

بررسی کاربرد مدل‌های هوش محاسباتی در شبیه‌سازی و پیش‌بینی بهنگام جریان‌های سیلابی

محمدتقی دستورانی^۱

چکیده

در این تحقیق توانایی مدل‌های شبکه عصبی مصنوعی جهت شبیه‌سازی رفتار هیدرولوژیکی آب در حوزه‌های آبخیز مورد بررسی قرار گرفته است. هدف اصلی تحقیق بررسی کاربرد انواع مختلف شبکه‌های عصبی مصنوعی جهت شبیه‌سازی جریان در یک حوزه آبخیز با چند ایستگاه هیدرومتری و پیش‌بینی بهنگام جریان‌های سیلابی در پایین دست بوده است. منطقه مورد بررسی قسمت فوقانی رودخانه درونت (Derwent) می‌باشد که یکی از شاخه‌های اصلی رودخانه ترنت (Trent river) در ناحیه مرکزی انگلستان است. جریان سیلاب رودخانه ۳، ۶، ۹ و ۱۲ ساعت قبل از وقوع در محل ایستگاه هیدرومتری واتستندول (Whatstandwell) با استفاده از داده‌های اندازه‌گیری شده در بالا دست پیش‌بینی گردیده است. سه نوع شبکه عصبی مختلف که عبارت‌اند از شبکه پرسپترون چند لایه (MLP network)، شبکه برگشتی (Recurrent network) و شبکه برگشتی با تأخیر زمانی (Time lag recurrent network) به صورت جداگانه مورد استفاده و ارزیابی قرار گرفتند. هم‌چنین جهت بررسی تأثیر طول داده‌های ورودی در کارایی مدل‌های شبکه عصبی، شبیه‌سازی‌های مختلف با استفاده از داده‌های هیدرولوژیکی با طول و تعداد متفاوت مورد استفاده قرار گرفت. داده‌های با فاصله اندازه‌گیری ۳۰ دقیقه‌ای با طول دوره‌های ۱ ماه، ۶ ماه و سه سال (که تولید تعداد مشاهده‌های متفاوتی را می‌نماید) بدین منظور مورد استفاده واقع شد. براساس نتایج به دست آمده هرچند شبکه‌های عصبی مصنوعی به صورت عمومی و کلی کارایی مناسبی را در شبیه‌سازی و پیش‌بینی دبی جریان از خود نشان داده‌اند ولی نوع شبکه عصبی مصنوعی و نیز خصوصیات داده‌های ورودی مدل خصوصاً داده‌های آموزشی پارامترهای بسیار مهمی هستند که تأثیر عمده‌ای را روی خروجی‌های مدل دارند.

واژه‌های کلیدی: پیش‌بینی سیلاب، شبکه عصبی مصنوعی، پیش‌بینی بهنگام سیل، مدل‌سازی سیلاب، پیش‌بینی جریان رودخانه

مقدمه

اهمیت فراوانی می‌باشد. پیش‌بینی به هنگام و خصوصاً مدت زمان بین تکمیل پیش‌بینی یک واقعه و اتفاق آن واقعه مهمترین پارامتر در اجرای موفقیت آمیز سیستم‌های هشدار سیلاب است. پیش‌بینی درست سیلاب با مدت زمان کافی قبل از وقوع در حوزه‌های آبخیز کوچک که غالباً زمان تمرکز کوتاهی نیز دارند

در سال‌های اخیر مدل‌سازی کامپیوتری بعضی از عوامل پایه‌ای هیدرولوژی و هیدرولیک توسعه چشمگیری داشته است. پیش‌بینی جریان‌های سیلابی در اغلب حوزه‌ها خصوصاً پیش‌بینی به هنگام آن از نقطه نظر کاهش خسارات سیلاب حائز

۱. استادیار آبخیزداری، دانشکده منابع طبیعی، دانشگاه یزد

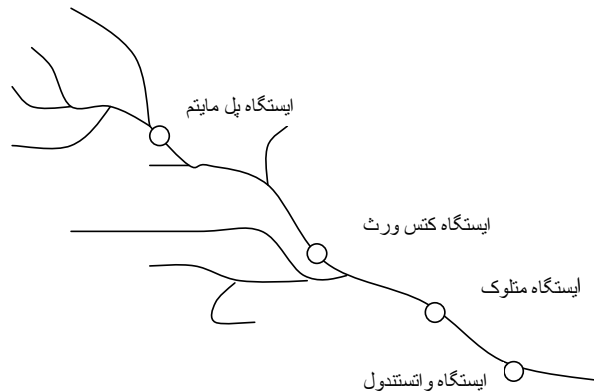
کاری بسیار مشکل و پیچیده بوده و بستگی کامل به صحت پیش بینی وضعیت هواشناسی محل دارد. در حوزه‌های بسیار کوچک در هر حال پیش بینی سیلاب وابستگی زیادی به شدت بارندگی داشته و تأثیرپذیری فوق العاده‌ای از این عامل دارد. ولی برای حوزه‌های بزرگ‌تر خصوصیات جریان و نیز شرایط حوزه و رودخانه تأثیرات بسیار زیادی روی وضعیت جریان در پایین دست و طبیعتاً روی پیش بینی به موقع و صحیح آن دارد. عواملی مانند ذخیره‌های داخلی حوزه، ذخیره رودخانه‌ای و پس زدگی آب و احیاناً اثرات امواج و جذر و مد در قسمت‌های متصل به دریا مواردی هستند که روی پیش بینی بهینه سیلاب در حوزه‌های بزرگ‌تر تأثیر می‌گذارند.

پیش بینی قابل اطمینان دبی جریان و نیز تغییرات آن در طول رودخانه بخش ضروری از پروژه‌های برنامه ریزی و مدیریت آب‌های سطحی می‌باشد. علاوه بر آن پیش بینی وضعیت در پایین دست براساس داده‌های اندازه‌گیری شده در بالا دست کمک شایانی به تصمیم‌گیری در رابطه با کاهش خسارات و احیاناً امکان طراحی و اجرای مخازن ذخیره و تنظیم جریان مازاد قبل از رسیدن به پهنه‌های خسارت بار خواهد نمود.

