

**کاربرد مدل شبکه عصبی در برآورد رواناب
مطالعه موردی: حوضه آبریز پلاسجان - حوضه آبریز زاینده رود**

مسعود نصری، عضو هیات علمی دانشگاه آزاد اسلامی، واحد اردستان

Email: ps_sepahan@yahoo.com

رضامدرس، دانشکده منابع طبیعی، دانشگاه صنعتی اصفهان

محمد تقی دستورانی، استادیار دانشکده منابع طبیعی، دانشگاه یزد

**Application of Artificial Neural Network for runoff estimation
Case study: Plajan Basin-Zayandehrud Watershed**

Masoud Nasri, Faculty member, Islamic Azad University, Ardestan Branch

Email: ps_sepahan@yahoo.com

**Reza Modarres, Graduated student, Faculty of Natural Resources, Isfahan
University of Technology**

**Mohammad Taghi Dastorani, Assistant Professor, Faculty of Natural resources,
Yazd University**

کاربرد مدل شبکه عصبی در برآورد رواناب مطالعه موردی: حوضه آبریز پلاسجان - حوضه زاینده رود

چکیده

برآورد رواناب در یک حوضه آبریز اهمیت زیادی در مدیریت منابع آب حوضه دارد. با وجود مدل‌های فیزیکی و آماری که هر کدام برخی از پارامترهای حوضه را به منظور برآورد رواناب را در بر می‌گیرند، استفاده از شبکه‌های عصبی به عنوان یک مدل جعبه سیاه نیز یکی از روش‌های مناسب محسوب می‌شود. هدف این تحقیق استفاده از شبکه عصبی پرسپترون چند لایه به منظور برآورد میزان رواناب روزانه از روی بارندگی روزانه حوضه آبریز پلاسجان است. ابتدا سری‌های بارندگی روزانه سه ایستگاه واقع در منطقه و سری روزانه دبی ایستگاه پلاسجان به سری نرمال تبدیل و با توجه به خود همبستگی و همبستگی عرضی بارندگی و رواناب، شش متغیر به عنوان ورودی به شبکه انتخاب شد. در پایان مشخص شد شبکه عصبی پرسپترون با چهار لایه مخفی اعتبار بیشتری در برآورد رواناب نسبت به سایر شبکه‌ها دارد.

کلمات کلیدی: رواناب، شبکه عصبی پرسپترون چند لایه، اعتبار سنجی، خود همبستگی، حوضه آبریز پلاسجان

مقدمه

مدل‌های مختلفی با درجات مختلفی از پیچیدگی به منظور برآورد رواناب از روی پارامترهای اقلیمی و فیزیکی حوضه‌های آبریز ابداع شده و توسعه پیدا کرده‌اند. این مدل‌ها به طور کلی به سه دسته تقسیم می‌شوند که شامل مدل‌های جعبه سیاه یا مدل‌های نظری^۱، مدل‌های مفهومی^۲ و مدل‌هایی که اساس کار آن‌ها روابط فیزیکی^۳ است هستند. مدل‌های جعبه سیاه معمولاً دارای یک ورودی و خروجی فیزیکی هستند و بنابراین مدل‌هایی کاملاً تجربی محسوب می‌شوند. مدل‌های مفهومی بارش-رواناب بر اساس ساده سازی روابط فیزیکی عناصر و پارامترهای دخیل در مدل بارش-رواناب عمل می‌کنند (اوکانر، ۱۹۹۷). این مدل‌ها برای پیش بینی مختصات هیدروگراف‌ها بسیار مناسب هستند. به همین دلیل برای ساختن روابط بارش-رواناب کارایی خوبی دارند (چن و آدامز^۴، ۲۰۰۵). با این حال درک چنین رابطه‌ای که عناصر آن

¹ Theoretical Models

² Conceptual Models

³ Physically based models

⁴ Chen and Adams

در مقیاس منطقه ای و ناحیه ای و حوضه ای و به لحاظ جغرافیایی متفاوت است، کار بسیار مشکلی است و هیدرولوژیست‌ها همواره سعی در ارائه مدل‌های توسعه یافته ای دارند که بر این مشکلات فایق آیند. در یک دهه گذشته تمایل به استفاده از شبکه‌های عصبی مصنوعی^۱ در بین هیدرولوژیست‌ها به شدت افزایش یافته است که از جمله آن‌ها می‌توان به اسمیت و الی^۲ (۱۹۹۵) با استفاده از روش پس‌خور و شبکه ۳ لایه، هسو و همکاران^۳ (۱۹۹۵) با استفاده از تلفیق مدل‌های فیزیکی و اقلیمی و اضافه کردن پارامترهایی مانند رطوبت خاک، داسون و ویلی^۴، ۱۹۹۸، توکار و جانسون^۵ (۱۹۹۹) با استفاده از داده‌های روزانه بارندگی، تبخیر و تعرق و دما در حوزه رودخانه Little Patuxent در مرلند آمریکا به منظور برآورد و پیش‌بینی رواناب، توکار و مارکوس^۶ (۲۰۰۰) در حوزه Fraser در ایالت کلرادو با تلفیق مدل‌های فیزیکی و پارامترهای اقلیمی به منظور پیش‌بینی رواناب و ژانگ و گووینداراجو^۷ (۲۰۰۳) با تلفیق پارامترهای ژئومورفولوژیکی و اقلیمی و بسیاری دیگر نام برد. تمام این محققین به قدرتمند بودن این روش برای مدل‌سازی پدیده‌های مختلف به ویژه پدیده‌های غیر خطی اذعان کرده‌اند. به عنوان مثال کانون و ویتفیلد^۸ (۲۰۰۲) آنرا بسیار قوی‌تر از رگرسیون خطی ارزیابی کردند. شمس‌الدین^۹ (۱۹۹۷) روش ANN را با روش‌های دیگر مانند رگرسیون خطی و روش فصلی و نزدیک‌ترین همسایه مقایسه کرد و نتیجه گرفت روش شبکه عصبی پیش‌بینی بهتری نسبت به سایر روش‌ها دارد. تحقیقات مختلف نشان داده شبکه‌های عصبی قابلیت مدل‌سازی سیستم‌های پیچیده که روابط ریاضی برای توصیف آن‌ها مشکل دارند را دارا هستند. همچنین قابلیت مدل‌سازی سیستم‌های با اعتشاش زیاد را دارا بوده و برای تشخیص الگو مناسب هستند. رهنما و موسوی (۱۳۸۲) و رضایی و همکاران (۱۳۸۶) برتری استفاده از شبکه عصبی را بر رگرسیون خطی به منظور برآورد دبی پیک نشان دادند. همچنین دستورانی (۱۳۸۵) کارایی شبکه‌های عصبی مصنوعی را در چند زمینه مرتبط با رواناب و بارش ارزیابی نموده و بر تواناییهای این تکنیک در برآورد رواناب در حوضه‌های فاقد آمار، پیش‌بینی بهنگام سیل، بازسازی داده‌های هیدرولوژیکی و نیز بهینه‌سازی نتایج مدل‌های هیدرودینامیکی توسط این تکنیک مورد تاکید قرار دادند.

