مجله علمی - پژوهشی
علوم و مهندسی آبخیـــزداری ایران
Iran-Watershed Management
Science & Engineering

سال چهارم - شماره ۱۱ - تابستان ۱۳۸۹
Vol. 4, No. 11, Summer 2010

گزارش فنی

ارزیابی تأثیر سیگنال‌های مختلف ورودی بر میزان کارایی مدل‌های شبکه عصبی مصنوعی در شبیه‌سازی هوشمند آبنمود سیل

حمید پهلوانی[۱]، عبدالرضا بهره‌مند[۲] و امیر احمد دهقانی[۳]

تاریخ دریافت: ۸۸/۱۱/۰۳ تاریخ پذیرش: ۸۹/۰۵/۱۱

چکیده

برآورد مشخصات آبنمود سیل در رودخانه‌ها، یکی از مسایل مورد علاقه پژوهشگران علوم آب و آب‌شناختی می‌باشد. در این پژوهش توانایی مدل‌های شبکه عصبی مصنوعی جهت شبیه سازی آبنمود سیل ورودی به سد مخزنی شیرین‌دره در استان خراسان مورد بررسی قرار گرفته است. بدین منظور تمامی آبنمودهای سیل ثبت شده در ایستگاه آب‌سنجی موجود در بالادست مخزن سد، گردآوری و مقادیر دبی سیل با استفاده از روابط مربوطه استاندارد شد. در ادامه چهار الگوی ورودی بر مبنای استفاده از دبی سیل در ساعات گذشته(یعنی ۲، ۳، ۴ و ۵ ساعت قبل) طراحی شدند. به منظور بررسی اثر تعداد پارامترهای ورودی بر دقت برآورد، در هر الگو نیز چهار سیگنال بر اساس تأخیر دبی سیل طراحی و مورد ارزیابی قرار گرفتند. به منظور ارزیابی تأثیر افزایش آموزش مدل در بهبود عملکرد آن، معیارهای آماری متعددی همچون خطای حجم سیل، خطای دبی اوج، خطای زمان تا اوج و معیار ناش-ساتکلیف در هر سیگنال ورودی محاسبه و مورد ارزیابی قرار گرفتند. نتایج نشان می‌دهد که با افزایش زمان تأخیر، دقت شبیه سازی کمتر می شود. همچنین به ازای یک زمان تاخیر معین، با افزایش تعداد ورودی‌ها (دبی در ساعتهای قبل)، نیز دقت نتایج افزایش می یابد. به طوریکه با افزایش تعداد ورودی‌ها در الگوی اول، میزان ضریب ناش-ساتکلیف از مقدار ۰/۷۹ به ۰/۹۱ برای سیگنال چهارم افزایش یافت.

واژه‌های کلیدی: آبنمود سیل، شبکه عصبی مصنوعی، حوزه آبخیز سد شیرین‌دره، الگوریتم یادگیری و تابع انتقال.

