مدل‌سازی فرآیند بارش – رواناب در حوضه لیقوان چای با استفاده از نرون شرطی آستانه دمایی

محمدتقی اعلمی[1] * ، حجت حسین‌زاده[2]

تاریخ دریافت: 87/8/21 پذیرش: 88/5/10
1و2- دانشیار و دانشجوی سابق کارشناسی ارشد، گروه عمران آب، دانشگاه تبریز
* مسئول مکاتبه E-mail:mtaalami@tabrizu.ac.ir

چکیده

لزومِ پیش‌بینی بده رودخانه در کارهای عمرانی، برنامه‌ریزی برای استفادهٔ بهینه از مخازن سدها، سامان‌دهیِ رودخانه و هشدار سیل، کاملاً احساس می‌شود. در این راستا مسئلهٔ بارش- رواناب بیشترین توجه مدل‌سازهای شبکه‌های عصبی مصنوعی[1] را به خود معطوف کرده است. در این تحقیق از شبکه‌های عصبی چند لایه MLP[2] برای پیش‌بینی بارش- رواناب حوضه آبریز برف‌گیر لیقوان‌چای واقع در استان آذربایجان شرقی استفاده شده است. اطلاعات این حوضه شامل داده‌های بارش، دما و رواناب روزانه می‌باشد. در مراحل مختلف تحقیق اثرات هر یک از این عوامل (در قالب ترکیبات مختلف) در کارایی شبکه، مورد بررسی قرار گرفته است. همراهی سه عامل بارش در روز جاری و روزهای قبل، دما در روز جاری و روزهای قبل و رواناب در روزهای قبل در ماتریس ورودی بهترین نتایج را برای شبکه عصبی در پی داشته است. از آنجایی که حوضهٔ آبریز لیقوان یک حوضهٔ برفگیر می‌باشد، اثر دما در این حوضه و تبدیل برف به رواناب حائز اهمیت بوده و در ادامه مورد بررسی قرار گرفته و نرونی با نام نرون شرطی آستانهٔ دمایی CTT[3] تعریف شده است. مقادیر این نرون بصورت باینری بوده و اعداد صفر و یک را به خود می‌گیرد. معیار این تفکیک مقدار آستانهٔ دمایی ذوب برف می‌باشد که برای حوضهٔ لیقوان محاسبه شده است. در پایان نتایج مدل شبکه‌های عصبی با مدل هیدروگراف ذوب برف بی بعد DSH[4] مقایسه شده است. نتایج نشان دهندهٔ کارایی بهتر شبکهٔ عصبی نسبت به مدل ذوب برف DSH می‌باشد.

واژه‌های کلیدی: الگوریتم پس انتشار خطا، شبکه‌های عصبی مصنوعی، مدل سازی بارش- رواناب، نرون شرطی آستانه دمایی

[1] Artificial neural networks
[2] Multi layer perceptron
[3] Conditional threshold temperature
[4] Dimensionless snowmelt hydrograph

Archive of SID
www.SID.ir

Modeling Rainfall – Runoff Process in Lighvan Chai Basin Using Conditional Threshold Temperature Neuron

MT Aalami[1]*, H Hosseinzadeh[2]

[1, 2] Assoc. Prof. and Former Grad. Student, Dept. of Civil Engin., Univ. of Tabriz, Iran
* Corresponding author: E-mail: mtaalami@tabrizu.ac.ir

Abstract

Necessity of river flow forecasting in constructional works, planning for optimal usage of water reservoirs, river training and flood warning has been well recognized. In this regard, the rainfall – runoff process has been widely studied using artificial neural networks modeling. In the current research, multi layer perceptron was applied to forecasting rainfall – runoff of Lighvan Chai snowy basin in East Azarbaijan province. The data of the basin includes daily rainfall, temperature, and runoff which their effects on the efficiency of network were studied at different steps. Getting along with the factors of rainfall and temperature at the current day, previous days and runoff in previous days in entrance matrix has led to the best results for neural networks. As the Lighvan Chai is a snowy basin, the effect of temperature and snowmelt on runoff is very important and a new neuron which is called conditional neuron of threshold temperature was introduced. Figure of this neuron is binary and the numbers are zero – one. The snowmelt temperature is the criterion of using these numbers. The results of neural networks model was compared to those from the dimensionless snowmelt hydrograph (DSH) including a greater efficiency of the neural networks.

Key words: Artificial neural networks, Conditional threshold temperature neuron, Error back propagate algorithm, Rainfall-Runoff process.

Archive of SID

مقدمه

بارش- رواناب یکی از پیچیده‌ترین فرآیندهای هیدرولوژیکی است. برای سالیان زیاد، هیدرولوژیست‌ها در شناخت چگونگی تبدیل بارش به رواناب برای پیش‌بینی سیلاب بوده‌اند. از اهداف این شناخت می‌توان به ذخیرهٔ آب، کنترل سیلاب، آبیاری، زهکشی، کیفیت آب، تولید انرژی، مراکز تفریحی، پرورش ماهی و گسترش حیات وحش و... اشاره کرد. تعداد پارامترها، عدم پایداری مشخصه‌های حوضه‌های آبریز و مدل‌های بارش بیش از پیش مسئله را پیچیده می‌کند. استفاده از مدل‌های آماری، هیدرولیکی و هیدرولوژیکی سابقه طولانی در بحث مدل‌سازی بارش- رواناب داشته است. با توجه به مشکلات و نقاط ضعفی که در مدل‌های مفهومی و آماری وجود دارد، نیاز به