¹ Artificial Neural Networks (ANN)

² Smith and Eli

³ Hsu et al.,

⁴ Dawson and Wilby

⁵ Tokar and Johnson

⁶ Tokar and Markus

⁷ Zhang and Govindaraju

⁸ Cannon and Whitfield

⁹ Shamseldin

با وجود این که شبکه عصبی مصنوعی غیر خطی بودن فرایند بارش-رواناب را در نظر میگیرد اما متعلق به مدل‌های جعبه سیاه بوده و نقاط ضعف این مدل‌ها با خود دارد (گاتمن و همکاران، ۲۰۰۰). ترکیب یک شبکه عصبی معمولاً از یک متغیر ورودی که شامل متغیرهای اقلیمی مانند بارندگی، تبخیر و تعرق، دما و ذوب برف است تشکیل شده و می‌توان به آن متغیرهای فیزیوگرافیک حوضه مانند توپوگرافی، پوشش گیاهی، رطوبت پیشین خاک را افزود. در این حالت خروجی مدل معمولاً شامل رواناب است. با این حال میتوان متغیرهای ورودی و خروجی را با در نظر گرفتن تاخیر زمانی بین آنها نیز وارد مدل شبکه عصبی کرد.

داسون و ویلیبی (۱۹۹۸) به منظور پیش بینی دبی جریان در رودخانه مول (Mole) دربالا دست رودخانه تایمز در انگلستان از بارندگی ۱۵ دقیقه به منظور ساختن رابطه بارندگی- رواناب از مدل شبکه عصبی استفاده کردند. آنها از دو مدل MLP^2 و RBF^3 برای این منظور استفاده کردند. هدف از این مطالعه ایجاد شبکه عصبی است که بتواند رواناب را فقط با استفاده از بارندگی در حوضه آبریز پلاسجان که مهمترین و بزرگترین زیر حوضه زاینده رود است به درستی برآورد کند.