مقدمه

شبیه‌سازی جریان رودخانه به معنی برآورد حجم آوردهای رودخانه و پیش‌بینی سیل می باشد. پیش بینی‌ها به دو صورت بلند مدت و کوتاه مدت می‌باشد. اهمیت انجام پیش‌بینی جریان، در اتخاذ تصمیماتی است که، بر مبنای این پیش‌بینی‌ها، مدیریت بهینه منابع آب صورت می گیرد. در دهه اخیر استفاده از شبکه‌های عصبی مصنوعی در شاخه‌های علوم مختلف مهندسی از جمله مهندسی منابع آب، رواج بسیاری یافته، که دلیل این امر قابلیت این روش‌ها در شبیه‌سازی و برآورد توابع غیرخطی با دقت مناسب می‌باشد. در ادامه به چند نمونه از پژوهش‌های انجام گرفته توسط شبکه عصبی مصنوعی در زمینه مهندسی آب اشاره می‌شود. اکبرپور [۱] برای شبیه‌سازی فرآیند بارش-رواناب از دو مدل HEC-HMS و شبکه عصبی مصنوعی استفاده نمود. نتایج به دست آمده نشان داد که مدل شبکه عصبی مصنوعی از توانایی بیشتری، در مدل سازی در فرآیند بارش-رواناب، نسبت به مدل HEC- HMSبر خوردار است. دستورانی [۲] توانایی مدل‌های شبکه عصبی را جهت شبیه‌سازی رفتار آب‌شناختی سیل در حوزه‌های آبخیز با استفاده از دبی سیلاب ۳، ۶، ۹ و ۱۲ ساعت قبل را مورد بررسی قرار داد. مشفق [۳] برای پیش‌بینی جریان رودخانه از مدل‌های مختلف شبکه عصبی مصنوعی به نام‌های پرسپترون چند لایه، شبکه عصبی مبتنی بر پایه شعاعی (RBF) استفاده نمود. نتایج ایشان نشان داد، مدل‌های شبکه عصبی مصنوعی بادقت قابل قبول نسبت به روش‌های تجربی می‌تواند برای مدل سازی جریان رودخانه مورد استفاده قرار گیرد. نایبی [۴] برای پیش‌بینی جریان رودخانه در حوزه آبخیز کر-چمریز در دو بازه زمانی روزانه و هفتگی، از مدل‌های شبکه عصبی مصنوعی استفاده نمود. نتایج به دست آمده نشان داد استفاده از الگوریتم آموزشی لونبرگ-مارکواردت عملکرد بهتری نسبت به الگوریتم آموزشی گرادیان مزدوج دارد. همچنین نتایج آنها نشان داد که شاخص دما به عنوان یک ورودی در عمکرد مدل برای پیش‌بینی جریان، تأثیر خاصی نداشته است. همچنین افزایش طول دوره آماری باعث بهبود عملکرد مدل شبکه عصبی مصنوعی می‌شود. پژوهش‌های احمد و سیمنویچ [۵] نیز نشان داد که از مدل شبکه

۱- دانشجوی کارشناسی ارشد مهندسی آبخیزداری دانشگاه علوم کشاورزی و منابع طبیعی گرگان
۲-استادیار گروه مهندسی آبخیزداری دانشگاه علوم کشاورزی و منابع طبیعی گرگان
۳-نویسنده مسئول واستادیار گروه مهندسی آب دانشگاه علوم کشاورزی و منابع طبیعی گرگان a.dehghani@gau.ac.ir

عصبی مصنوعی و بر پایه پارامترهای هیدرواقلیمی می‌توان برای پیش بینی دبی اوج لحظه‌ای رودخانه در شمال آمریکا استفاده نمود. براساس نتایج به دست آمده هر چند شبکه‌های عصبی مصنوعی به صورت کلی، کارایی مناسبی را در شبیه سازی و پیش بینی جریان از خود نشان دادند، ولی نوع شبکه عصبی مصنوعی و نیز خصوصیات داده‌های ورودی مدل به ویژه داده‌های آموزشی، پارامترهای بسیار مهمی هستند که تأثیر عمده‌ای روی خروجی مدل دارند. هدف از این پژوهش، ارزیابی تأثیر سیگنال‌های مختلف ورودی بر آموزش مدل شبکه عصبی و به تبع آن بهبود عملکرد آن در امر شبیه سازی آبنمود سیل می‌باشد. بدین منظور سیگنال‌های ورودی مختلفی، طراحی و تأثیر آنها بر میزان آموزش مدل و بهبود عملکرد آن بطور جداگانه مورد ارزیابی قرار گرفت.

