



شبکه‌های عصبی زمان تاخیری ضمن داشتن انعطاف پذیری بسیار بالا، بخوبی توانایی شبیه‌سازی عکس‌العمل حوزه آبخیز نسبت به ورودی‌ها از جمله بارش و دما را دارند. واژگان کلیدی: شبکه‌های عصبی زمان تاخیری، پرسپترون چند لایه، آنالیز حساسیت، حوزه آبخیز زاینده رود

مقدمه

بیشتر فرآیندهای آب‌شناختی دارای درجه بالایی از تغییرات زمانی و مکانی هستند که تا حدودی مربوط به غیر خطی بودن فرآیندهای فیزیکی، تضاد مقیاس‌های زمانی و مکانی و عدم صحت در برآورد عامل می‌باشد. بنابراین تحفین آب‌شناختی تلاش می‌کند تا پاسخ‌های منطقی را برای مسائل فراهم نماید تا در طراحی و مدیریت منابع آب از آنها استفاده نمایند. از جمله مهم‌ترین چالش‌ها در مدیریت منابع آب و مدیریت حوزه‌های آبخیز، برآورد رواناب خروجی از حوزه‌های آبخیز می‌باشد. این مسئله با توجه به عدم وجود ایستگاه‌های آب‌سنجی در بعضی از زیر حوزه‌ها به دلیل موقعیت توپوگرافیک، جنبه‌های اقتصادی و مشکلات مربوط به نگهداری ادوات ایستگاه‌ها تشدید می‌گردد. برای حل این معضل روش‌های زیادی در برآورد رواناب مانند روش‌های آماری و ریاضی، روش‌های مبتنی بر وضعیت فیزیوگرافی و عامل‌های اقلیمی و روش‌های مبتنی بر داده‌ها ارائه شده است. این روش‌ها هر کدام مزایا و معایب خاص خود را دارند و در صورت استفاده در شرایط متفاوت باید واسنجی شده و یا به عبارتی با شرایط منطقه وفق داده شوند. از جمله این روش‌ها، روش شبکه‌های عصبی^۵ (محاسبات نرونی) است [۱۱] ASCE-I. شبکه‌های عصبی جزء نظام‌های هوشمند مدل آزاد^۶ می‌باشند که با پردازش روی داده‌های تجربی، دانش یا قانون نهفته در داده‌ها رابه ساختار شبکه منتقل می‌کنند و بر اساس محاسبات روی داده‌های عددی یا مثال‌ها، قوانین کلی را فرا می‌گیرند مهنج [۹].

روش‌های فن هوش مصنوعی مانند شبکه‌های عصبی اغلب در تکمیل داده‌های غیر قابل اندازه‌گیری یا فقدان آنها در مدیریت منابع آب به دلایل مختلف بکار می‌روند توران و یوردسف [۳۱]. پژوهش‌های زیادی در خصوص استفاده از شبکه‌های عصبی مصنوعی در آب‌شناختی و منابع آب در زمینه‌های پیشبینی سطح

بررسی کارایی شبکه‌های عصبی پرسپترون چند لایه و زمان تاخیری در برآورد جریان‌های سطحی حوزه آبخیز زاینده رود

محمدرضا یزدانی^۱، جواد خوشحال دستجردی^۲، محمد مهدوی^۳ و سعید سلطانی^۴
تاریخ دریافت: ۸۹/۰۵/۰۴ تاریخ پذیرش: ۹۰/۰۹/۱۰

چکیده

رواناب نقش مهمی در مدیریت حوزه‌های آبخیز ایفا می‌کند و برنامه‌ریزی و ایجاد زمینه مناسب برای بهبود وضعیت حوزه‌های آبخیز بستگی زیادی به آن دارد. از طرفی تخمین رواناب در حوزه‌های آبخیز اهمیت زیادی در مطالعات منابع آب، تعیین و طراحی سازه‌های کنترل سیل دارد. با توجه به قابلیت شبکه‌های عصبی مصنوعی در تخمین رواناب، کم هزینه بودن، انعطاف پذیری و اهمیتی که حوزه‌ی آبخیز سد زاینده‌رود در تامین آب مورد نیاز شهری، کشاورزی و صنعتی ایفا می‌کند، کارایی شبکه‌های عصبی در تخمین رواناب ماهانه زیرحوضه‌های بالا دست سد زاینده رود مورد بررسی قرار گرفت. در این تحقیق دو نوع مدل شبکه عصبی پرسپترون چند لایه (MLP) و مدل شبکه عصبی زمان تاخیری (TLNN) در زیرحوضه‌های پلاسجان، سمندگان و زاینده رود مورد بررسی قرار گرفت. نتایج بیانگر این بود که مدل TLNN علیرغم حساسیت زیاد در مرحله آموزش، از کارایی خوبی در تخمین رواناب برخوردار بوده و نسبت به مدل MLP از خطای کمتری برخوردار است. بطوری که این شبکه‌ها با استفاده از ورودی‌هایی شامل ۳ تا ۴ ایستگاه باران‌سنجی و ۲ تا ۳ ایستگاه دماسنجی با آموزش مناسب می‌توانند بخوبی رواناب ماهانه را تخمین بزنند. میانگین خطای مطلق پیش‌بینی در مرحله تست برای سه ایستگاه اسکندری، مندرجان و قلعه شاهرخ با استفاده از روش TLNN به ترتیب برابر ۰/۵، ۰/۳۱ و ۰/۲۷ و همچنین در روش MLP نیز به ترتیب ۰/۵، ۰/۳۳ و ۰/۴۵ بود.