مواد و روش‌ها

منطقه مورد مطالعه

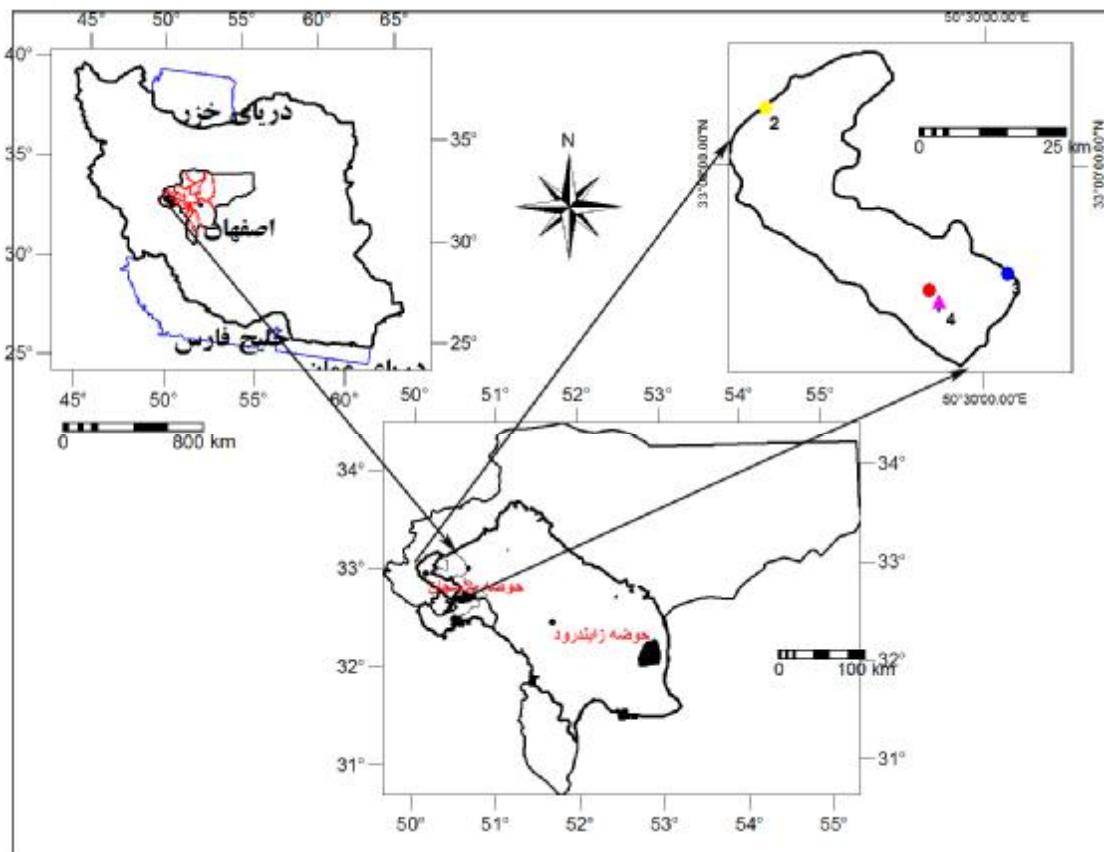
حوضه آبریز زاینده رود مهمترین، بزرگترین و پرآب ترین رودخانه در حوضه آبریز فلات مرکزی ایران به شمار می آید که از دامنه‌های شرقی ارتفاعات زاگرس میانی سرچشمه گرفته و در جهت عمومی شرق به غرب جریان می یابد. رودخانه از تلاقی چندین شاخه بزرگ و پرآب به نامهای کوه‌رنگ، چم رود، دره زری، دره غازی، دره خوربه و دره دولت آباد تشکیل می گردد. قسمت عمده آبدهی رودخانه را تامین می کند. از محل سد زاینده رود به سمت پایین دست زاینده رود آب قابل توجهی دریافت نکرده بلکه بخشی از آب نیز در اراضی وسیع موجود که در دره رودخانه یا بستر سیلابی آن واقع شده اند برای آبیاری به مصرف می رسد و بخشی از بالادست حوضه آبخیز زاینده رود است. اهمیت این حوضه از این موضوع ناشی می شود که مستقیماً به سد زاینده رود وارد می شود که منبع اصلی تامین منابع آب کشاورزی، شرب و صنعت در منطقه و استان اصفهان است و ارائه مدلی که نوسانات و تغییرات دبی رودخانه پلاسجان را مدل سازی یا پیش بینی کند حائز اهمیت است.

¹ Gautman et al.,

² Multilayer Perceptron

³ Radial Basis Function

از آن جا که هدف از این مطالعه ایجاد یک شبکه عصبی به منظور بررسی رابطه بارندگی رواناب در حوضه آبریز پلاسجان است، بارندگی و دبی روزانه ایستگاه بارندگی و هیدرومتری پلاسجان در دوره آماری ۱۳۵۵-۱۳۷۶ جمع آوری گردید. همچنین به منظور در نظر گرفتن بارندگی منطقه ای و تاثیر آن بر رواناب حوضه پلاسجان، بارندگی ۲ ایستگاه رزوه و ازناوله در دوره مورد نظر نیز جمع آوری گردید (شکل ۱).




شکل ۱- موقعیت آبریز زاینده رود در استان اصفهان و موقعیت حوضه آبخیز پلاسجان به همراه ایستگاه‌های بارندگی (دوایر توپر، ۱- ایستگاه اسکندری، ۲- ایستگاه ازناوله، ۳- ایستگاه رزوه) و ۴- ایستگاه هیدرومتری اسکندری (مثلث)

شبکه عصبی

با توجه به بررسی منابع انجام شده و ماهیت رابطه بارندگی- رواناب که از یک رابطه غیر خطی پیروی می کند، در این مطالعه از شبکه عصبی پرسپترون چند لایه^۱ که نوعی از توپولوژی پیشخور^۱ است (شکل ۲). در اغلب شبکه‌ها، لایه ورودی متغیرهای ورودی را دریافت می کند.

^۱ Multilayer Perceptron

این متغیرها شامل تمام مقادیری است که می تواند متغیر خروجی را تحت تاثیر قرار دهد. بنابراین لایه ورودی کاملا مشخص بوده و اطلاعات لازم برای شبکه را فراهم می کند. لایه آخر یا لایه خروجی نیز شامل متغیری است که شبکه آن را پیش بینی می کند و در واقع خروجی مدل است. تعداد لایه های شبکه یا لایه های مخفی و تعداد نورون های وجود در هر لایه از طریق روش سعی و خطا بدست می آید. نورون های موجود در هر لایه با تمام نورون های لایه های قبل و بعد از خود در ارتباط هستند. بین ۹۰ تا ۹۵ درصد کاربرد شبکه های عصبی امروزی از این توپولوژی استفاده می کنند (نجفی و همکاران، ۱۳۸۵؛ ASCE^۲، a,b، ۲۰۰۰، هارفام و داسون^۳، ۲۰۰۵). در این روش ابتدا به وزن های سیناپسی مقادیر تصادفی داده می شود، اطلاعات مربوط به نمونه ها به صورت الگو به الگو و یا به صورت دسته ای به شبکه داده می شود، این اطلاعات در وزن های سیناپسی ضرب شده، از تابع تحریک^۴ عبور کرده و نتیجه (خروجی لایه مذکور) ورودی نرون لایه های بعدی را تشکیل می دهد. در نهایت شبکه یک پاسخ در لایه خروجی خواهد داشت که با مقادیر واقعی متفاوت است. برای کاهش این خطا از روش توزیع معکوس خطا^۵ (پس انتشار) استفاده می شود. در این روش وزن ها به تدریج طوری تغییر می کند که خطی پیش بینی به صفر نزدیک شود.