مواد و روش‌ها

ویژگی‌های عمومی منطقه مطالعاتی

حوزه آبخیز شیرین‌دره در استان خراسان شمالی، یکی از زیرحوزه‌های رودخانه اترک می‌باشد و در محدوده مطالعاتی بین ۳۷ و۳۸ و ۳۷ تا ۰ و۰ و ۳۸ عرض شمالی ۲۲ و۰۶ و ۵۷ تا ۱۴ و۵۷ و ۵۷ طول جغرافیایی واقع است. مساحت محدوده مطالعاتی برابر با ۱۶۱۲۱۳/۶ هکتار است. ارتفاع متوسط وزنی حوزه ۱۴۸۱/۹ متر از سطح دریا بوده و بارندگی سالیانه آن از ۲۷۰ میلیمتر تا ۳۰۰ میلیمتر در سال متغیر است. تغییرات دمایی آن در دامنه ۸ تا ۳۵ درجه سانتیگراد می‌باشد. دو ایستگاه آب سنجی بر روی رودخانه شیرین‌دره موجود می‌باشد که، در این پژوهش از آمار ایستگاه آب سنجی بربرقلعه استفاده گردید.

روش پژوهش

در ابتدا تمامی آبنمودهای سیل ثبت شده در ایستگاه آب سنجی این حوزه آبخیز گردآوری شد. سپس تعداد ۱۶ آبنمود سیل انتخاب و از میان آنها آبنمود، تعداد ۱۱ آبنمود سیل برای آموزش مدل، تعداد ۳ آبنمود برای صحت سنجی و ۲ آبنمود سیل برای آزمون مدل شبکه عصبی مصنوعی انتخاب شد. در ادامه داده‌های مربوط به این آبنمودها در حوزه آبخیز، با توجه به برد تابع انتقال، توسط روابط مربوطه استاندارد شدند و سه الگوی ورودی در حوزه آبخیز، بر اساس دبی سیل در ۲، ۴ و ۵ ساعت قبل به عنوان مبنای پیش بینی سیل طراحی شد و در هر الگو نیز چهار سیگنال ورودی، بر اساس زمان تأخیر دبی سیل در هر گام زمانی طراحی شد (جدول ۱). سپس با انجام سعی و خطای فراوان، اجزای نهایی مدل شبکه عصبی مصنوعی از قبیل تعداد نرون در لایه مخفی، تابع انتقال، الگوریتم یادگیری و ضریب مومنتوم، به دست آمد. سپس بهترین سیگنال ورودی در هر الگو به عنوان سیگنال نهایی انتخاب شد و نتایج حاصل از شبیه‌سازی آن، بر اساس آموزش و آزمون نهایی مدل طراحی شده، مورد تجزیه و تحلیل و ارزیابی قرار گرفت. به منظور ارزیابی دقت مدل شبکه عصبی مصنوعی در شبیه سازی آبنمود سیل از معیارهای خطای نسبی حجم سیل رابطه، خطای نسبی دبی پیک رابطه، خطای نسبی زمان تا اوج، معیار ناش-ساتکلیف رابطه و ریشه میانگین مربعات خطا استفاده گردید.

بحث و نتیجه‌گیری

نتایج حاصل از بهینه سازی اجزای فنی مدل شبکه عصبی مصنوعی نشان می‌دهد که با افزایش تعداد متغیرهای ورودی از سیگنال ۱ به ۴، تعداد نرون در لایه‌های پنهان افزایش می‌یابد. و به

جدول ۱ - ساختار ریاضی سیگنال‌های ورودی طراحی شده در هر الگوی ورودی به عنوان ورودی مدل در حوزه آبخیز