www.SID.ir

مدلی که با پارامترهای ورودی و خروجی بتواند عملیات نگاشت را انجام دهد، ضروری به نظر می‌رسد. طی دهۀ اخیر مدل ریاضی غیرخطی شبکه‌های عصبی مصنوعی به ابزارهای پیش‌بینی افزوده شده و تحقیقات متنوعی در زمینۀ مدل‌سازی بارش-رواناب با استفاده از این ابزار صورت گرفته است. آنمالا و همکاران (2001) از شبکه‌های عصبی مصنوعی بازگشتی برای پیش‌بینی رواناب ماهانه در سه حوضۀ آبریز واقع در کانزاس استفاده کرده‌اند. بازده شبکه برای معماری‌های مختلفی بر اساس تعداد نرون‌ها سنجیده شده است. بارش و دمای ماهانه بعنوان ورودی‌های شبکه و رواناب ماهانه بعنوان خروجی شبکه انتخاب شده‌اند. اسمیت و الی (1995) با توجه به مسئلۀ توزیع بارش در حوضۀ آبریز از داده‌های هواشناسی و ماهواره‌ای حاصل از سنجش از دور توزیع بارش را مشخص کردند و سپس یک شبکه عصبی پس‌انتشار برای پیش‌بینی دبی اوج و زمان دبی اوجِ ناشی از یک نمونۀ بارش را آموزش داده و در نهایت با استفاده از سری‌های فوریه خروجی گسسته بر روی هیدروگراف رواناب را برازش دادند. وو و همکاران (2005) در یک تحقیق برای پیش‌بینی رواناب حوضۀ آبریز و جریان رودخانه‌ای از شبکه‌های عصبی مصنوعی استفاده کردند. داده‌های ورودی مدل شامل بارش و رواناب خروجی در حوضه بوده و مطالعه بر روی یک حوضۀ کوچک شهری در کالیفرنیای شمالی انجام گرفته است. این مدل در پیش‌بینی چند ساعتۀ رواناب با بازه‌های زمانی 15 دقیقه‌ای موفق عمل کرده است. از ابعاد مهم این تحقیق می‌توان به گسترش سازمان‌دهی داده‌های ورودی، ارزیابی کارایی مدل و روشهای اعمال شده در شبکه‌های عصبی مصنوعی اشاره کرد. نتایج تحقیق نشان می‌دهد که می‌توان از شبکه‌های عصبی مصنوعی برای هشدار سیل در حوضه‌های شهری بصورت مؤثر استفاده کرد. توکار و پگی (1999) از شبکه‌های عصبی مصنوعی برای پیش‌بینی رواناب روزانه که تابعی از بارش روزانه، دما و آب ناشی از ذوب برف برای حوضۀ آبریز بود، استفاده کردند. کاهش طول داده‌های لازم برای کالیبره کردن، و کاهش زمان کالیبره کردن مدل از نتایج استفاده از شبکه‌های عصبی مصنوعی در این مدل بوده است. بارچوال (2002) از شبکه‌های عصبی مصنوعی برای پیش‌بینی جریان کوتاه مدتِ رودخانه تحت اثر بارش شدید استفاده کرد. شبکۀ نهایی ، از مقایسۀ الگوریتم‌های مختلفی بدست آمده و آموزش شبکه با الگوریتم QN [1] انجام گرفته است. لاوزن و همکاران (2006) دربارۀ استفاده از بارش‌های غیرمتجانس با مقادیر مختلف به جای بارش میانگین در حوضۀ باسِن‌باست فرانسه، برای مدل‌سازی بارش-رواناب تحقیق کردند. در این تحقیق از مدل شبکۀ عصبی کوهنن و MLP برای طبقه‌بندی بارش استفاده شده است. هسیو و همکاران (2006) از شبکه‌های عصبی مصنوعی برای پیش‌بینی فرآیند بارش-رواناب استفاده کردند. در این تحقیق از روش LLSSIM[2] برای تعریف ساختار شبکه‌های عصبی مصنوعی و ارزیابی رفتار غیرخطی حوضۀ آبریز استفاده شده است. ساجی‌کومار و تانداورسوارا (1999) از شبکه‌های عصبی مصنوعی TBP-NN[3] برای آموزش شبکه استفاده کردند که بارش و رواناب ماهانه به ترتیب ورودی و خروجی‌های شبکه بودند. در این تحقیق کارایی شبکه‌های عصبی مصنوعی نسبت به مدلِ FSM[4] نشان داده شده است.در تحقیق حاضر کارایی مدل شبکه‌های عصبی مصنوعی برای مدلسازی حوضه برفگیر لیقوان چای مورد ارزیابی قرار گرفته است.

در این مقاله ابتدا تئوری شبکه های عصبی و جایگاه آنها در تحقیق آورده شده است و در ادامه منطقه مورد مطالعه معرفی شده است. در قسمت تحلیل نتایج با تغییر در پارامتر ورودی‌های شبکه،

[1] Qusi-newton
[2] Linear least squares simplex model
[3] Temporal back propagation neural network
[4] Functional series model

Archive of SID

www.SID.ir

ساختارهای مختلفی از شبکه‌های عصبی مصنوعی ایجاد شده است تاثیر هر کدام از این پارامترها در ورودی شبکه‌های عصبی مصنوعی تحلیل شده است. در مرحلهٔ بعد نرون آستانهٔ دمایی معرفی و شبکهٔ مربوطه تشکیل می‌شود. در انتها نیز نتایج حاصله از شبکه‌های عصبی مصنوعی با یک روش کلاسیک مورد مقایسه قرار گرفته است.

مواد و روش‌ها

تئوری شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی می‌توانند نگاشت یا تبدیل از فضای چندبعدی به فضای چندبعدی دیگر را انجام دهند و قابلیت هایی از قبیل شناسایی الگو، تفکیک الگو، نگاشت غیرخطی، حافظهٔ انجمنی، خودسازمان‌دهی و کنترل را دارا می‌باشند. هاپفیلد (1986) با معرفی شبکه‌های حافظه انجمنی و راملهارت و همکارانش (1986) با معرفی الگوریتم پس‌انتشار خطا گام مهمی در جهت توسعهٔ شبکه های عصبی برداشتند (منهاج 1379). یکی از مهمترین انواع شبکه‌های عصبی، شبکه‌های MLP می‌باشند. این شبکه‌ها از چند لایه تشکیل شده‌اند که در شکل 1 نمونه‌ای از شبکه‌های MLP سه لایه نشان داده شده است.