شکل ۲- یک شبکه عصبی پیش رو ۳ لایه (ASCE، a، ۲۰۰۰)

¹ Feed Forward
² American society of Civil engineers
³ Harpham and Dawson
⁴ Activation Function
⁵ Backpropagation

این عمل تا جایی ادامه پیدا می کند که خطای پیش بینی در حد مطلوب باقی بماند و با ورود اطلاعات جدید به شبکه مقدار خطا بایستی در حد مطلوب باقی بماند. بنابراین طراحی یک شبکه عبارت است تعیین تعداد لایه‌های مناسب، تعداد مناسب نرون‌ها در هر لایه و نوع تابع تحریک در هر لایه به نحوی که خطای آموزش و آزمایش شبکه به حداقل برسد.

انتخاب داده‌ها

انتخاب داده‌ها اولین گام در ساختن شبکه عصبی مناسب به منظور برآورد رابطه بارندگی-رواناب است. به طور کلی دو نوع داده را میتوان به عنوان داده‌های ورودی به شبکه عصبی مورد استفاده قرار داد که شامل داده‌های صرفاً آماری که مربوط به مشاهدات بارندگی در طول زمان با درجه تفکیک مشخص مانند داده‌های ساعتی، روزانه یا ماهانه است. نوع دوم داده‌های ورودی شامل نوع اول بعلاوه داده‌های فیزیکی حوضه آبخیز است که در رابطه بارندگی-رواناب نقش دارند مانند رطوبت خاک، ضریب نفوذ پذیری، تبخیر تعرق، آب زیرزمینی و ... هستند (چن و آدامز، ۲۰۰۵؛ احمد و سیمونویچ^۱، ۲۰۰۵). در این تحقیق، از داده‌های نوع اول استفاده می شود. سری زمانی روزانه بارندگی سه ایستگاه باندگی منطقه و دبی روزانه ایستگاه پلاسجان در دوره آماری ۱۳۵۵-۱۳۷۶ جمع آوری گردید.

مقایسه آماری

به منظور مقایسه نتایج حاصل از هر شبکه عصبی با مقادیر واقعی در مرحله اعتبار سنجی^۲ و مقایسه شبکه‌های مختلف و انتخاب بهترین مدل، از مقادیر آستانه ای^۳ استفاده می شود. ضریب همبستگی بین مقادیر مشاهده ای و برآوردی رایج ترین شاخص مقایسه ای است. با این وجود ضریب همبستگی یک شاخص کلی بوده و نمیتواند شاخص مناسبی باشد (خان و کولیبالی^۴، ۲۰۰۶). بنابراین در این تحقیق علاوه بر ضریب همبستگی، ۲ شاخص دیگر مورد استفاده قرار می گیرند (داسون و ویلی، ۱۹۹۸):

۱- ضریب همبستگی

رابطه ضریب همبستگی بین مقادیر مشاهده ای و برآورد شده به صورت زیر است:

$$R^2 = \frac{\sum_{i=1}^N (Q_{Ci} - \bar{Q})^2}{\sum_{i=1}^N (Q_{Oi} - \bar{Q})^2} \quad (1)$$

¹ Ahmad and Simonovic

² Validation

³ Criteria

⁴ Khan and Coulibaly

۲- میانگین مربعات خطا

میانگین مربعات خطا یک شاخص جهانی محسوب می شود که در اغلب مطالعات هیدرولوژیک از آن استفاده می شود (کومار و همکاران، ۲۰۰۵). این ضریب به صورت زیر نوشته می شود:

$$RMSE = \left[\frac{\sum_{i=1}^n (Q_{Ci} - Q_{Oi})}{n} \right] \quad (2)$$

۳- ضریب کارائی مدل^۱

این ضریب به صورت زیر نوشته می شود:

$$CE = 1 - \frac{\sum_{i=1}^N (Q_{Ci} - Q_{Ci})^2}{\sum_{i=1}^N (Q_{Oi} - \bar{Q})^2} \quad (3)$$

در اینجا Q_O مقادیر مشاهده شده و Q_C مقادیر دبی بدست آمده از شبکه و \bar{Q} متوسط دبی مشاهده شده و N تعداد مشاهدات است.

نتایج

انتخاب داده‌های ورودی و ایجاد شبکه

در گام نخست مقادیر بارندگی و دبی روزانه ایستگاه‌های مورد بررسی به عنوان ورودی و خروجی به مدل MLP وارد شبکه شدند. در این مرحله سه نوع ورودی پس از مرتب کردن به صورت تصادفی^۲ به شبکه به شرح زیر مورد آزمون قرار گرفت:

- بارندگی ایستگاه پلاسجان
- بارندگی ایستگاه ازناوله و ایستگاه پلاسجان
- بارندگی ایستگاه رزوه و ایستگاه پلاسجان

در این مرحله هیچکدام از شبکه‌های فوق در مرحله آزمایش و اعتبار سنجی شرایط لازم را را کسب نکردند. مهمترین عامل این موضوع واریانس شدید مقادیر بارندگی با وجود روزهای بدون بارندگی (بارندگی صفر) زیاد است. در این حالت بهتر است سری‌های مشاهداتی را تعدیل کرد. در این تحقیق از روش نرمال کردن داده‌های و محاسبه مقدار Z استفاده می شود.