الگوهای ورودی مدل	سیگنال‌های ورودی طراحی شده در هر الگو	ساختار ریاضی سیگنال‌های ورودی و تعداد متغیرها	خروجی مدل
الگوی ۱	سیگنال ۱	$Q(t) = f(Q_{t-2}, Q_{t-3}, Q_{t-4})$	$Q(t)$
	سیگنال ۲	$Q(t) = f(Q_{t-2}, Q_{t-3}, ..., Q_{t-6})$	$Q(t)$
	سیگنال ۳	$Q(t) = f(Q_{t-2}, Q_{t-3}, ..., Q_{t-8})$	$Q(t)$
	سیگنال ۴	$Q(t) = f(Q_{t-2}, Q_{t-3}, ..., Q_{t-10})$	$Q(t)$
الگوی ۲	سیگنال ۱	$Q(t) = f(Q_{t-4}, Q_{t-5}, Q_{t-6})$	$Q(t)$
	سیگنال ۲	$Q(t) = f(Q_{t-4}, Q_{t-5}, ..., Q_{t-8})$	$Q(t)$
	سیگنال ۳	$Q(t) = f(Q_{t-4}, Q_{t-5}, ..., Q_{t-10})$	$Q(t)$
	سیگنال ۴	$Q(t) = f(Q_{t-4}, Q_{t-3}, ..., Q_{t-12})$	$Q(t)$
الگوی ۳	سیگنال ۱	$Q(t) = f(Q_{t-5}, Q_{t-6}, Q_{t-7})$	$Q(t)$
	سیگنال ۲	$Q(t) = f(Q_{t-5}, Q_{t-6}, ..., Q_{t-9})$	$Q(t)$
	سیگنال ۳	$Q(t) = f(Q_{t-5}, Q_{t-6}, ..., Q_{t-11})$	$Q(t)$
	سیگنال ۴	$Q(t) = f(Q_{t-5}, Q_{t-3}, ..., Q_{t-13})$	$Q(t)$

این علت است که، با افزایش تعداد متغیرهای ورودی، به تعداد نرون بیشتری در لایه‌های پنهان، جهت شبیه‌سازی رفتارغیرخطی نیاز است. همچنین در این پژوهش از توابع تحریک و قوانین یادگیری مختلف نیز برای آموزش شبکه‌های عصبی مصنوعی طراحی شده، استفاده شد که از بین آنها تابع تحریک تانژانت آکسون منجر به نتایج بهتری شد. همچنین محدوده تغییرات ضریب مومنتم نیز بین ۰/۱۵ تا ۰/۲ بدست آمد.

در ادامه، پس از تعیین اجزای بهینه مدل شبکه عصبی مصنوعی و آموزش آن، مدل طراحی شده برای آزمون آبنمودهای آزمون استفاده گردید که بطور نمونه نتایج حاصل از شبیه‌سازی یکی از آبنمودهای آزمون در شکل (۱) نشان شده است.

با توجه به شکل (۱) مشخص است که با افزایش زمان تأخیر از الگوی اول به الگوی سوم، دقت شبیه‌سازی کاهش می یابد. دلیل این امر کاهش همبستگی دبی فعلی با دبی جریان در ساعتهای دورتر است.

همچنین بمنظور بررسی اثر افزایش تعداد ورودی‌ها بر دقت شبیه‌سازی، نتایج حاصل از اجرای شبکه بر اساس سیگنال چهارم در شکل (۲) نشان داده شده است. نتایج نشان می‌دهد که دقت برآورد نسبت به سیگنال اول افزایش یافته است که این نتایج با نتایج آقای دستورانی [۲] در یک راستا می باشد. اما دلیل این بهبود عملکرد می‌تواند این باشد که، با افزایش داده‌های آموزشی و تعداد ورودی‌های مدل، میزان آموزش مدل افزایش می یابد. به طوری که مدل درک واضحی از پدیده‌ای را که قرار است شبیه‌سازی شود (در این پژوهش آبنمود سیل) خواهد داشت. همچنین استفاده از شکل‌های مختلف داده‌ها در فایل آموزش مدل شبکه عصبی مصنوعی (شکل‌های مختلف آبنمود سیل) باعث می‌شود که مدل حالت‌های بحرانی و عادی پدیده مورد نظر را تجربه کند و در مواجهه با داده‌های آزمون، که مدل هرگز آنها را ندیده، در شبیه‌سازی آنها دچار مشکل نشود و عملکرد بهتری به نمایش بگذارد.