۱ - استادیار گروه مدیریت مناطق خشک و بیابانی، دانشکده کویرشناسی دانشگاه سمنان، پست الکترونیکی: m_yazdani@sun.semnan.ac.ir

۲ - دانشیار گروه اقلیم شناسی دانشگاه اصفهان

۳ - استاد دانشکده منابع طبیعی دانشگاه تهران

۴ - دانشیار دانشکده منابع طبیعی دانشگاه صنعتی اصفهان

[۲۸] برای شبیه‌سازی جریان‌های حداقل و حداکثر روزانه در اقالیم مختلف در حوزه مزوجرا در مرکز یونان از یک مدل شبکه عصبی پیش رونده سه لایه استفاده نموده است. وی نتایج کار خود را با مدل مفهومی رطوبت خاک مقایسه و بیان نموده که در صورت آموزش مناسب با داده‌های طولانی مدت، مدل ایجاد شده قادر است به خوبی جریان‌های مذکور را در اقالیم متغیر شبیه‌سازی نماید و نسبت به مدل مفهومی رطوبت خاک نتایج بهتری داشته است.

دامنگیر [۴] با استفاده از نرم‌افزار MATLAB به تعیین مدل شبکه عصبی مبتنی بر پارادایم RBF در دو مقیاس زمانی روزانه و ساعتی برای رودخانه کر اقدام نمود و به این نتیجه رسید که این شبکه قادر به شبیه‌سازی رفتار آب‌شناختی سامانه حتی در شرایط اوج‌های چندگانه آبنمود خروجی می‌باشد. آریان [۱] مدلی را براساس شبکه‌های عصبی مصنوعی با یک شبکه رو به جلو با الگوریتم پس انتشار جهت بهره‌برداری بهینه از مخزن سد بوکان ارائه نمود. مدل‌های شبکه عصبی مصنوعی، سری زمانی ARIMA و مدل همبستگی آماری برای پیش‌بینی جریان در فصل بهار مخزن سد امیرکبیر مورد ارزیابی قرار گرفته و نتایج حاکی از قابلیت بهتر روش شبکه عصبی مصنوعی نسبت به دیگر روش‌ها بوده است محمدی و دیگران [۲۶]. طارقیان و دیگران [۵] در پژوهشی دبی رودخانه کارون را در محل پل شالو با استفاده از شبکه‌های عصبی مصنوعی پیش‌بینی کرده‌اند. آنها در کار خود از اطلاعات بارش، تبخیر و تعرق و دبی استفاده نمودند. الگوریتم آموزشی مورد استفاده، الگوریتم پس انتشار بود. آنها به این نتیجه رسیدند که این مدل‌ها می‌توانند جریان را با خطای کمی پیش‌بینی کنند. همچنین نتایج مطالعه‌ای دیگر بر رودخانه کارون حاکی از کارایی مناسب شبکه‌های عصبی مصنوعی در برآورد جریان بوده است کریمی و دیگران [۶]. باقری [۲] با استفاده از روش شبکه عصبی MLP یک مدل پیش‌بینی جریان بر اساس بده ماه‌های قبل برای رودخانه کرج و سد امیرکبیر توسعه داده است. این مدل پس از سپری شدن هر بازه یک ماهه بر اساس مقادیر مشاهده شده جریان، به هنگام می‌گردد. رستم افشار و دیگران [۳] در پژوهشی با استفاده از مدل پرسپترون چند لایه میزان جریان را در رودخانه باراندوز چای در غرب دریاچه ارومیه مورد پیش‌بینی قرار دادند. آنها بیان نمودند به علت توانایی این شبکه‌ها در تبیین روابط غیرخطی، این مدل کارایی خوبی در پیش‌بینی جریان داشته است. ضمن اینکه در مرحله آموزش توجه به تعداد تکرار از اهمیت زیادی برخوردار است.