تکنیک شبکه عصبی مصنوعی به عنوان یک ابزار کارآمد با توانایی مناسب به صورت گسترده‌ای در زمینه‌های مختلف مورد استفاده واقع شده است که عرصه‌های مختلف تحقیقات مربوط به آب را نیز پوشش می‌دهد. در این زمینه می‌توان از کاربرد شبکه‌های عصبی مصنوعی در مدل‌سازی رابطه بارندگی - رواناب به تحقیقات انجام شده توسط برخی محققین اشاره نمود (۷، ۹، ۱۱ و ۱۲). در این تحقیقات با معرفی اطلاعات اقلیمی و فیزیکی مربوط به حوزه‌های آبخیز همچون بارندگی، دما، تبخیر، وسعت و شیب به مدل‌های شبکه عصبی مصنوعی حجم و دبی رواناب در محل خروجی پیش بینی شده که اغلب نتایج امیدوار کننده‌ای را نیز در بر داشته است. در تحقیق دیگری که نگارنده قبلاً (۵) به انجام رساند کاربرد شبکه‌های عصبی مصنوعی در پیش بینی جریان در حوزه‌های فاقد آمار و هم‌چنین کاربرد این تکنیک در شناسایی و طبقه بندی

حوزه‌هایی که از نظر هیدرولوژیکی مشابه هستند مورد ارزیابی قرار گرفت و در هر دو مورد نتایج مناسبی را ارائه نمود. هم‌چنین در زمینه پیش بینی جریان رودخانه با مدل‌های شبکه عصبی مصنوعی می‌توان به تحقیقات کارونایتی و دیگران در سال ۱۹۹۴ اشاره کرد (۱۰). در این تحقیقات دو ساختار متفاوت از شبکه عصبی مصنوعی جهت پیش بینی وضعیت جریان رودخانه با استفاده از داده‌های بارش مورد ارزیابی قرار گرفت و در مقایسه با روش‌های موجود نتایج بهتری را ارائه داد. هم‌چنین در رابطه با کاربرد شبکه عصبی مصنوعی در تعیین رابطه دبی و اشل به تحقیقات انجام شده توسط محققینی می‌توان اشاره کرد که در آن نامبردگان با کالیبره کردن شبکه عصبی مصنوعی به وسیله داده‌های اشل - دبی مربوط به گذشته توانستند فقط با وارد کردن مقادیر اشل مقدار دبی مربوطه را با دقت کافی برآورد کنند (۳). در ایران نیز در این زمینه بررسی‌هایی صورت گرفته است. از آن جمله می‌توان به پروژه تحقیقاتی که نگارنده در خصوص کاربرد شبکه‌های عصبی مصنوعی در بازسازی داده‌های هیدرولوژی انجام داده اشاره کرد (۲). در این پروژه تحقیقاتی سعی شد که مقادیر مربوط به نواقص آماری ایستگاه‌ها با استفاده از مقادیر ایستگاه‌های دیگر موجود در گروه مربوطه و به کمک ساختار مناسبی از شبکه‌های عصبی مصنوعی برآورد گردد. جهت امکان مقایسه این روش با روش‌های موجود نتایج حاصل از شبکه‌های عصبی مصنوعی با نتایج روش نسبت نرمال و روش هم‌بستگی بین ایستگاه‌ها مورد بررسی و مقایسه قرار گرفت و مشخص شد که تکنیک شبکه‌های عصبی در مقایسه با این روش‌ها نتایج مناسب‌تری از خود نشان داده است.

در تحقیق حاضر سعی شده کارایی مدل‌های مختلف شبکه عصبی مصنوعی در شبیه سازی تغییرات دبی جریان در فواصل بین سایت‌های مختلف اندازه‌گیری مورد ارزیابی قرار گیرد و نهایتاً کارایی هر یک از این شبکه‌ها در پیش بینی بهنگام جریان در نقطه‌ای در پایین دست رودخانه و براساس داده‌های مختلف مورد آزمون و تجزیه و تحلیل قرار گیرد. سه نوع ساختمان



شکل ۱. تصویر شماتیک موقعیت ایستگاه‌های هیدرومتری مورد استفاده نسبت به هم در حوزه درونت

مربوط به ماه ژانویه ۱۹۹۹، شش ماه اول سال ۲۰۰۰ و نهایتاً داده‌های سال‌های ۱۹۹۸، ۱۹۹۹ و ۲۰۰۰ به صورت جداگانه در قالب تست‌های مختلف شبیه‌سازی مورد استفاده قرار گرفت. برای هر تست، داده‌ها به سه قسمت تقسیم شد قسمت اول جهت استفاده به عنوان داده‌های آموزشی به منظور آموزش مدل، قسمت دوم جهت صحت‌یابی برای جلوگیری از آموزش کاذب و اضافی مدل و قسمت سوم جهت تست کارایی مدل مورد استفاده قرار گرفت. به منظور آماده‌سازی داده‌ها برای مدل و مشخص نمودن زمان تأخیر ایستگاه‌ها نسبت به هم از آنالیز هم‌بستگی استفاده گردید. وضعیت هم‌بستگی بین داده‌های ایستگاه واتستندول با داده‌های هر یک از ایستگاه‌های بالادست امکان برآورد زمان تأخیر را فراهم نمود. نتایج حاصل از این بررسی نشان داد که بیشترین هم‌بستگی بین داده‌های ایستگاه مورد نظر با ایستگاه‌های متلوک، کتس ورث و پل مایتم زمانی حاصل می‌شود که به ترتیب زمان تأخیر $1/5$ ، $3/5$ و $5/5$ ساعت در نظر گرفته شود.

فرایند پیش‌بینی بهنگام سیلاب

توسعه و بهبود در پیش‌بینی جریان‌های سیلابی رودخانه‌ها اساساً بخشی به‌خاطر افزایش تعداد ایستگاه‌های اندازه‌گیری در دهه‌های اخیر و در نتیجه دسترسی به داده‌های بیشتر و بخشی دیگر به علت پیشرفت سریع در تکنولوژی پردازش داده‌ها و مهیا شدن ابزارهای شبیه‌سازی کامپیوتری بوده است. سه

متفاوت از شبکه‌های عصبی مصنوعی شامل پرسپترون چندلایه، برگشتی و برگشتی با تأخیر زمانی در این تحقیق مورد استفاده و آزمون قرار گرفته که رفتار هر یک از این شبکه‌ها نیز براساس تعداد داده‌های ورودی متفاوت روی کیفیت نتایج حاصله در شرایط مختلف مورد تحقیق واقع گردیده است. در واقع این‌که کدام نوع شبکه سازگاری بهتری با سری‌های زمانی مربوط به دبی جریان داشته و توانایی پیش‌بینی بهنگام سیل با یک فاصله زمانی معقول قبل از وقوع را دارد موضوعی است که تا حال مورد تحقیق و ارزیابی قرار نگرفته و این تحقیق به دنبال روشن کردن این مسأله است.