با توجه به این که الگوی اول نسبت به بقیه الگوها از دقت بالاتری در شبیه‌سازی آبنمود برخوردار است، لذا نتایج معیارهای آماری حاصل از به کارگیری این الگو در سیگنال ۱ و ۴ در جدول (۲) ارایه شده است. نتایج نشان می‌دهد که ضریب ناش- ساتکلیف که معیاری از کارایی مدل بکار گرفته شده است، از مقدار ۰/۷۹ به ۰/۹۱ افزایش یافته است که نشان از دقت بالاتر با افزایش تعداد ورودی‌ها دارد.

نتیجه‌گیری

نتایج این پژوهش نشان داد که می‌توان بر اساس دبی سیلاب در زمانهای قبل، دبی سیلاب در زمان فعلی را با دقت مناسبی برآورد زد. همچنین به کارگیری شبکه‌های عصبی می‌تواند در شبیه سازی

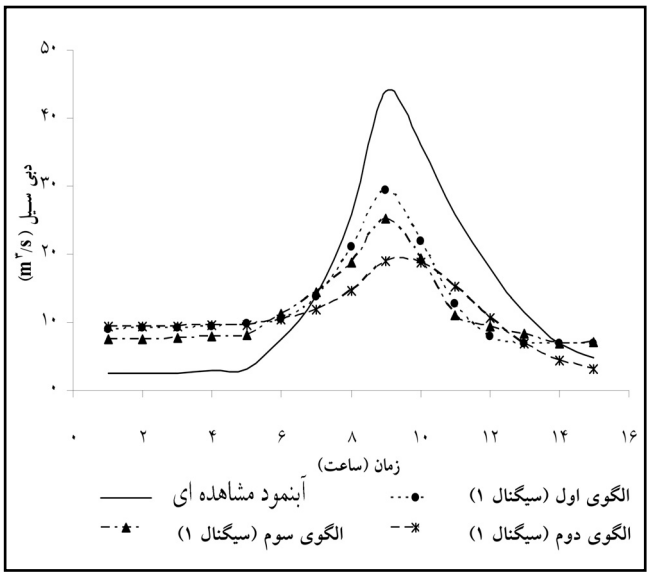

شکل ۱- آبنمودهای شبیه‌سازی شده بر اساس الگوی اول (سیگنال ۱)، الگوی دوم (سیگنال ۱) و الگوی سوم (سیگنال ۱)

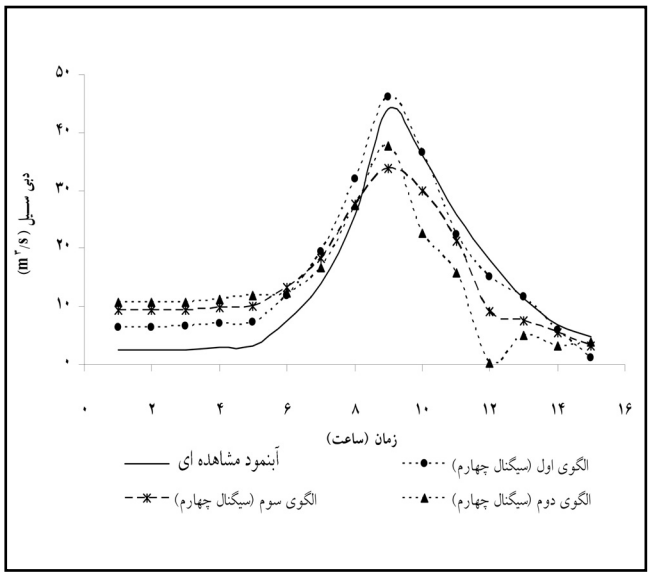

شکل ۲- آبنمودهای شبیه‌سازی شده با الگوی اول، دوم و سوم و بر اساس سیگنال ۴

جدول ۲- معیارهای ارزیابی آماری آبنمود شبیه‌سازی شده برای الگوی اول و سیگنالهای ۱ و ۴

سیگنال	خطای نسبی تعادل حجم سیل	خطای نسبی دبی پیک	RMSE	معیار نش - ساتکلیف
۱	۲۲/۱۱	۱۳/۰۸	۳/۴	۰/۷۹
۴	۱۱/۶۲	۴/۹۹	۱/۹۳	۰/۹۱