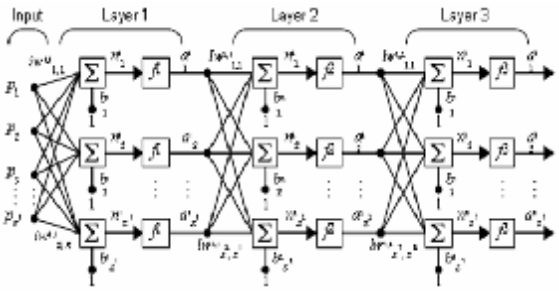

شکل 1- شبکه عصبی مصنوعی سه لایه

در هر لایه تعدادی نرون در نظر گرفته می‌شود که به نرون‌های لایه‌های مجاور وصل می‌شوند. در این شبکه‌ها ورودی مؤثر هر نرون، حاصلضرب خروجی نرون‌های لایهٔ قبل در وزن‌های میان آن نرون‌ها است. نرون‌های لایهٔ اول اطلاعات ورودی را گرفته و از طریق اتصالات مربوطه به نرون‌های لایهٔ مخفی منتقل می‌کنند. در لایهٔ مخفی پس از محاسبهٔ ورودی مؤثر هر نرون، این ورودی از یک تابع محرک گذرانده می‌شود. برای این کار توابعِ محرک مختلفی ارائه شده است. گرایش بیشتر محققان به استفاده از توابع محرک کران‌دار می‌باشد که مشهورترین آنها تابع سیگموید است. برای هماهنگی بین برد تابع محرک و خروجی شبکه نیاز به نرمال‌سازی داده‌ها می‌باشد. با استفاده از تابع زیر می‌توان داده‌ها را در هر بازهٔ دلخواه موجود نرمال‌سازی کرد.

$$x_i' = \frac{x_i(B_u - B_L) + x_{\max}B_L - x_{\min}B_u}{x_{\max} - x_{\min}} \qquad [1]$$

در این رابطه دسته اطلاعات $(x_1, x_2, ..., x_n)$ به بازهٔ دلخواه $[B_L, B_u]$ نگاشته می شوند که $x_{\max}, x_{\min}$ به ترتیب حداقل و حداکثر داده‌های ورودی می‌باشند. پارامترهای قابل تنظیم در شبکه‌های MLP، وزن اتصالات مابین لایه‌ها است و فرآیند آموزش در این شبکه‌ها، به معنی یافتن مقادیر مناسب برای وزن‌های اتصالات مابین نرون‌ها است. متداول‌ترین الگوریتم یادگیری این شبکه‌ها، الگوریتم پس‌انتشار خطا است. از پارامترهای طراحی شبکه‌های عصبی می‌توان به معیار کارایی شبکه، تقسیم داده‌ها، پیش‌تحلیل داده‌ها، تعیین ورودی‌های مدل، توابعِ محرک، تعداد تکرارها و معیار توقف شبکه اشاره کرد. بعد از آموزش، شبکه برای

Archive of SID

www.SID.ir

قسمتی دیگر از داده‌ها مورد صحت سنجی قرار می‌گیرد.

منطقهٔ مورد مطالعه و داده‌ها

حوضهٔ لیقوان چای یکی از زیر حوضه‌های فرعی حوضهٔ آبریز دریاچهٔ ارومیه بوده و با وسعتی معادل 76 کیلومترمربع در دامنهٔ شمالی سهند بین طول‌های شرقی ″30-´20-°46 تا ″30-´27-°46 و عرض‌های شمالی ″55-´42-°37 تا ″30-´49-°37، گسترده شده است (شکل 2). به طور کلی حوضه آبریز لیقوان به علت وجود پوشش‌های برفی دائمی در ارتفاعاتِ مختلف آن دارای رژیم برفی بوده و ذوب برف در جریان دائمی آن مؤثر و قابل ملاحظه است. ریزش باران‌ها در فصل بهار شدید است و این اثر قابل توجهی در بالا بردن مقدار دبی سالانه رودخانه دارد.

سری‌های زمانی روزانهٔ داده‌های بارش، رواناب و دما برای سال‌های70 الی82 (به جز 73 و 74) به ترتیب در شکل‌های 3، 4 و5 ارائه شده است.

نتایج و بحث

در این تحقیق ابتدا بارش به تنهایی به عنوان عامل مؤثر مورد بررسی قرار گرفت. با اتخاذ پارامتر n، ورودی بارش در روز جاری و روزهای قبل که می‌تواند در رواناب خروجی موثر باشد $(P(t), P(t-1)....P(t-n))$، معرفی شده است. استفاده از نرونهای بارش به تنهایی، در لایه ورودی، همبستگی چندانی در پی نداشته و ضریب همبستگی حدود 0/08 به دست آمد (جدول1). این موضوع نشان‌دهنده تأثیر کم نرون بارش در پیش بینی رواناب روزانه حوضه لیقوان چای دارد. به عبارتی موفق نبودن پدیده بارش در پیش‌بینی رواناب این حوضه را نشان می دهد. یکی از دلایل این رفتار، می‌تواند بالا بودن ضریب رواناب حوضه باشد که بعضاً حتی بیشتر از یک بوده و نشان دهندهٔ وجود یک منبع رواناب خارجی می‌باشد. دلیل دیگری که می‌توان به آن اشاره کرد، برفگیر بودن منطقه است. در داده‌های ورودی بارندگی تفکیکی بین داده‌های برف و باران صورت نگرفته که این موضوع می‌تواند باعث ایجاد خطا در مدل‌سازی گردد.

در ادامه داده‌های بارش و دما برای روز جاری و روزهای قبلی به عنوان عوامل مؤثر در رواناب روز جاری وارد شبکه نموده و کارایی شبکه مورد تحلیل قرار گرفت. با استفاده از نرون‌های بارش و دما در لایه ورودی، ضریب همبستگی حدود 0/29 بدست آمد. همراهی نرون بارش و دما باعث افزایش قدرت پیش بینی شبکه در برآورد رواناب روزانه حوضه لیقوان چای شده است. از آنجایی که حوضه لیقوان چای یک حوضه برف‌گیر است و در اطلاعات بارندگی، برف و بارش تفکیک نشده‌اند، خطایی در داده‌های ورودی وجود داشته است. اما با ورود نرون دمایی یک معیار تفکیک برای داده‌های برف و بارش به شبکه القا می‌گردد که در نهایت باعث افزایش نسبی کارایی شبکه می‌شود.