مواد و روش‌ها

منطقه مورد مطالعه و داده‌های مورد استفاده در مدل

منطقه مورد مطالعه در برگیرنده بالادست حوزه رودخانه درونت در محدوده حوزه رودخانه ترنت می‌باشد. جریان رودخانه در ایستگاه هیدرومتری واتستندول با استفاده از داده‌های اندازه‌گیری شده در ایستگاه‌های بالاتر پیش‌بینی شده است. سه ایستگاه هیدرومتری در قسمت‌های بالادست عبارت‌اند از متلوک، کتس ورث و پل مایتم با فواصل به ترتیب 10 ، 25 و 50 کیلومتر بالاتر از ایستگاه واتستندول.

داده‌های اندازه‌گیری شده جریان رودخانه با فواصل 30 دقیقه‌ای برای ایستگاه‌های هیدرومتری فوق‌الذکر از آرآنس محیط زیست انگلستان دریافت گردید و از این میان داده‌های

مقدار Q هنگامی که شش ساعت قبل از وقوع پیش بینی می‌شود (تست‌های ۱ و ۲ و ۳):

$$Q_{(t)} = f(Q_{(t-12)}, Q_{(t-13)}, \dots, Q_{(t-n)} + q_{(t-12)}(1), q_{(t-13)}(1), \dots, q_{(t-n)}(1) + q_{(t-12)}(2), q_{(t-13)}(2), \dots, q_{(t-n)}(2) + q_{(t-12)}(3), q_{(t-13)}(3), \dots, q_{(t-n)}(3) + e_{(t)} \quad [3]$$

و به همین ترتیب برای ۹ و ۱۲ ساعت قبل از وقوع.

در تست ۴ با توجه به این که داده‌های اندازه‌گیری شده با فاصله زمانی ۱ ساعت مورد استفاده قرار گرفت لذا پیش بینی‌ها به صورت زیر خواهد بود:

مقدار Q که به ترتیب سه و شش ساعت قبل از وقوع با استفاده از داده‌های یک ایستگاه پیش بینی می‌شود (زیر تست ۱):

$$Q_{(t)} = f(q_{(t-3)}(1), q_{(t-4)}(1), \dots, q_{(t-n)}(1) + e_{(t)}) \quad [4]$$

$$Q_{(t)} = f(q_{(t-6)}(1), q_{(t-7)}(1), \dots, q_{(t-n)}(1) + e_{(t)}) \quad [5]$$

مقدار Q که به ترتیب سه و شش ساعت قبل از وقوع با استفاده از داده‌های دو ایستگاه پیش بینی می‌شود (زیر تست ۲):

$$Q_{(t)} = f(q_{(t-3)}(1), q_{(t-4)}(1), \dots, q_{(t-n)}(1) + q_{(t-3)}(2), q_{(t-4)}(2), \dots, q_{(t-n)}(2) + e_{(t)}) \quad [6]$$

$$Q_{(t)} = f(q_{(t-6)}(1), q_{(t-7)}(1), \dots, q_{(t-n)}(1) + q_{(t-6)}(2), q_{(t-7)}(2), \dots, q_{(t-n)}(2) + e_{(t)}) \quad [7]$$

و به همین ترتیب برای ۹ و ۱۲ ساعت قبل از وقوع و نیز برای زیر تست ۳ که در آن از داده‌های سه ایستگاه استفاده می‌شود.

مدل‌های شبکه عصبی مصنوعی

شبکه عصبی مصنوعی در حقیقت یک سیستم محاسباتی است که بر اساس سیستم عصبی جانداران (انسان) ساخته شده است. ساختمان این شبکه متشکل از نرون‌های مصنوعی (همانند سلول‌های عصبی جانداران) است که انتقال سیگنال‌ها را که در اثر ورودی‌های سیستم ایجاد شده انجام می‌دهد. این عمل همانند انتقال پیام در شبکه عصبی جانداران است که در اثر محرک خارجی ایجاد شده و با ترشح هورمون‌های شیمیایی در محل اتصال سلول‌ها به همدیگر (سیناپس) با شدت و ضعف مورد نیاز از سلولی به سلول دیگر منتقل می‌شود. این انتقال سیگنال‌ها در نرون‌های مصنوعی توسط مقادیر عددی که به آنها

پارامتر اصلی در پیش بینی سیلاب که بایستی توجه پیش بینی کننده را به خود معطوف نماید عبارت از صحت، اعتماد و اطمینان و نیز مسأله زمان (مدت زمان بین پیش بینی و وقوع حادثه) می‌باشد. در سیستم‌های هشدار سیلاب مسأله زمان (فاصله زمانی بین پیش بینی و وقوع حادثه) عامل بسیار مهم و تعیین کننده است علاوه بر آن که تغییرات شکل هیدروگراف خصوصاً شاخه صعودی و نیز قسمت اوج آن نیز دارای اهمیت زیادی می‌باشند. در روشی که در این تحقیق مورد استفاده واقع شده در حقیقت شرایط مربوط به مقطع‌های زمانی آینده براساس داده‌های مقطع‌های زمانی گذشته و حال مورد پیش بینی قرار می‌گیرد. به عبارت دیگر در صورتی که Q نمایانگر مقدار دبی جریان در زمان t در نقطه‌ای در پایین دست باشد مقدار Q در مقطع زمانی آینده $(t+1)$ به صورت زیر مورد پیش بینی قرار می‌گیرد:

$$Q_{(t+1)} = f(Q_{(t)}, Q_{(t-1)}, \dots, Q_{(t-n)} + q_{(t)}, q_{(t-1)}, \dots, q_{(t-n)} + e_{(t)}) \quad [1]$$

