The linear Volterra model was not more effective in simulating the rainfall-runoff process. It needs to be extended to higher orders and also the number of the parameters should be reduced.

Keywords: Volterra model, Artificial Neural Network, Rainfall-runoff process, Simulation