¹ Coefficient of Efficiency

² Randomize

$$Z = \frac{X_i - \bar{X}}{\sigma} \quad (8)$$

که در آن X_i مقدار مشاهده i ام، \bar{X} میانگین سری و σ واریانس سری مشاهداتی است. پس از نرمال کردن داده‌ها، شبکه عصبی MLP با استفاده از متغیرهای ورودی فوق مجدداً تشکیل گردید. با وجودیکه نتایج حاصل از شبکه‌های ایجاد شده با مقادیر نرمال بهتر از شبکه‌های اصلی بود، شبکه‌های بدست آمده فاقد اعتبار لازم هستند. به همین دلیل لازم است تغییراتی در نوع مقادیر ورودی به شبکه داده شود. به منظور ایجاد شبکه نیز از نرم افزار Neurosolutions استفاده شد.

یکی از راه حل‌های مناسب استفاده از مشاهدات هیدرولوژیکی در زمان تاخیرهای مختلف است. سری‌های زمانی هیدرولوژیکی به ویژه سری‌های روزانه دارای خود همبستگی^۱ هستند. به عبارت دیگر مقادیر دبی یا بارندگی در زمان t به زمان $t-1$ بستگی دارد. توابع خود همبستگی سری‌های مشاهداتی در شکل ۳ نشان داده شده است. از طرف دیگر، رابطه بارندگی-رواناب در طول زمان تغییر می کند که این رابطه را می توان با استفاده از تابع همبستگی عرضی^۲ نشان داد. به این ترتیب با توجه به بررسی توابع خود همبستگی و همبستگی عرضی بین بارندگی و رواناب متغیرهای ورودی جدیدی به شرح زیر مورد استفاده قرار می گیرند:

- ۱- مقادیر نرمال بارندگی ایستگاه اسکندری با تاخیر^۳ ۱ روز: R^1_{t-1}
- ۲- مقادیر نرمال بارندگی ایستگاه اسکندری با تاخیر ۲ روز: R^1_{t-2}
- ۳- مقادیر نرمال بارندگی ایستگاه رزوه با تاخیر ۱ روز: R^2_{t-1}
- ۴- مقادیر نرمال بارندگی ایستگاه ازناوله با تاخیر ۲ روز: R^3_{t-2}
- ۵- دبی نرمال ایستگاه اسکندری با تاخیر ۱ روز: Q_{t-1}
- ۶- دبی نرمال ایستگاه اسکندری با تاخیر ۲ روز: Q_{t-2}

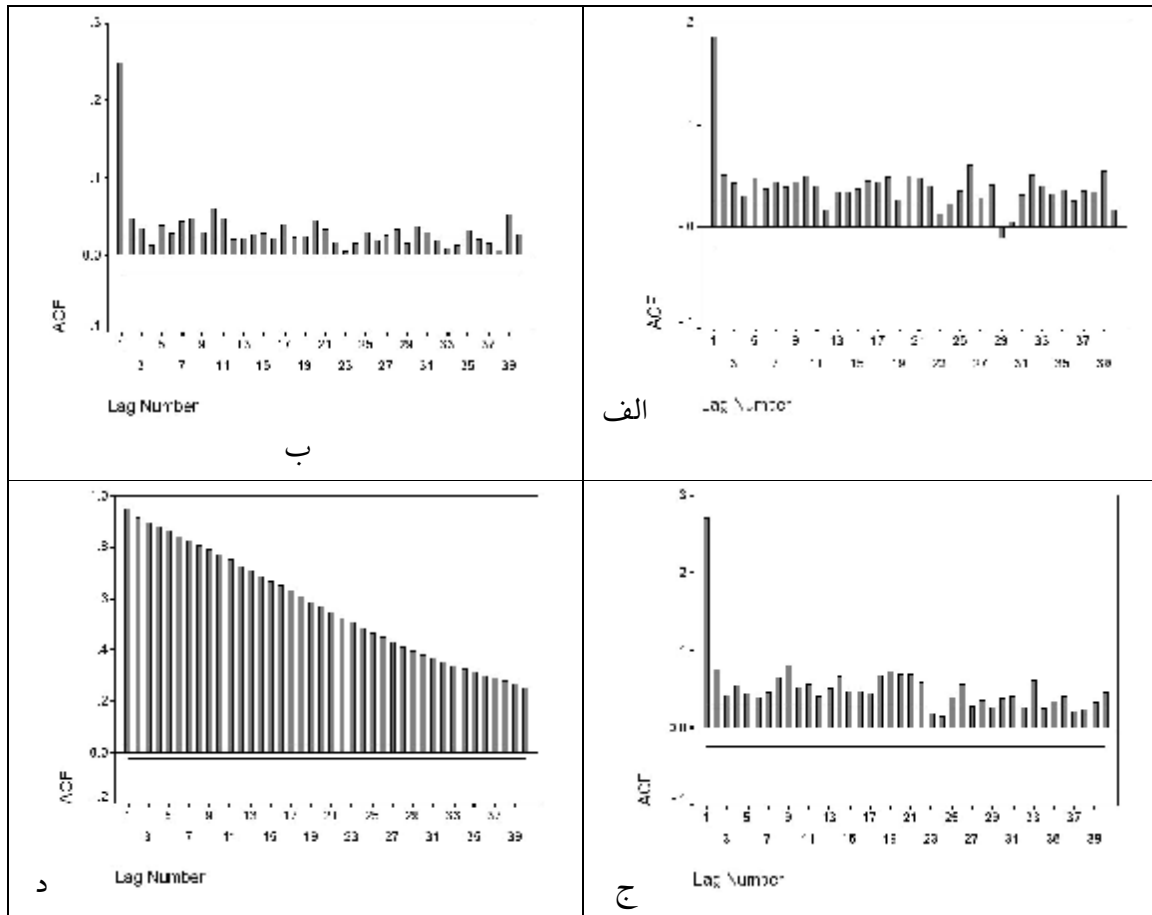
متغیر خروجی تمام شبکه‌های مورد بررسی دبی نرمال شده ایستگاه هیدرومتری اسکندری (Q_t) می باشد. پس از سعی و خطای فراوان در انتخاب تعداد لایه‌ها و تعداد نرون‌ها در هر لایه و همچنین انتخاب تابع تانژانت هیپربولیک به عنوان تابع فعال سازی، ۵ شبکه با تعداد لایه‌های مختلف بررسی و نتایج حاصل از آموزش و آزمایش شبکه بدست آمد که در جدول ۱ نشان داده شده اند. لازم به ذکر است که شبکه MLP با یک لایه مخفی جواب قابل قبولی ارائه نمی کند. دلیل این امر می تواند به پیچیده بودن و غیر