که در آن f یک تابع غیر خطی نامعین، $e_{(t)}$ یک مقدار مجهول که مربوط به خطای فرایند و n تعداد داده‌های مربوط به مقطع‌های زمانی حال و گذشته است که جهت پیش بینی جریان در آینده مورد استفاده واقع می‌شود. $Q_{(t+1)}$ عبارت است از دبی جریان در مقطع زمانی آینده در ایستگاه واتستندول (Whatstandwell) که با استفاده از داده‌های بالادست در مقاطع زمانی $t, t-1, \dots, t-n$ و مربوط به سه ایستگاه بالادست ($Q_{(t)}(1), Q_{(t)}(2), Q_{(t)}(3)$) مورد برآورد قرار می‌گیرد. داده‌های اندازه‌گیری شده در فاصله زمانی ۳۰ دقیقه و نیز چهار پایه زمانی متفاوت پیش بینی (فاصله زمانی بین پایان پیش بینی و آغاز وقوع حادثه) در این تحقیق مورد استفاده قرار گرفت که بر این اساس رابطه ریاضی پیش بینی‌ها به صورت زیر خواهد بود:

مقدار Q هنگامی که سه ساعت قبل از وقوع پیش بینی می‌شود (تست‌های ۱ و ۲ و ۳):

$$Q_{(t)} = f(Q_{(t-6)}, Q_{(t-7)}, \dots, Q_{(t-n)} + q_{(t-6)}(1), q_{(t-7)}(1), \dots, q_{(t-n)}(1) + q_{(t-6)}(2), q_{(t-7)}(2), \dots, q_{(t-n)}(2) + q_{(t-6)}(3), q_{(t-7)}(3), \dots, q_{(t-n)}(3) + e_{(t)}) \quad [2]$$

با :

$$e_i(n) = d_i(n) - y_i(n) \quad [8]$$

با استفاده از تئوری یادگیری کاهش شیب (Gradient decent)

وزن‌ها با استفاده از رابطه زیر تصحیح می‌شوند :

$$w_{ij}(n+1) = w_{ij}(n) + \eta \delta_i(n) x_j(n) \quad [9]$$

که در آن $W_{ij}(n+1)$ عبارت است از وزن اتصال عنصر i به عنصر j در $n+1$ امین تجدید و $W_{ij}(n)$ مقدار این وزن در n امین چرخش (تجدید) است. $\delta_i(n)$ عبارت از از خطای موضعی که مستقیماً از $e_i(n)$ محاسبه شده است (در n امین تجدید) و مقدار ثابت η نیز اندازه قدم محاسباتی (Step size) است.

روش یادگیری موسوم به ممتم که برای سیستم‌های عصبی مصنوعی در این تحقیق استفاده شده است در واقع یک حالت توسعه یافته از روش یادگیری شیب کم است که در آن یک واحد حافظه جهت تسریع در همگرایی و ایجاد ثبات به کار رفته است. در این روش یادگیری، تجدید وزن‌های عناصر سیستم با استفاده از رابطه زیر صورت می‌گیرد:

$$w_{ij}(n+1) = w_{ij}(n) + \eta \delta_i(n) x_j(n) + \alpha (w_{ij}(n) - w_{ij}(n-1)) \quad [10]$$

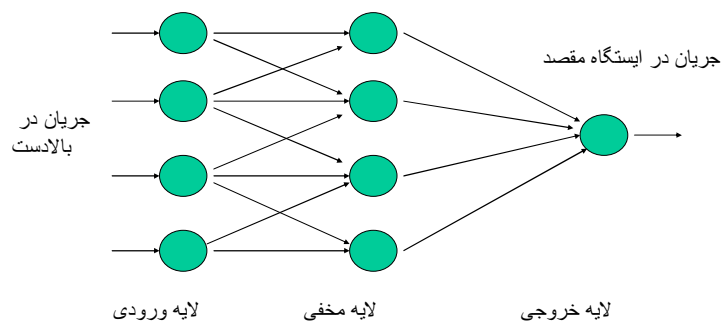
که در آن α فاکتور ممتم است و معمولاً برابر عددی ما بین ۰/۱ تا ۰/۹ قرار داده می‌شود. همان‌طور که قبلاً ذکر شد وزن‌های نهایی که حاصل یک فرایند مناسب یادگیری است در پایان مرحله آموزش مدل تثبیت و ذخیره شده و جهت آزمایش کارایی مدل در مورد دسته جدیدی از داده‌های ورودی به کار برده می‌شود.

جهت جلوگیری از آموزش کاذب و بیش از حد (Over training) مدل، که غالباً باعث عدم یادگیری مناسب فرآیند توسط مدل می‌شود، بخش کوچکی از داده‌ها (حدود ۱۰ درصد) به عنوان داده‌های cross-validation انتخاب شده و به مدل معرفی گردید. در حقیقت کل داده‌ها به سه بخش مجزا جهت استفاده به عنوان داده‌های آموزشی (Training data)، داده‌های آزمایشی (Testing data) و داده‌های مربوط به ارزیابی نتایج در میانه کار (Cross-validation data) تقسیم گردید. لازم به ذکر است که زمانی که بخشی از داده‌ها به عنوان داده‌های

وزن اطلاق می‌شود انجام می‌گردد و در نهایت نحوه کارکرد آن نیز مطابق سیستم عصبی جانداران بر اساس یادگیری فرایند از طریق یک الگو استوار است.