شکل آبنمود نیز مفید باشد. نتایج همچنین نشان داد که از بین توابع تحریک، تابع تحریک تانژانت آکسون منجر به نتایج بهتری می شود. همچنین محدوده تغییرات ضریب مومنتم نیز بین ۰/۱۵ تا ۰/۲ به دست آمد. نتایج همچنین نشان می دهد که الگوی اول از بقیه الگوها بهتر می تواند مشخصات آبنمود را شبیه سازی کند. همچنین در مدل اول، سیگنال ۴ نسبت به سیگنال ۱ از ضریب کارایی بالاتری برخوردار است که این نتایج با نتایج آقای دستورانی [۲] همخوانی دارد.

منابع

۱- اکبرپور، م. ۱۳۸۵. شبیه سازی فرآیند بارش-رواناب با استفاده از مدل های شبکه عصبی مصنوعی و مدل HEC-HMS (مطالعه رودخانه زرد). پایان نامه کارشناسی ارشد مهندسی آب دانشگاه با هنر کرمان. ۱۱۳ ص.

۲- دستورانی، م. ۱۳۸۶. ارزیابی کارایی مدل های هوش مصنوعی در پیش بینی بهنگام جریان های سیلابی. مجله علوم کشاورزی و منابع طبیعی. ص ۱۵ -۲۷.

۳- مشفق ، م. ۱۳۸۳. پیش بینی جریان رودخانه کرخه به کمک شبکه عصبی مصنوعی و الگوریتم ژنتیک. پایان نامه کارشناسی ارشد دانشگاه تربیت مدرس دانشکده فنی مهندسی. ۱۲۹ ص.

۴- نایبی، م. ۱۳۸۵. پیش بینی جریان رودخانه ای با استفاده از مدل های شبکه عصبی مصنوعی. پایان نامه کارشناسی ارشد مهندسی سازه های آبی دانشگاه شیراز. ۱۰۸ ص.

5-Amad, S and Simonovic, S. 2005. Artificial neural network model for generating hydrograph from hydro - meteorological parameters. Journal of hydrology, 18 (2): 236- 250.

مجله علمی - پژوهشی
علوم و مهندسی آبخیـــزداری ایران
Iran-Watershed Management
Science & Engineering

Vol. 4, No. 11, Summer 2010
سال چهارم - شماره ۱۱ - تابستان ۱۳۸۹

Abstract (Technical Note)

Evaluating the Effects of Different Input Signals on Efficiency Coefficients of Artificial Neural Network Models for Intelligent Estimation of Flood Hydrographs

H. Pahlavani[1], A. Bahremand[2] and A.A. Dehghani[3]

The estimation of flood hydrograph characteristics in natural rivers is of hydrologists interests. In this paper, the ability of neural networks for estimation of flood hydrograph to Shirindareh reservoir dam in Khorasan province is evaluated. Therefore, all flood hydrograph events of hydrometery station in upstream were collected and normalized. It is notable that the flood hydrometery was estimated 2, 3, 4 and 5 hours earlier using the flood discharges at 2, 3, 4 and 5 previous hours as model inputs respectively. In each pattern, four signals were selected for considering the effect of number of inputs for estimation of flood hydrograph. The results show that by increasing the estimation lag time, the accuracy of results decrease and in given lag time, by increasing the number of input, the accuracy of results increase. The results show that the amount of efficiency coefficients, which is the representation of goodness of flood hydrograph modeling, is increased from 0.79 for signal one to 0.91 for signal four.

Keywords: Flood Hydrograph, Artificial Neural Network, Shirindarreh Reservoir Dam Basin, Learning Algorithms and Transfer Function.

1- M.SC. student, Department of Watershed Management Engineering, Gorgan University of Agricultural Sciences and Natural Resources.
2- Assistant Professor, Department of Watershed Management Engineering, Gorgan University of Agricultural Sciences and Natural Resources.
3 Assistant Professor, Department of Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources, a.dehghani@gau.ac.ir