برای بالا بردن میزان کارایی شبکه، داده‌های بارش و رواناب به صورت ماتریس ورودی وارد شبکه شد. با ورود نرون رواناب در روزهای قبلی، ضریب همبستگی به مقدار 0/92 افزایش یافت (جدول1). این نتیجه نشان دهنده وابستگی رواناب روز جاری به رواناب روزهای قبل می‌باشد. با اضافه کردن اولین نرون رواناب در روز قبلی، $Q(t-1)$، تغییرات اساسی در مقدار ضریب همبستگی مشاهده می‌شود. علت افزایش ضریب همبستگی با اضافه شدن نرون

Archive of SID

www.SID.ir

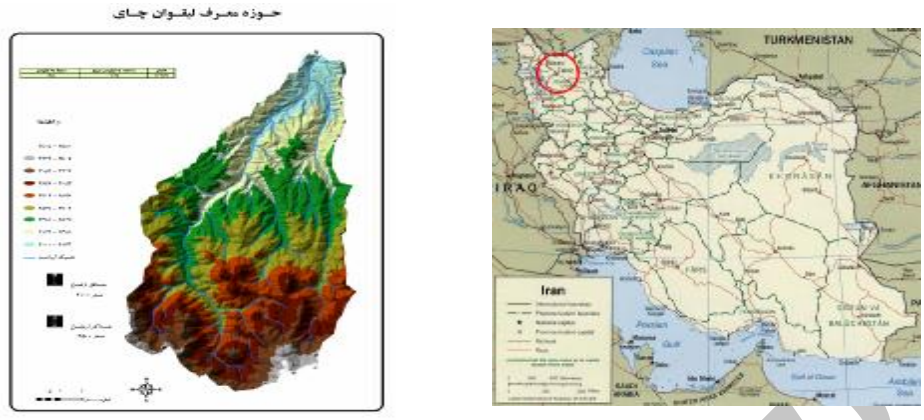

شکل 2- موقعیت حوزهٔ آبریز لیقوان‌چای

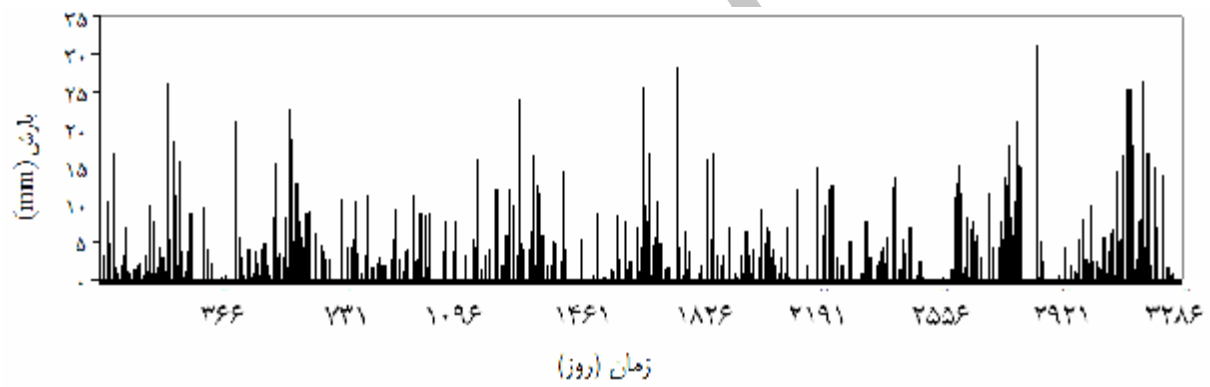

شکل 3- سری زمانی بارش لیقوان‌چای

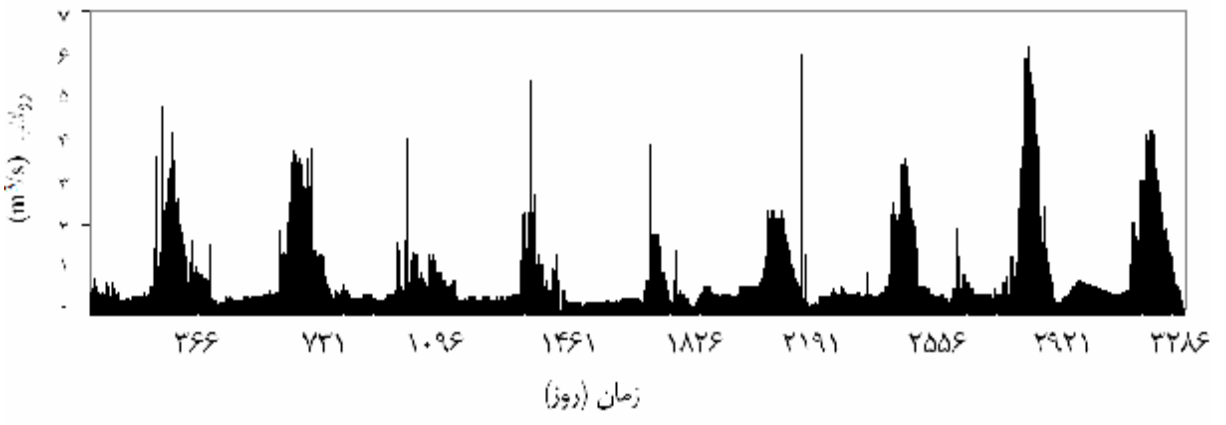

شکل 4- سری زمانی رواناب لیقوان‌چای

www.SID.ir

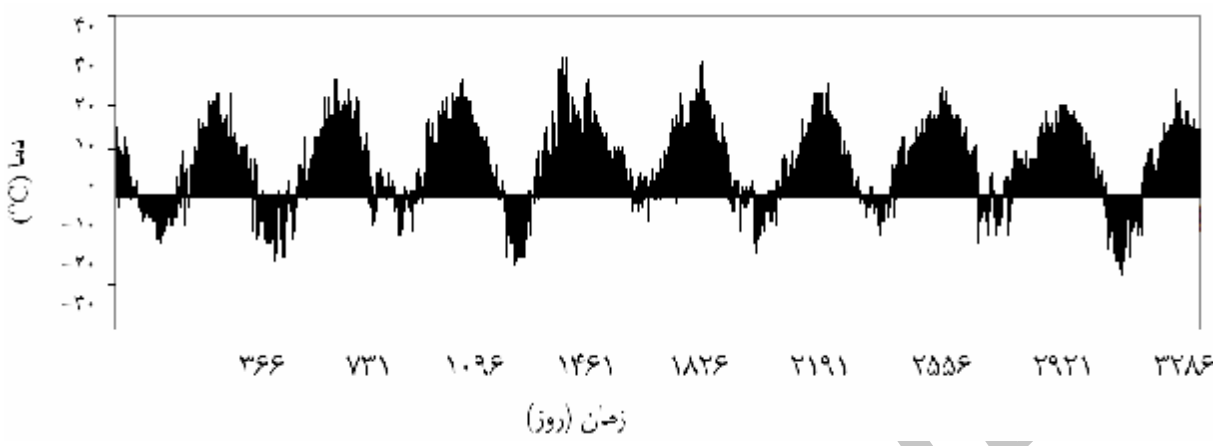

شکل 5- سری زمانی دمای لیقوان‌چای

جدول 1- ساختار شبکه‌های عصبی مصنوعی با داده‌های بارش، دما و رواناب

حالات مختلف تحلیل شبکه	ساختارشبکه	تعداد نرونهای بارش	تعداد نرونهای دما	تعداد نرونهای رواناب	تعداد نرونهای میانی	معیار نش- ساتکلیف	میانگین مربعات خطا	ضریب همبستگی آموزشی	ضریب همبستگی صحت سنجی
نرون ورودی بارش	7-9-1	7	----	----	9	0/0786	0/0243	0/0853	0/0785
نرون ورودی بارش، دما	8-8-1	5	3	----	8	0/2907	0/0186	0/3122	0/2886
نرون ورودی بارش، رواناب	8-8-1	5	----	3	8	0/93	0/0026	0/92	0/92
نرون ورودی بارش، رواناب و دما	14-8-1	6	4	4	8	0/9675	0/0011	0/9681	0/9639
ماه‌های گرم	6-4-1	4	----	2	4	0/9526	0/0021	0/9563	0/9525
ماه‌های گرم بدون بارش صفر	6-4-1	4	----	2	4	0/9033	0/0053	0/91	0/9014

رواناب، ناشی از وضعیت داده‌های حوضه آبریز لیقوان می‌باشد. میانگین ضریب رواناب حوضه برای داده‌های بارش و رواناب، با توجه به گزارش مندرج در دفترچه مطالعات حوضه لیقوان‌چای حدود 0/97 می‌باشد. این موضوع وابستگی زیاد رواناب روز جاری به روزهای قبل را باعث شده است. در واقع با ورود رواناب روز

www.SID.ir

قبل بـه عنـوان نـرون ورودی، افـزایش ضـریب کـارایی شبکه کاملاً منطقی به نظر می‌رسد.