شبکه‌های عصبی مصنوعی باید توسط داده‌های مناسبی که در برگیرنده ورودی و خروجی می‌باشد آموزش داده شود که به این داده‌ها داده‌های آموزشی اطلاق می‌شود. لذا انتخاب مناسب داده‌های آموزشی مسأله مهمی در یادگیری مناسب مدل است. علاوه بر آن انتخاب نوع و ساختمان مناسبی از شبکه‌های عصبی مصنوعی برای موضوع مورد نظر اهمیت خاصی در اخذ نتایج قابل قبول دارد. در این تحقیق سه نوع مختلف شبکه عصبی مصنوعی که عبارت‌اند از شبکه‌های پرسپترون چند لایه (Multi-layer perceptron)، برگشتی (Recurrent) و برگشتی با تأخیر زمانی (Time lag recurrent) مورد استفاده قرار گرفتند. لازم به ذکر است که هر سه شبکه اساساً جزء شبکه‌های پیشخور (Feed forward networks) محسوب می‌شود که معمولاً به وسیله الگوریتم انتشار به عقب (Backpropagation) آموزش داده می‌شود. در این نوع الگوریتم خطای خروجی شبکه برآورد و به عقب (به داخل سیستم) انتشار یافته و بر این اساس وزن‌های انتخاب شده در مدل اصلاح می‌گردد. این فرایند مربوط به اصلاح وزن‌ها در تمامی عناصر سیستم ادامه می‌یابد تا بهترین وزن‌ها که صحیح‌ترین خروجی را برای سیستم ایجاد می‌کنند، شناسایی و انتخاب شوند. در حقیقت در این روش با تصحیح مرتب خطا وزن‌های مناسب برای سیستم به دست می‌آید. مفهوم حالتی که مناسب‌ترین وزن‌ها به دست آمده این است که مدل آموزش کافی را دیده است و لذا وزن‌های مربوطه تثبیت شده و در مورد داده‌های ورودی جدید که در قالب داده‌های مربوط به آزمایش کارایی مدل است اعمال می‌گردد. در این حالت با مقایسه نتایج مدل با مقادیر مشاهده شده، در مورد کارایی مدل قضاوت می‌شود.

اگر $y_i(n)$ خروجی عنصر i سیستم در n امین تجدید (گردش) باشد و مقدار واقعی برای آن عنصر در این تجدید با $d_i(n)$ نشان داده شود خطای لحظه‌ای در این حالت برابر است



شکل ۲. تصویری ساده از ساختمان MLP استفاده شده در این تحقیق

این تحقیق را نشان می‌دهد.

شبکه عصبی برگشتی (Recurrent)


این نوع شبکه عصبی مصنوعی خود به دو نوع برگشتی کامل یا Recurrent کامل و برگشتی جزئی یا Recurrent جزئی یا نیمه برگشتی تقسیم می‌شود. هرچند شبکه برگشتی به مراتب قوی‌تر و تواناتر از شبکه MLP است ولی آموزش آن نیز به همان نسبت حساس‌تر و مشکل‌تر می‌باشد و نکات مبهم و ناشناخته در آن بیشتر است. جهت رسیدن به یک ساختمان مناسب این نوع شبکه برای این تحقیق ساختمان‌های مختلف با تعداد لایه‌ها، توابع انتقال و پارامترهای یادگیری متفاوت ساخته شده و نتایج حاصل از آنها مورد بررسی و مقایسه قرار گرفت. در نهایت پس از این بررسی‌ها این نتیجه حاصل شد که تابع انتقال تانژانت هیپربولیک بهترین تابع انتقال برای لایه‌های میانی (پنهانی) است و برای لایه خروجی تابع انتقال از نوع سیگموئید تناسب بیشتری دارد. از بین عناصر دینامیک شبکه که عبارت‌اند از گاما (Gamma)، لاگوار (Laguarre) و تأخیر زمانی (Time delay) نوع لاگوار و نوع تأخیر زمانی کارایی بهتری را نشان دادند. تعداد مناسب لایه‌های پنهان در تست‌های مختلف بسته به تعداد داده‌های مورد استفاده متفاوت بود طوری که برای تست‌های با داده کم یک لایه پنهان و برای تست‌های با داده زیاد دو لایه پنهان بهترین نتیجه را ارائه نمودند. ضمناً در رابطه با شبیه سازی‌های این تحقیق شبکه برگشتی جزئی یا نیمه برگشتی کارایی بهتری نسبت به شبکه برگشتی کامل داشت.

cross-validation به مدل معرفی می‌گردد، پس از هر مرحله تجدید وزن (چرخش) در طول دوره آموزش، مدل وزن‌های جدید را درباره داده‌های مربوط به cross-validation به عنوان سری جدیدی که در آموزش مدل نقش نداشته است اعمال می‌کند و زمانی که خطای نتایج در مورد این داده‌ها شروع به افزایش می‌کند (که نشان دهنده ادامه بی‌مورد و کاذب فرایند آموزش است) فرایند آموزش متوقف می‌شود و این دقیقاً همان موقعی است که وزن‌ها حالت بهینه را داشته و بایستی تثبیت گردند.

شبکه عصبی پرسپترون چند لایه MLP (Multi-layer Perceptron)

در این نوع شبکه اتصال فقط از جزء i به جزء $i+1$ برقرار بوده و در جهت عکس وجود ندارد. یکی از مزایای شبکه‌های MLP توانایی آنها در تخمین توابع دلخواه است. این خصوصیت در بررسی مسائل مرتبط با تغییرات غیر خطی عوامل ارزش فوق‌العاده‌ای دارد. در این تحقیق جهت یافتن مناسب‌ترین ترکیب ساختمانی MLP، ساختمان‌های متفاوتی همراه با توابع انتقال مختلف مورد استفاده و ارزیابی قرار گرفت و نهایتاً مشخص گردید که شبکه سه لایه‌ای (یعنی فقط یک لایه پنهانی) مناسب‌ترین ساختمان MLP برای این کاربرد است که در آن لایه میانی دارای تابع انتقال از نوع تانژانت هیپربولیک و لایه خارجی تابع انتقال از نوع لوجستیک یا سیگموئید است.

شکل ۲ تصویر ساده‌ای از ساختمان MLP استفاده شده در



شکل ۳. حالت ساده‌ای از شبکه عصبی مصنوعی Recurrent که در این تحقیق استفاده شده است.