¹ Autocorrelation Function (ACF)

² Cross Correlation Function (CCF)

³ Lag^۱

خطی بودن زیاد رابطه رواناب - بارندگی در حوضه مورد مطالعه یا وجود عوامل فیزیکی باشد که در ساختن شبکه عصبی در این مطالعه وجود ندارد.

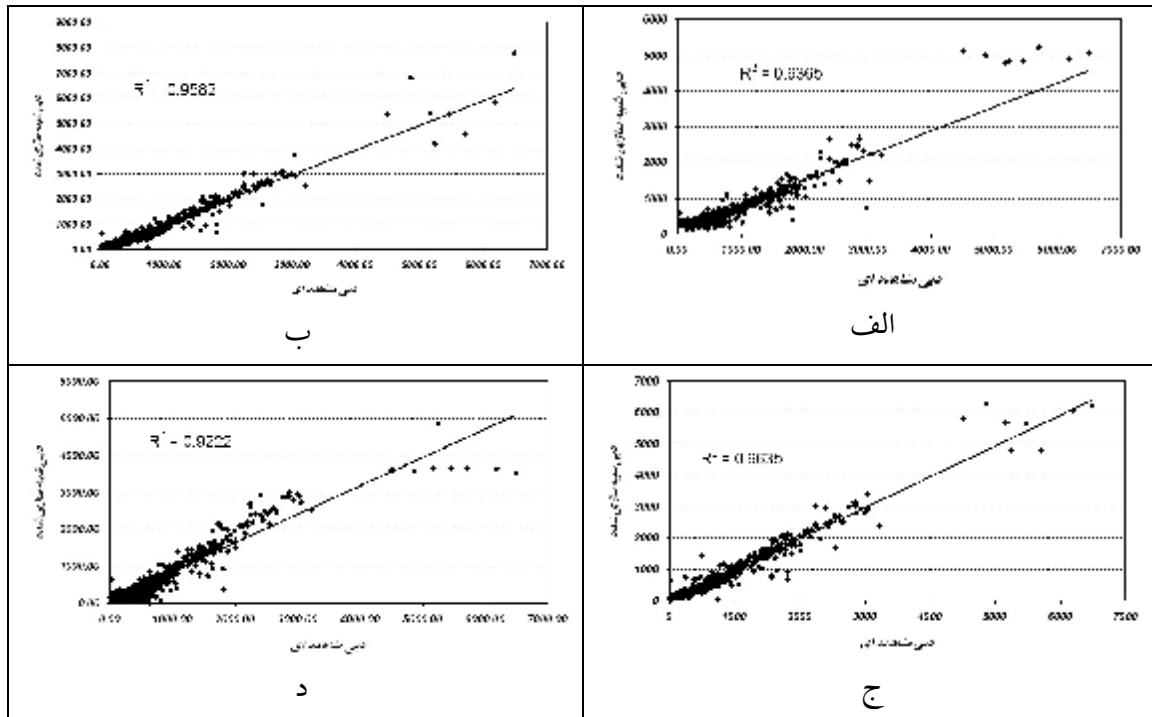


شکل ۳- تابع خود همبستگی بارندگی ایستگاه اسکندری (الف)، ازناوله (ب)، رزوه (ج) و دبی ایستگاه اسکندری (د)

جدول ۱- مشخصات شبکه‌های عصبی منتخب و مقادیر ضریب همبستگی آنها برای دوره آموزش و آزمایش

تعداد لایه‌های مخفی	تعداد نرون‌ها در هر لایه	تابع تحریک	ضریب همبستگی (R^2) مرحله آموزش	ضریب همبستگی (R^2) مرحله آزمایش
۲	۵۰	تانژانت هیپربولیک	۰/۹۵۵۸	۰/۹۳۶۵
۳	۵۰	تانژانت هیپربولیک	۰/۹۶۷۲	۰/۹۵۸۲
۴	۵۰	تانژانت هیپربولیک	۰/۹۷۲۹	۰/۹۶۳۵
۵	۵۰	تانژانت هیپربولیک	۰/۹۳۰۰	۰/۹۲۲۲
۶	۵۰	تانژانت هیپربولیک	۰/۹۷۳۸	۰/۹۵۵۴

همانطور که جدول ۱ نشان می دهد شبکه عصبی با ۴ لایه مخفی بالاترین ضریب همبستگی را در مرحله آزمایش شبکه دارد. بنابراین به عنوان بهترین شبکه انتخاب می شود. شکل ۴ مقادیر دبی مشاهده شده و دبی شبیه سازی شده توسط شبکه های عصبی فوق را نشان می دهد.