در مرحلـهٔ بعـدی هـر سـه دادهٔ بـارش، دمـا و رواناب را به صورت ماتریس ورودی شبکه وارد کـرده و کارایی شبکه مورد بررسـی قـرار گرفـت. بـا در نظـر گرفتن نرون‌های دما، بـارش و رواناب در لایـه ورودی بیشترین مقدار ضریب همبستگی حاصل شـد و ضـریب همبستگی در این حالـت برابـر بـا 0/9681 بدسـت آمـده است (جدول1). در شکل 6 معیارهای کارایی شبکه برای آمـوزش، صـحت سـنجی و نـش-سـاتکلیف بـا یکـدیگر مقایسه شده انـد. نکتـه جالـب توجـه قرارگیـری مقـادیر معیار نش-ساتکلیف در بین مقادیر همبستگی آموزشـی و صحت سنجی است. برای مشاهده هرچـه بهتـر داده-های خروجی در مقابل داده‌های مـشاهداتی، درشـکل 7 از نمودار پراکندگی و در شکل 8 از نمودار سری زمـانی اسـتفاده شـده اسـت. در نمـودار شـکل 7 مقـادیری کـه منطبق بر داده‌های مشاهداتی نیستند فاصله بسیار کمـی با این داده‌ها دارنـد. آنچـه در شـکل 8 مـشخص اسـت، پوشش خوب داده‌های خروجی شـبکه عـصبی در نقـاط اسـت کـه دارای تغییـرات ناگهـانی هـستند. بـه عبـارتی مقادیر دبی در روزهایی کـه بـصورت ناگهـانی افـزایش می یابد، توسط شبکه‌های عصبی به خوبی شبیه سـازی شده است.

مشخص است که با تلفیق تمامی داده‌های موثر در رواناب، بیشترین کارایی شبکه حاصل مـی‌شـود. در واقع اثر همزمان هر سه دادهٔ بارش، رواناب و دما باعث شده است که بالاترین ضریب را در ایـن تحقیـق داشـته باشـیم. درمـورد ایـن امـر، عـلاوه بـر تنـوع داده‌هـا در ماتریس ورودی، می‌توان به اثر نرون دمایی در پوشـش داده‌های بارش برف اشاره کرد. همان طـوری کـه قـبلاً گفته شد، در داده‌های بـارش موجـود روزهـای برفـی و بارانی متمایز نشده اند و این امر باعث افزایش خطـا در اسـتفاده از داده هـای بـارش بـرای مدلـسازی پدیـده بارش-رواناب ایجاد می کند.

برای تایید مورد فوق‌الذکر بـا حـذف داده‌هـای ماه‌های سرد، داده‌های ماه‌های گرم از اول اردیبهشت تا آخر مهر ماه در نظر گرفته شد. در ایـن مرحلـه ضـریب همبستگی برابر 0/9563 بدست آمد. کاهش طول داده‌هـا از یک طرف و کاهش خطای بارندگی در داده‌ها از طرف دیگر، در مقایسه با مرحلـه قبـل، تقریبـاً اثـر همـدیگر را خنثی می‌کنند.