مورد استفاده و نیز تعداد ایستگاه‌های بالادست که مورد استفاده قرار گرفت تنظیم گردید. در تست‌های ۱ و ۲ و ۳ داده‌های اندازه‌گیری شده با فاصله زمانی ۳۰ دقیقه به ترتیب برای مدت یک ماه، ۶ ماه و سه سال مورد استفاده قرار گرفت. در تست ۴ بررسی تأثیر تعداد ایستگاه‌های مورد استفاده جهت اخذ داده، مورد تحقیق و بررسی قرار گرفت. این تست خود به ۳ زیر تست که در آنها داده‌ها به ترتیب از ۱، ۲ و ۳ ایستگاه بالادست مورد استفاده قرار گرفته است تقسیم شد. هر تست و زیر تست با استفاده از سه نوع شبکه عصبی مصنوعی (که قبلاً توضیح داده شد) جداگانه انجام گرفت تا تأثیر نوع شبکه عصبی در اخذ نتایج مناسب نیز مورد ارزیابی قرار گیرد. هیدروگراف‌های مربوط به دبی‌های پیک پیش بینی شده ۳، ۶، ۹ و ۱۲ ساعت قبل از وقوع که توسط شبکه‌های عصبی مختلف در تست ۱ (با داده‌های کم یا یک ماه داده) ترسیم شده در شکل‌های ۴ تا ۶ نشان داده شده است. به خاطر محدودیت جا امکان ارائه گرافیکی نتایج برای تست‌های ۲، ۳ و ۴ در اینجا ممکن نیست ولی جهت ارزیابی کارایی هر یک از شبکه‌ها در تست‌های مختلف این تحقیق از دو پارامتر آماری که عبارت‌اند از ریشه میانگین مربع اشتباه (RMSE) و ضریب کارایی (R^2) استفاده گردیده است. مقادیر مربوط به RMSE برای نتایج حاصل از تست‌های مختلف این تحقیق در جدول ۱ نشان داده شده است. لازم به ذکر است مقادیر R^2 نیز وضعیتی مشابه RMSE را نشان می‌دهد. همان‌طور که جدول

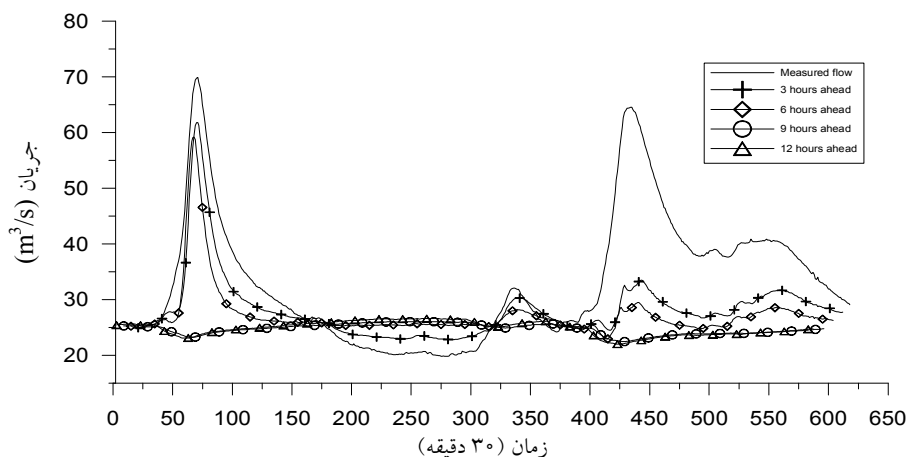
شکل ۳ حالت ساده‌ای از این شبکه را که در این تحقیق استفاده شده نشان می‌دهد.

شبکه عصبی برگشتی با تأخیر زمانی (Time lag Rectrrent)

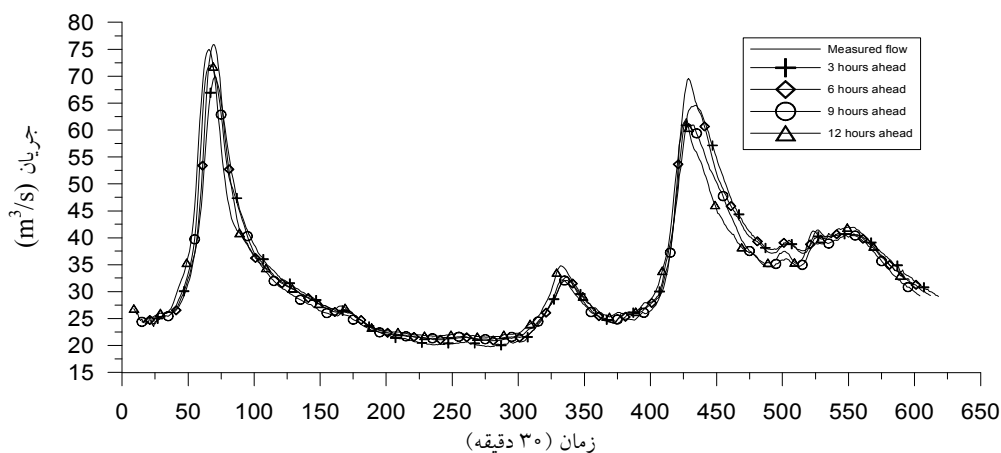
این نوع شبکه عصبی دارای لایه‌های با اتصال برگشتی محلی می‌باشد و در حقیقت حالت ساده‌تری از شبکه‌های برگشتی محسوب می‌شود ولی برعکس شبکه‌های برگشتی در این شبکه‌ها پایداری تا حدودی تضمین بوده و آموزش مدل بسادگی انجام می‌گیرد. در رابطه با این شبکه نیز تا نژانت هیپربولیک مناسب‌ترین تابع انتقال برای لایه پنهانی در غالب تست‌ها بود هرچند در تعداد محدودی از تست‌ها نیز تابع انتقال سیگموئید سازگاری بهتری در لایه پنهانی از خود نشان داد. برای لایه خروجی در تمامی تست‌ها تابع انتقال سیگموئید مناسب‌ترین تابع انتقال بود. عنصر دینامیک نوع گاما (Γ) سازگاری بیشتری با این نوع شبکه در رابطه با تست‌های این تحقیق از خود نشان داد و در رابطه با تعداد لایه‌های پنهان لازم به ذکر است که این نوع شبکه با یک لایه پنهانی بهترین ساختمان برای تست‌های انجام شده در این تحقیق بوده است.