شکل ۴- مقایسه مقادیر دبی مشاهده شده و شبیه سازی شده توسط شبکه عصبی ۲ لایه (الف)، ۳ لایه (ب)، ۴ لایه (ج) و ۵ لایه (د)

مقایسه آماری

اعتبار شبکه عصبی در تولید ویژگی های آماری سری مشاهداتی (میانگین، انحراف معیار و تابع توزیع) با استفاده از نرم افزار SPLUS مورد آزمون قرار گرفت. همانطور که جدول ۲ نشان می دهد، شبکه های عصبی با تعداد لایه های مختلف به جز شبکه عصبی با ۴ لایه مخفی مناسب شبیه سازی نیستند.

جدول ۲- مقایسه آماری سری های مشاهداتی و شبیه سازی شده در شبکه های مختلف

MLP6	MLP5	MLP4	MLP3	MLP2	شبکه
					آماره
127.88	201.1	97.15	112.21	247.17	RMSE
0.9554	0.9222	0.9635	0.9582	0.9365	R^2
95.28	88.35	97.3	96.5	82	CE (%)

در نهایت و با توجه به نتایج حاصل از آزمون‌های آماری، شبکه عصبی ۴ لایه پرسپترون برای شبیه‌یازی رابطه بارندگی- رواناب در حوضه ابخیز پلاسجان کارائی بسیار خوبی نسبت به سایر شبکه‌های پرسپرون ایجاد شده دارد.

بحث و نتیجه‌گیری

رابطه بارندگی-رواناب متأثر از پارامترهای اقلیمی و فیزیکی حوضه مانند تغییرات زمانی بارندگ، شیب، ارتفاع، پوشش گیاهی، رطوبت خاک، آب‌های زیرزمینی و ... است. این موضوع باعث شده رابطه بارندگی-رواناب از حالت خطی خارج شده و به یک رابطه غیر خطی پیچیده تبدیل شود. مدل‌های فیزیکی زیادی برای ایجاد این رابطه توسعه پیدا کرده اند اما عدم وجود برخی پارامترهای مورد نیاز و ساده سازی برخی روابط باعث کاهش کارآمدی این مدل‌ها شده است. شبکه‌های عصبی مصنوعی به دلیل قدرت مدل سازی روابط غیر خطی پیچیده و عدم نیاز به پارامترهای زیاد در چند دهه اخیر کاربرد زیادی در بررسی رابطه بارندگی-رواناب پیدا کرده اند. در این تحقیق یک شبکه عصبی پرسپترون با ۴ لایه مخفی به عنوان بهترین شبکه برای تعیین رابطه بارندگی-رواناب حوضه پلاسجان انتخاب شد. مهمترین نکته در این مطالعه انتخاب صحیح داده‌های ورودی به شبکه است به ویژه اینکه سری‌های مورد بررسی دارای واریانس شدیدی هستند. در این رابطه ذکر ۳ نکته حائز اهمیت است.

۱- انتخاب روش مناسب به منظور تبدیل مشاهدات اولیه به مشاهداتی که واریانس کمتری داشته و جواب مناسبی ایجاد کنند بسیار مهم است. به عنوان مثال تبدیل نرمال در تحقیق به یافتن شبکه عصبی مناسب کمک شایان توجهی کرد به طوریکه ایجاد شبکه مناسب با داده‌های اولیه بارندگی که دارای مقادیر زیادی صفر بودند در عمل غیر ممکن گردید.

۲- نکته قابل ذکر دیگر تاثیر بارندگی منطقه ای بر دبی خروجی از ایستگاه پلاسجان است به طوریکه با در نظر گرفتن تنها یک ایستگاه بارندگی به عنوان ورودی، شبکه عصبی مناسبی تشکیل نشد. لذا از دو ایستگاه دیگر منطقه به منظور ورودی به شبکه کمک گرفته شد که جواب مثبتی در پی داشت. این موضوع را می توان به رطوبت خاک و نفوذ اولیه در سرتاسر حوضه و تاثیر آن بر رواناب ایستگاه خروجی حوضه مرتبط دانست. لذا در نظر گرفتن فقط یک ایستگاه بارندگی در توسعه شبکه عصبی برندگی-رواناب توصیه نمی شود.

۳- سری‌های زمانی هیدرولوژیک به ویژه سری‌های روزانه بارندگی و رواناب دارای خود همبستگی مثبت هستند. به عبارت دیگر روانابی که در یک روز ثبت می شود به رواناب روز قبل بستگی دارد. همچنین این رواناب به بارندگی روز قبل و روزهای قبل از (از طریق رطوبت خاک یا آب‌های زیرزمینی)

بستگی دارد. لذا در نظر گرفتن بارندگی و رواناب در روزهای قبل در ایجاد یک شبکه مناسب حائز اهمیت است. در این تحقیق تابع خود همبستگی بارندگی و رواناب و همبستگی عرضی بین آنها مورد بررسی قرار گرفت و بارندگی و رواناب روزهای قبل نیز به عنوان ورودی به شبکه ورد استفاده قرار گرفت. این متغیرها در بالا بردن اعتبار شبکه ایجاد شده نقش به سزایی داشتند.

در نهایت با توجه به نتایج این تحقیق پیشنهاد می شود اعتبار شبکه های عصبی مورد استفاده در شبیه سازی رابطه بارندگی رواناب از طریق آماری نیز مورد آزمون قرار گیرد. همچنین استفاده از سایر پارامترهای فیزیکی حوزه مانند پارامترهای ژئومورفولوژیک مانند شیب، مساحت، طول رودخانه و سایر پارامترها مانند رطوبت و پوشش گیاهی در مدل های شبکه عصبی توصیه می شود.