در مقایسهٔ ساختارهای بدست آمده از دو شبکهٔ ماه‌های گرم و کل داده‌ها آنچه مشخص است کم حجم بودن ساختار شبکه برای داده‌های ماه‌های گرم می‌باشد. ساختار بدست آمده برای شبکه با داده‌های بارش و رواناب برای کل داده‌ها 1-8-14 می‌باشد (به غیر از سه نرون که نرون دمایی هستند). از آنجایی که نرون‌های ورودی و میانی نسبت به ماه‌های گرم بیشتر می‌باشند، شبکهٔ مورد نیاز برای آموزش آن نیز بزرگتر خواهد بود. در ادامه با حذف داده‌های متناظر با بارش صفر اثر تمرکز داده‌های ورودی و طول داده‌ها مورد بررسی قرار گرفت چرا که حدود 78 درصد داده‌های روزانه بارش‌ها در طول دوره آماری صفر هستند. ضریب همبستگی برای این مرحله 0/91 بدست آمد که این نتیجه نشان دهنده برتری طول داده‌ها در مقابل تمرکز آنها است (شکل 9). در مقایسهٔ دو عامل کاهش طول داده‌ها و بهتر شدن توزیع یکنواخت آنها، به علت اینکه طول داده‌ها بسیار کاهش می‌یابد، حذف داده‌های بارش صفر در این تحقیق باعث کاهش محسوس کارایی مدل شبکه‌های عصبی می‌شود.

Archive of SID

www.SID.ir

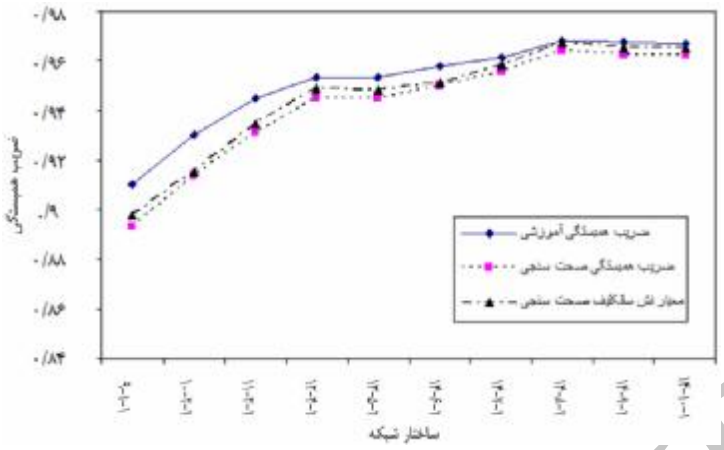

شکل 6 - مقایسه معیارهای کارآیی شبکه ورودیهای بارش ، دما و رواناب

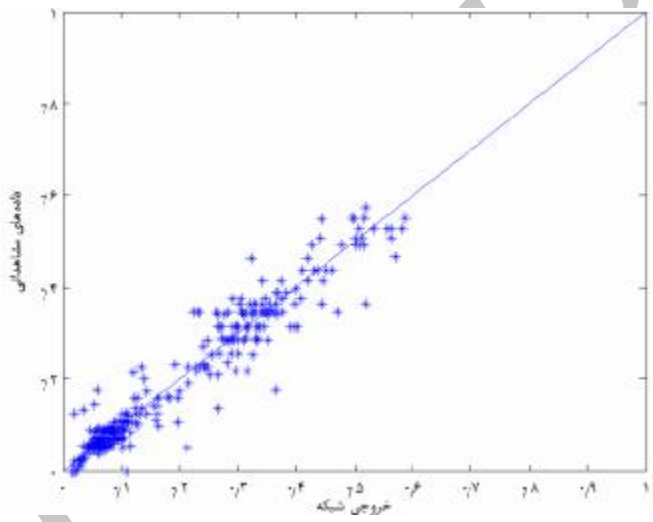

شکل 7- نمودار پراکندگی خروجی شبکه و داده‌های مشاهداتی برای ورودی‌های بارش، رواناب و دما

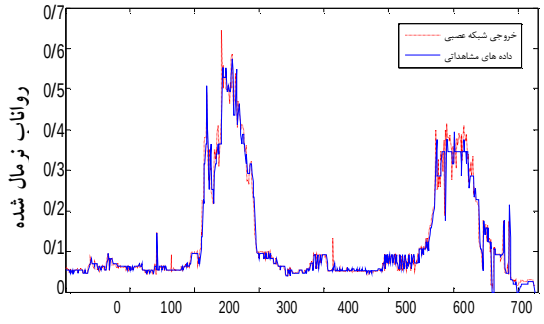

شکل 8- سری زمانی رواناب مشاهداتی همراه با خروجی شبکه عصبی مصنوعی برای داده‌های بارش، رواناب و دما

www.SID.ir

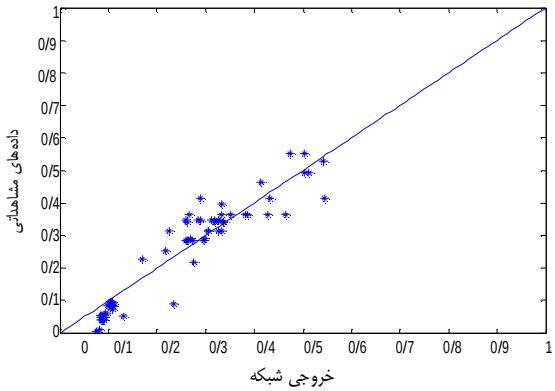

شکل 9- نمودار پراکندگی داده‌های مشاهداتی و خروجی ANN برای ماه‌های گرم بدون بارش صفر