نتایج و بحث

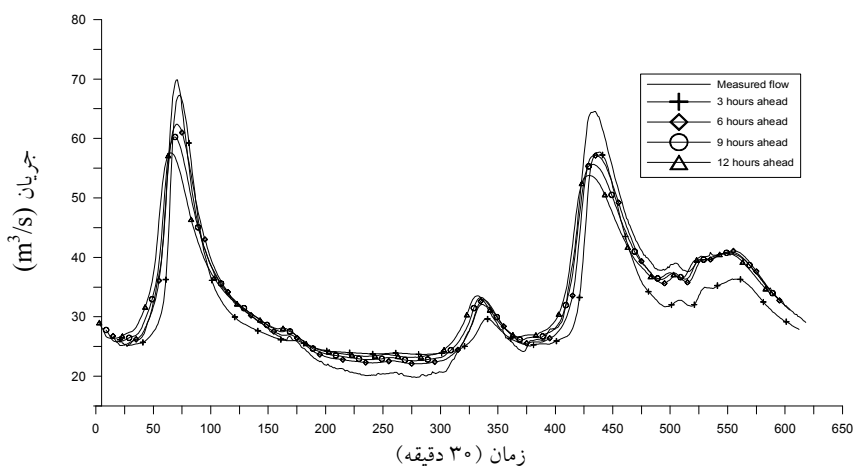
در این تحقیق جریان رودخانه در ایستگاه واتستندول با استفاده از داده‌های ایستگاه‌های بالادست پیش بینی گردید. در این پیش‌بینی چهار تست مختلف با توجه به تعداد داده‌های



شکل ۴. هیدروگراف جریان پیش بینی شده ۳، ۶، ۹ و ۱۲ ساعت قبل از وقوع (توسط شبکه شبکه عصبی مصنوعی MLP) در ایستگاه واتستندول در تست ۱ (داده کم) در مقابل مقادیر اندازه گیری شده.



شکل ۵. هیدروگراف جریان پیش بینی شده ۳، ۶، ۹ و ۱۲ ساعت قبل از وقوع (توسط شبکه عصبی مصنوعی برگشتی) در ایستگاه واتستندول در تست ۱ (داده کم) در مقابل مقادیر اندازه گیری شده



شکل ۶. هیدروگراف جریان پیش بینی شده ۳، ۶، ۹ و ۱۲ ساعت قبل از وقوع (توسط شبکه شبکه عصبی مصنوعی برگشتی با تاخیر زمانی) در ایستگاه واتستندول در تست ۱ (داده کم) در مقابل مقادیر اندازه گیری شده

جدول ۱. مقادیر RMSE بین نتایج مدل‌های مختلف شبکه عصبی مصنوعی و مقادیر اندازه‌گیری شده در تست‌ها و زیرتست‌های انجام شده

تست	زیرتست	زمان تا وقوع سیل	فاز آموزشی			فاز صحت‌یابی		
			شبکه MLP	شبکه Rec.	شبکه T.L.R.	شبکه MLP	شبکه Rec.	شبکه T.L.R.
۱	-	۳ ساعت	۱/۷۲۷	۲/۱۲۵	۵/۳۷۴	۹/۴۸۴	۱/۶۴۶	۲/۹۸۲
		۶ ساعت	۳/۴۸۰	۳/۰۱۲	۴/۶۰۴	۱۱/۴۸۵	۱/۸۱۸	۳/۰۰۶
		۹ ساعت	۴/۳۷۹	۳/۶۲۵	۴/۹۳۲	۱۵/۵۰۵	۲/۱۸۵	۳/۲۴۳
		۱۲ ساعت	۶/۱۶۴	۴/۸۹۹	۵/۷۰۶	۱۵/۷۶۶	۴/۳۱۳	۳/۸۹۷
۲	-	۳ ساعت	۲/۵۶۷	۲/۳۱۵	۳/۸۷۸	۴/۵۵۱	۲/۱۶۸	۳/۱۵۳
		۶ ساعت	۳/۸۴۲	۳/۲۶۷	۵/۲۹۰	۶/۷۷۲	۲/۱۸۵	۳/۳۴۴
		۹ ساعت	۴/۴۱۸	۴/۲۳۴	۳/۶۹۰	۷/۴۷۲	۳/۱۵۹	۳/۳۸۸
		۱۲ ساعت	۶/۵۶۲	۵/۲۰۷	۴/۷۶۹	۱۱/۲۳۰	۳/۱۸۳	۴/۲۹۸
۳	-	۳ ساعت	۳/۳۵۲	۵/۶۶۴	۱۲/۱۷۱	۹/۲۹۸	۱۰/۴۵۶	۱۲/۶۴۷
		۶ ساعت	۶/۲۳۷	۶/۹۹۰	۱۴/۹۷۶	۱۴/۹۵۸	۱۰/۷۸۳	۱۳/۰۸۴
		۹ ساعت	۸/۶۸۹	۹/۸۱۳	۱۸/۳۲۹	۲۱/۳۶۷	۱۱/۵۳۹	۱۸/۷۳۶
		۱۲ ساعت	۱۰/۷۲۷	۱۱/۶۳۷	۲۱/۵۰۴	۲۴/۳۴۲	۱۱/۷۳۴	۱۹/۹۳۰
۴	۱	۳ ساعت	۱/۹۳۰	۲/۴۶۴	۲/۸۰۰	۲/۰۹۴	۱/۸۹۷	۱/۶۹۲
		۶ ساعت	۱/۹۳۹	۳/۲۱۷	۳/۶۶۹	۳/۳۲۵	۱/۹۲۳	۱/۹۳۷
		۹ ساعت	۲/۷۱۴	۳/۵۷۳	۴/۴۴۳	۶/۰۹۳	۲/۰۴۴	۲/۴۰۵
		۱۲ ساعت	۳/۶۵۰	۳/۸۲۵	۷/۵۷۲	۷/۰۴۰	۲/۰۸۴	۴/۳۶۱
	۲	۳ ساعت	۱/۴۳۴	۳/۳۲۵	۲/۴۷۲	۱/۹۸۴	۲/۶۹۶	۲/۰۹۷
		۶ ساعت	۲/۸۰۴	۳/۳۵۵	۳/۵۶۱	۴/۷۸۴	۲/۳۷۵	۱/۹۳۰
		۹ ساعت	۳/۷۹۱	۳/۸۰۳	۴/۰۱۰	۶/۰۲۹	۲/۱۶۴	۱/۸۴۱
		۱۲ ساعت	۴/۸۶۵	۳/۹۲۹	۴/۴۸۹	۶/۱۶۲	۲/۱۵۷	۱/۸۰۷
	۳	۳ ساعت	۱/۱۶۴	۲/۳۹۰	۲/۹۷۷	۱/۶۵۳	۱/۴۱۷	۱/۵۹۱
		۶ ساعت	۲/۵۵۵	۲/۳۵۷	۳/۲۱۵	۵/۲۶۷	۱/۶۵۶	۱/۵۹۳
		۹ ساعت	۳/۸۷۸	۴/۲۲۵	۳/۵۹۳	۸/۰۰۲	۱/۸۰۸	۱/۷۴۵
		۱۲ ساعت	۵/۱۰۵	۴/۰۳۸	۴/۲۰۷	۸/۲۸۲	۲/۰۰۱	۱/۸۸۲