تقدیر و تشکر

بدینوسیله از حوزه معاونت پژوهشی دانشگاه آزاد اسلامی واحد اردستان، در اجرای طرح پژوهشی مصوب دانشگاه تحت عنوان "تعیین رابطه رواناب- بارش در حوزه آبخیز زاینده رود با استفاده از شبکه های عصبی به منظور پیش بینی رواناب" قدردانی می شود

منابع

- دستورانی، م، ۱۳۸۵، روش شبکه های عصبی مصنوعی در مدلسازی جریانهای رودخانه ای (تحلیل تواناییها و نقطه ضعفها)، هفتمین کنفرانس بین المللی مهندسی رودخانه، اهواز ۱۳۸۵.

- رهنما، م. ب. و ج. موسوی، ۱۳۸۲. پیش بینی سیلاب حوضه آبریز قره آقاج با استفاه از شبکه عصبی مصنوعی. هشتمین سمینار سراسری ایاری و کاهش تبخیر، دانشگاه شهید باهنر کرمان، صفحه ۶۱۰-۶۲۰

- رضایی، ع. مهدوی، م. لوکس، ک. فیض نیا، س. مهدیان، م. ح. ۱۳۸۶. مدلسازی منطقه ای دبی های اوج در زیر حوضه های آبخیز سد سفید رود با استفاده از شبکه عصبی مصنوعی. مجله علوم و فنون کشاورزی و منابع طبیعی، ۴۰، ۲۵-۳۹

- نجفی، ن. حیدر پور، م و کیخائی، م. ۱۳۸۵. بررسی کارائی شبکه عصبی مصنوعی در شبیه سازی بارش و رواناب. اولین همایش منطقه ای بهره برداری بهینه از منابع آب حوضه های کارون و زاینده رود، شهرکرد، ۱۴-۱۵ شهریور

- Ahmad, S., Simonovic, S. P., 2005. An artificial neural network model for generating hydrograph from hydro-meteorological parameters. J. Hydrol, 315, 236-251

- ASCE Task Committee on application of Artificial Neural Networks in Hydrology, 2000. Artificial neural networks in hydrology. I: preliminary concepts. J. Hydr. Eng. 5(2), 115-123.

- ASCE Task Committee on application of Artificial Neural Networks in Hydrology, 2000. Artificial neural networks in hydrology. II: hydrologic applications. J. Hydr. Eng. 5(2), 124-137.

- Cannon, AJ, Whitfield, PH, 2002. Downscaling recent streamflow conditions in British Colombia, Canada using ensemble neural networks. *J. Hydrol.*, 259, 136-151.
- Chen, J, Adams, BI, 2006. Integration of artificial neural networks with conceptual models in rainfall-runoff modeling. *J. Hydrol.*, 318, 232-249
- Dawson, CW, Wilby, R. 1998. An artificial neural network approach for rainfall-runoff modeling. *Hydr. Sci. J.*, 43, 47-66
- Harpham, C., Dawson, C. W., 2005. The effect of different basis functions on a radial basis function network for time series prediction: A comparative study. *Neurocomputing*, 69, 2161-2170
- Gautman, MR, Watanabe, K, Saegusa, H, 2000. Runoff analysis in humid forest catchment with artificial neural network. *J. Hydrol.*, 235, 117-136
- Hsu, KL, Gupta, HV, Sorooshian, S. 1995. Artificial Neural Network modeling of rainfall-runoff modeling. *Water Resour. Res.*, 31, 2517-2530.
- Khan, S. M., Coulibaly, P., and Dibike, Y., 2006. Uncertainty analysis of statistical downscaling methods. *J. hydrol.*, 319, 357-382
- O'connor, MK, 1997. Applied hydrology I-deterministic. Unpublished lecture note. Department of engineering hydrology, National university of Ireland, Galway.
- Shamseldin, AY, 1997. Application of a neural network technique to rainfall-runoff modeling. *J. Hydrol.*, 240, 45-61.
- Smith, J, Eli, RB, neural Network models of rainfall-runoff process. *J. Water Resour. Plng. Mgmt.*, 4, 232-239.
- Tokar, AS, Markus, M, 2000. Precipitation-runoff modeling using artificial neural networks and conceptual models. *J. Hydr. Eng.*, 5, 156-161.
- Tokar, AS, Johnson, PA, 1999. Rainfall-runoff modeling using artificial neural networks. *J. Hydr. Eng.*, 4, 232-239.
- Zhang, B. Govindaraju, RS, 2003. Geomorphology-based artificial neural networks for estimation of direct runoff over watersheds. *J. Hydrol.*, 273, 18-34.

Application of Artificial Neural Network for runoff estimation **Case study: Plajan Basin-Zayandehrud Watershed**

Abstract

Runoff estimation is an important part of water resources management of watersheds. Although a lot of physical and statistical methods are available which apply different watershed parameters, the black box artificial neural networks are more suitable methods. In this study, a multilayer perceptron network is applied for estimation of daily runoff from daily rainfall of Plasjan Basin. At first, daily rainfall series of 3 stations and daily discharge of Plasjan station were normalized and according to autocorrelation and cross correlation of rainfall-runoff data, 6 variables were selected as input of the network and a 4-hidden-layer network was found to be more valid comparing with other networks.

Keywords: runoff, Multilayer Perceptron network, Validation, autocorrelation, Plasjan Basin