نرون شرطی آستانهٔ دمایی

با توجه به کمبود داده‌های هیدرولوژیکی در بسیاری از کشورها از جمله ایران و وجود محدودیت در داده‌های حوضه‌های مختلف، از جمله داده‌های دمایی در این مطالعه، اقدام به معرفی یک نرون جدید به نام نرون شرطی آستانه دمایی شده است. با استفاده از این نرون پیشنهادی می‌توان در حوضه‌هایی که دارای محدودیت داده‌های دمایی می‌باشند، اثر دما را در فرآیند بارش-رواناب لحاظ کرد. از طرفی برای تحقیق فرآیند بارش و رواناب در حوضه‌های آبریز برف‌گیر داده‌های دما لازم و ضروری هستند. با توجه به اینکه برف در دمای خاصی(دمای آستانه) بسته به شرایط اقلیمی منطقه ذوب می‌شود، ، دماهایی که از این مقدار آستانه بالاتر یا برابر هستند را یک و دماهایی را که از این آستانهٔ دمایی کوچک‌تر هستند، صفر در نظر گرفته شد. با توجه به تحلیل‌های صورت گرفته و آنالیز حساسیت انجام گرفته بر اساس معیار کارایی شبکه، دمای آستانه برای حوضه حاضر یک درجه سانتی گراد بدست آمد. با جایگزین کردن نرون دمایی با نرون شرطی آستانه، اثر نبود داده‌های دمایی در یک حوضه برف‌گیر لیقوان چای مورد بررسی قرار گرفت. ضریب همبستگی بدست آمده در این مرحله برابر 0/9563 بود. در مقایسه ضریب کارایی این مرحله با مرحله قبل که برابر 0/9639 می‌باشد، آنچه مسلم است با تغییر نرون دمایی از داده‌های واقعی دما به داده‌های شرطی صفر و یک، مقدار ضریب همبستگی کاهش کمی داشته است. این مسئله نشان دهنده قابلیت نرون پیشنهادی در مدلسازی فرآیند بارش- رواناب با استفاده از شبکه‌های عصبی است. همان طوری که اشاره شده، از کاربردهای دمای آستانه می‌توان به زمانی اشاره کرد که اطلاعات دمایی در منطقه موجود نباشد و در این تحقیق با استفاده از الگوهای دمایی مناطق مجاور و یا حدس، می‌توان گفت که آیا دما در آن روز خاص از این مقدار آستانه بیشتر بوده یا نه؟ پاسخ این سوال در برخی از روزهای سال (مربوط به ماههای گرم) چندان مشکل نیست و می‌توان به راحتی بیشتر درایه‌های مربوط به نرون شرطی ماتریس ورودی را پر کرد. با انتخاب داده‌ها برای بقیهٔ درایه‌های نرون شرطی، می‌توان با آنالیز آماری نشان داد که این داده‌ها از سری نرمال در یک بازهٔ خطایی مورد قبول پیروی

Archive of SID

www.SID.ir

می‌کنند. برای مدل کردن این حالت، با ایجاد تغییرات در مقادیر نرون شرطی، خطایی به شبکه وارد می شود. اعمال خطا به این صورت است که در نرون‌هایی که مقدار یک دارند صفر، و در نرون‌هایی که مقدار صفر دارند یک قرار داده می شود. نحوهٔ انتخاب این نرون‌ها به صورت کاملاً تصادفی خواهد بود. در گام اول به 5 درصد داده‌ها خطا اعمال می شود. درگام دوم به 10 درصد از داده‌ها خطا اعمال می‌شود و به همین ترتیب فرآیند ادامه می یابد. آنچه مسلم است در صورتی که 50 درصد داده‌ها را تغییر داده شود، به نوعی حداکثر خطا به شبکه وارد شده است. نتایج کارایی شبکه در شکل 10 آمده است. همان طوری که ملاحظه می‌شود در 25 درصد داده‌های خطا، یک تغییر شیب در نمودار اتفاق می‌افتد. بعد از این مرحله شیب تابع خطا بیشتر می‌شود و با افزایش درصد داده‌های خطا رشد خطا نیز افزایش می‌یابد. بنابراین مقدار داده‌های خطای مجاز که به نرون شرطی می تواند وارد شود 25 درصد می‌باشد. یعنی در صورت نبود داده‌های دمایی در یک منطقه اگر تا 25 درصد حدس‌های نرون شرطی غلط باشد باز می‌توان به نتایج ANNs امیدوار بود. با عامل خطا در 25 در صد داده‌ها در شکل 11 مشاهده می‌شود که مقادیر خطای بین داده‌های مشاهداتی و خروجی شبکه با نرون شرطی از توزیع نرمال پیروی می کند.

مدل ریاضی DSH [1]

در قسمت قبل اثرات هر کدام از پارامترهای هیدرولوژیک موجود روی مدل‌سازی بارش-رواناب با استفاده از شبکه‌های عصبی بررسی گردید. برای مقایسهٔ میزان کارایی شبکه‌های عصبی برای حوضه برف‌گیر از یک مدل ریاضی با نام DSH استفاده شد (کانینگهام 1977). این مدل فرآیند تبدیل ذوب برف به رواناب را در دوره ذوب (T_m) مورد ارزیابی قرار می‌دهد. یکی از پارامترهای موثر در این مدل تعداد روزهایی است که دما بر روی ذوب برف اثر می‌گذارد که در این تحقیق برابر سه روز بدست آمده است. نتایج بدست آمده برای این مدل و شبکه‌های عصبی و همچنین داده‌های مشاهداتی برای حوضه لیقوان‌چای در شکل 12 آورده شده است. ضریب همبستگی مدل DSH پس از آزمون و خطا برای سالهای مختلف 0/85 بدست آمده است در حالیکه این ضریب برای شبکه‌های عصبی حدود 0/96 می‌باشد. لازم به ذکر است که دوره مدل‌سازی برای این مورد از اردیبهشت تا تیر ماه 1379 بمدت 67 روز بوده و نتایج نشان‌دهنده برتری مدل شبکه‌های عصبی مصنوعی نسبت به مدل کلاسیک DSH برای این دوره بوده است.