با توجه به قابلیت‌ها و مزیت‌های ذکر شده، عدم کارایی مناسب روش‌های همبستگی خطی در برآورد رواناب، فقدان ایستگاه‌های آب‌سنجی در اکثر حوزه‌های آبخیز کشور و همچنین نقشی که حوزه‌های بالادست در تامین آب سد زاینده‌رود و تامین نیاز آبی بخش‌های مختلف دارند، لازم است تا کارایی مدل‌های مبتنی بر داده (در این پژوهش شبکه‌های عصبی پرسپترون چند لایه و زمان

آب بریت شیدل و دیگران [۱۳]، تولید آبنمود لانگ [۲۴]، سیلاب و سامانه‌های هشدار سیل هال و مینز [۱۹] و استری و دیگران [۲۹]، پیش‌بینی سیلچن و دیگران [۱۴]، کیم و باروس [۲۱] و ناپولیتانو و دیگران [۲۷]، پیش‌بینی زمان واقعی سیل توت و دیگران [۳۰]، پیش‌بینی کوتاه مدت جریان رودخانه زلاند و دیگران [۳۳]، شبیه‌سازی جریان‌های حداقل پانگولیا [۲۸] انجام شده است و استفاده از این مدل‌ها در منابع آب رو به افزون است. دکورت [۱۷] مدل بارش-رواناب را با استفاده از شبکه‌های عصبی مصنوعی در حوزه لیندبرگ مورد ارزیابی قرار داده است. او در کار خود از اطلاعات روزانه بارندگی، تبخیر و تعرق و متوسط درجه حرارت استفاده کرده و بیان نموده است که این مدل‌ها، مدل‌های جعبه سیاه می‌باشند و قادرند میزان خطا را کاهش دهند. مقایسه شبکه‌های عصبی با ساختارهای گوناگون با برخی از روش‌های تجربی برای برآورد رواناب ماهانه در سه حوزه آبخیز در ایالت کانزاس حاکی از دقت بیشتر روش شبکه‌های عصبی بوده است [جاگادیش و دیگران، ۲۰]. باتاچاری [۱۲] روش شبکه عصبی و مدل M5 را در تعیین رابطه دبی-اشل در رودخانه ایندین مورد ارزیابی قرار داده است و مشخص نمود که مدل مذکور قابلیت بهتری در تعیین رابطه دبی-اشل نسبت به منحنی‌های منطقی مرسوم داشته است. بررسی‌ها حاکی از این است که وقتی مشخصه‌های جریان مانند ضریب تغییرات در مدل‌های شبکه عصبی به ویژه ساختار پرسپترون چند لایه برای برآورد رواناب مورد استفاده قرار گیرد، کارایی پیش‌بینی بهتر می‌باشد. همچنین می‌توان در مناطق فاقد ایستگاه با استفاده از مشخصه‌های حوزه آبخیز یا بهره‌گیری از مشخصات بدست آمده از حوزه‌های مجاور دارای ایستگاه آب‌سنجی، برآورد بهتری از رواناب در قیاس با مدل‌های همبستگی چندگانه انجام داد [آدولیه، ۱۰].

دروم و دیگران [۱۶] مدل‌سازی بارش رواناب با استفاده از شبکه‌های عصبی مصنوعی و سامانه‌های استنتاج نروفازی با مدل‌های همبستگی چندگانه مورد بررسی قرار دادند. نتایج حاصل از این بررسی در ۷ ایستگاه اندازه‌گیری جریان در حوزه سسورلک در شبه جزیره آناتولی حاکی از نتایج قابل قبولی برای بیشتر ایستگاه‌ها بود. هرچند این نتایج برای مدل‌های نروفازی بهتر بودند و دبی‌های اوج موجب افزایش خطا در این مدل‌ها می‌شدند. با توجه به محدودیت حافظه کوتاه مدت در برخی از مدل‌های بارش-رواناب، ساختاری از شبکه عصبی در ترکیب با مدل آشفستگی غیرخطی NLPM-ANN مورد بررسی قرار گرفت. در این مدل جدید، اطلاعات فصلی بارش و رطوبت حوزه نیز استفاده شد. این مدل در هشت حوزه آبخیز در چین مورد بررسی قرار گرفت و نتایج قابلیت بهتر این ساختار جدید مدل شبکه عصبی را نشان می‌داد [لی و دیگران، ۲۵]. فرناندو و دیگران [۱۸] در پژوهشی به بررسی کارایی مدل‌های شبکه عصبی در برآورد رواناب ماهانه در حوزه رودخانه جانگادا در برزیل پرداختند. آنها بیان کردند که این شبکه‌ها دارای خطای کم بوده و می‌توانند خروجی مدنظر را (دبی ماهانه) با دقت بالایی برآورد نمایند. پانگولیا