رضایت‌بخش بوده و حتی در برخی موارد قابل مقایسه با نتایج شبکه عصبی برگشتی است ولی نتایج آن در تست ۳ که تعداد زیادی داده استفاده شده رضایت‌بخش نمی‌باشد. بهترین نتایج را در تمام تست‌های این تحقیق شبکه عصبی برگشتی از خود نشان داده است. در رابطه با تست ۴ نیز توانایی شبکه‌های

نشان می‌دهد شبکه عصبی مصنوعی MLP کارایی مناسبی را خصوصاً وقتی که فاصله زمانی بین پیش‌بینی و وقوع طولانی‌تر باشد از خود نشان نداده است. نتایج حاصل از شبکه عصبی مصنوعی برگشتی با تأخیر زمانی هرچند در تست ۱ و تا حدی تست ۲ (وقتی تعداد داده‌های مورد استفاده زیاد نیست)

استاتیک است توانایی شبیه سازی سری داده‌هایی که با زمان تغییر می‌کند (همانند آنچه که در این تحقیق مورد استفاده قرار گرفته) را ندارد. این عدم توانایی زمانی بیشتر خودنمایی می‌کند که بخواهیم مقدار دبی سیلابی را مدت زمان طولانی‌تری (۹ و ۱۲ ساعت) قبل از وقوع آن پیش بینی نماییم. بهترین نتایج به دست آمده در این تحقیق مربوط به شبکه عصبی برگشتی می‌باشد (در رابطه با تمام تست‌های انجام شده). همان‌طور که جدول ۱ نشان می‌دهد در فاز صحت یابی (که ملاک ارزیابی کارایی مدل‌ها می‌باشد) مقادیر RMSE مربوط به نتایج شبکه‌های برگشتی و برگشتی همراه با تأخیر زمانی به مراتب کوچک‌تر از مقادیر این پارامتر در نتایج MLP است و خصوصاً در مورد نتایج شبکه برگشتی افزایش مقدار آن با افزایش زمان بین پیش بینی و وقوع بسیار بطنی و کم است.

عصبی مختلف کماکان همانند تست‌های ۱ و ۲ و ۳ است و لازم به ذکر است که تعداد ایستگاه‌های بالادست که به عنوان منبع داده‌ها مورد استفاده قرار گرفته تفاوت زیادی را در نتایج حاصل نموده است (مقایسه نتایج زیر تست‌های مختلف تست ۴) هرچند نتایج زیر تست‌های ۲ و ۳ مربوط به شبکه عصبی برگشتی تا حدی بهتر از نتایج این شبکه در زیر تست ۱ می‌باشد.

نتیجه‌گیری

نتایج حاصل از این تحقیق کارایی مناسب شبکه‌های عصبی از نوع دینامیک (شبکه برگشتی و شبکه برگشتی با تأخیر زمانی) را در پیش بینی به هنگام جریان رودخانه که پارامتری ضروری در طراحی و اجرایی سیستم‌های هشدار سیلاب محسوب می‌شود نشان می‌دهد. شبکه عصبی MLP که در واقع یک شبکه

منابع مورد استفاده

۱. دستورانی، م. ت. و ج. ر. نایجل. ۱۳۸۲. بهینه سازی نتایج حاصل از یک مدل هیدرودینامیکی در پیش‌بینی جریان رودخانه توسط سیستم عصبی مصنوعی. مجموعه مقالات چهارمین کنفرانس هیدرولیک ایران، شیراز.
۲. دستورانی، م. ت. ۱۳۸۴. ارزیابی کارایی هوش مصنوعی کامپیوتر در تخمین داده‌های مفقود شده هیدرولوژی. دومین کنفرانس سراسری آبخیزداری و مدیریت منابع آب و خاک، کرمان.
3. Bhattacharya, B. and D. P. Solomatine. 2000. Application of artificial neural network in stage-discharge relationship. Proc. 4th International Conference on Hydroinformatics, Iowa City, USA.
4. Dastorani, M. T. 1997. The Effects of the data record period in accuracy of river flood prediction using frequency analysis procedure. Proc. of 8th International Rainwater Catchment Systems, Tehran, Iran.
5. Dastorani M. T. and N. G. Wright. 2001. Application of artificial neural networks for ungauged catchments flood prediction. Proc. of the Floodplain Management Association, March 12-16, San Diego, USA.
6. Dastorani, M.T and N. G. Wright. 2002. Artificial neural network based real-time flow prediction. 5th International Conference on Hydrodynamics, Cardiff, UK.
7. Dawson, C. W. and R. Wilby. An artificial neural network approach to rainfall-runoff modelling. J. Hydrolo. Sci. 43(1): 47-66.
8. Environment Agency, UK (river flow data), WWW. Environment – Agency. Gov. UK.
9. Hsu, K., H. V. Gupta and S. Sorooshian. 1995. artificial neural network modeling of the rainfall-runoff process. J. Water Resour. Res. 31(10): 2517-2530.
10. Karunanithi, N., W. J. Grenney, D. Whitley and K. Bovee. 1994. Neural networks for flow prediction, J. Comput. in Civil Eng. 8(2): 201-220.
11. Minns, A. W. and M. J. Hall. 1996. Artificial neural networks as rainfall-runoff models. J. Hydrol. Sci. 41(3): 399-417.
12. Tokar, S.A and Pa. Johnson. 1999. Rainfall – runoff modeling using artificial neural networks. J. Hydrol. Eng. 4(3): 232-239.