[1] Dimensionless snowmelt hydrograph

Archive of SID

www.SID.ir

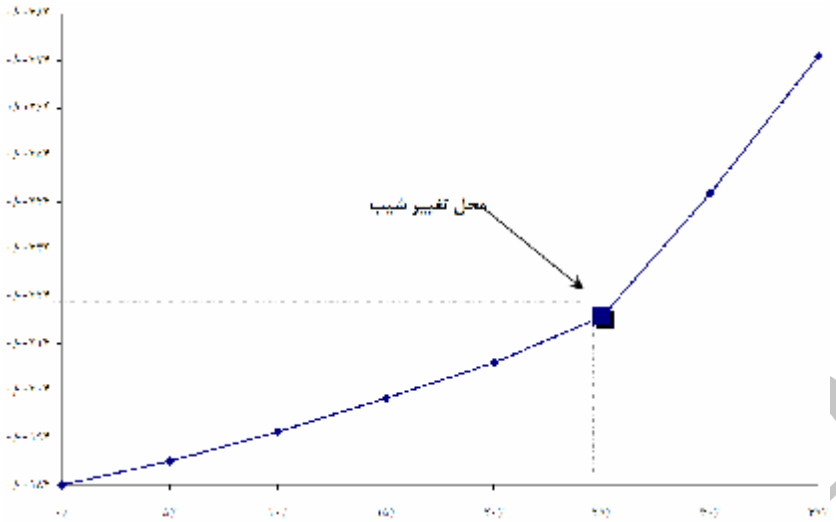

شکل 10- نمودار خطا با تعداد درصد داده‌های خطا ورودی برای نرون شرطی آستانهٔ دمایی

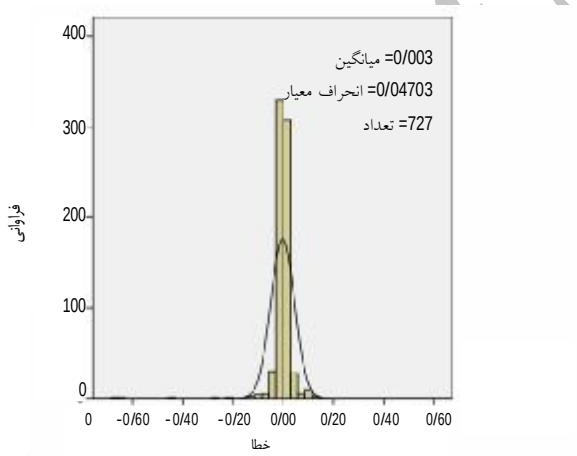

شکل11- هیستوگرام خطای شبکه و توزیع نرمال مربوط به اعمال خطا به نرون آستانهٔ دمایی

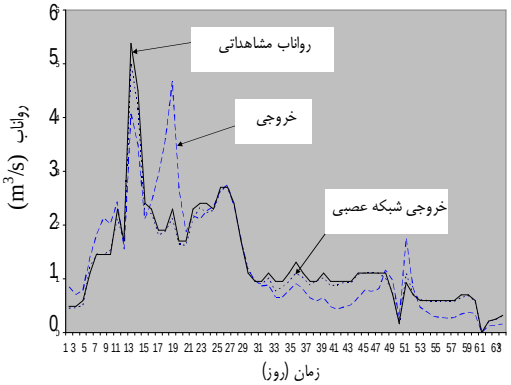

شکل 12- هیدروگراف های مشاهداتی، DSH و شبکه عصبی در دورهٔ ذوب برف

www.SID.ir

نتیجه‌گیری و پیشنهادات

در این تحقیق ضمن مدل سازی بارش-رواناب برای حوضه برف‌گیر لیقوان‌چای با استفاده از شبکه‌های عصبی مصنوعی، یک نرون شرطی آستانهٔ برای جایگزین کردن نرون دمایی معرفی شد. بطور خلاصه نتایج حاصله زیر را می‌توان ارائه داد:

1- با توجه به ضریب رواناب بالای حوضه لیقوان لحاظ کردن فقط بارش در مدلسازی رواناب منطقه نبوده لیکن به علت برف‌گیر بودن حوضه نرون دمایی منطقه نقش مهمی را ایفا می‌کند. همراهی سه نرون بارش، دما و رواناب بالاترین ضریب همبستگی را در پی خواهد داشت.

2- با جایگزین کردن نرون دمایی با نرون شرطی آستانه و بررسی نتایج دو مرحله، می‌توان گفت که نرون شرطی می‌تواند برای حوضه‌هایی با محدودیت داده‌های دمایی موثر عمل کند.

3- در مقایسه مدل ریاضی DSH با ANNs در مدلسازی ذوب برف ، برتری شبکه عصبی مصنوعی نسبت به مدل کلاسیک DSH مشخص گردید.

برای تحقیقات آینده می‌توان مواردی را به شرح زیر پیشنهاد کرد:

- مقایسه با سایر مدل‌های تفهیمی و یا جعبه سیاه از جمله مدل سری‌های زمانی.
- وارد کـــردن داده های دما،بارش و رواناب بصورت فازی و مدلسازی نروفازی.
- ارزیابی سایـــر الگوریتم های آموزشی و انواع شبکه‌های عصبی از جمله شبکه عصبی بازگشتی.

منابع مورد استفاده

منهاج، م. 1379. مبانی شبکه‌های عصبی(هوش محاسباتی). چاپ اول، انتشارات دانشگاه صنعتی امیرکبیر.

Anmala J, Zhang B and Govindaraju RS, 2000. Comparison of ANNs and empirical approaches for predicting watershed runoff. Journal of Water Resources Planning and Management, 126: 18200-18207.

Bartual RG, 2002. Short term river flood forecasting with neural networks. Proceeding of Iemss, 160- 165.

Cunningham AB, 1977. Synthesis of snowmelt runoff hydrographs. Journal of hydraulics division, 103: 12668-12675.

Hsu KL, Gupta H and Sorooshian S, 1995. Artificial neural network modeling of the rainfall-runoff Process. Water resources research, 31: 2517-2530.

Archive of SID

www.SID.ir

Lauzon N, Anctil F and Baxter CW, 2006. Classification of heterogeneous precipitation fields for the assessment and possible improvement of lumped neural network models for stream flow forecasts. hydrologic earth system science dscussion, 3: 201–227.

Sajikumar N and Thandaveswara BS, 1999. A non-linear rainfall-runoff model using an artificial neural network. Journal of hydrology, 216: 32-55

Smith J and Eli RN, 1995. Neural-network models of rainfall-runoff process. Journal of water resource planning and management, 121: 6, 7613-7620.

Tokar AS and Peggy JA, 1999. Rainfall-runoff modeling using artificial neural networks. Journal of hydrologic engineering, 4: 232-239.

Wu S, Han JS, Annambhotla S and Bryant BS, 2005. Artificial neural networks for forecasting watershed runoff and stream flows. Journal of hydrologic engineering, 10: 216-222.

Archive of SID

www.SID.ir