شکل ۱: موقعیت منطقه و حوزه‌های آبخیز مورد مطالعه

روش انجام پژوهش

داده‌های مورد استفاده در این پژوهش با استفاده از آزمون دنباله‌ها مورد بررسی قرار گرفته و همگنی داده‌ها تایید گردید. داده‌های ناقص با استفاده از بالاترین ضریب همبستگی بین ایستگاه‌های ناقص و شاهد (ایستگاه‌های دامنه فریدن، بادیجان و سینگرد) تکمیل گردید [مهدوی، ۸]. و برای استفاده در مدل‌سازی شبکه عصبی استاندارد شدند. با توجه به بررسی‌های انجام شده، دو نوع مدل شبکه‌های پرسپترون چند لایه و مدل شبکه عصبی زمان تاخیری مورد استفاده قرار گرفتند.

شبکه‌های پرسپترون چند لایه: از جمله ساختارهای مهم شبکه‌های عصبی، پرسپترون چند لایه می‌باشد که کاربرد زیادی دارد (شکل ۲) و به خوبی قادر به تقریب توابع دلخواه می‌باشد [کیسی، ۲۲]. در بررسی سامانه‌های پویای غیرخطی و دیگر مسائل تقریب تابع از اهمیت زیادی برخوردار است. به طور معمول پرسپترون‌های چند لایه با الگوریتم پس انتشار آموزش داده می‌شوند. پرسپترون چند لایه با قانون تصحیح خطا آموزش می‌بیند، پس نیاز به خروجی مشخص می‌باشد. از پاسخ سامانه $d_i(n)$ در واحد پردازشگر PEi و تکرار n ، پاسخ مد نظر $d_i(n)$ با توجه به الگوی ورودی داده شده، خطا در هر تکرار $e_i(n)$ به صورت زیر تعریف می‌گردد:

$$e_i(n) = d_i(n) - y_i(n) \quad (1)$$

با توجه به نظریه یادگیری کاهش شیب هر وزن شبکه با توجه به مقادیر موجود وزن و نسبت ورودی به خطا تطبیق پیدا می‌کند:

$$w_{ij}(n+1) = w_{ij}(n) + \eta \partial_i(n) x_j(n) \quad (2)$$

در رابطه فوق خطای موضعی $\partial_i(n)$ می‌تواند به طور مستقیم از $e_i(n)$ در خروجی واحد پردازشگر و یا مجموع وزنی خطاها در بین

تاخیری) مورد ارزیابی قرار گیرد و در صورت مناسب بودن موارد مربوط به برآورد رواناب یا در طرح‌های مشابه مورد استفاده قرار گیرد.

مواد و روش‌ها

محدوده مورد مطالعه

محدوده مورد مطالعه حوزه‌ی آبخیز بالا دست سد زاینده‌رود می‌باشد که تمام آورد رودخانه‌ها و آبراه‌ها را به دریاچه سد تخلیه می‌کند. این حوزه دارای سه زیر حوزه اصلی می‌باشد که عبارتند از حوزه‌ی آبخیز رودخانه زاینده‌رود، حوزه‌ی آبخیز رودخانه پلاسجان و حوزه‌ی آبخیز رودخانه سمنندگان (شکل ۱). مساحت حوزه زاینده‌رود ۱۴۲۷ کیلومترمربع است و جریان در رودخانه اصلی زاینده‌رود در ایستگاه قلعه شاهرخ اندازه‌گیری می‌شود. مساحت حوزه پلاسجان ۱۶۴۲ کیلومترمربع می‌باشد و ایستگاه آب‌سنجی اسکندری در خروجی این حوزه قرار دارد. مساحت حوزه سمنندگان در حدود ۲۲۷ کیلومترمربع بوده و رودخانه سمنندگان واقع در این حوزه مستقیم به دریاچه سد زاینده‌رود می‌ریزد. جریان خروجی این حوزه توسط ایستگاه مندرجان اندازه‌گیری می‌شود [مؤسسه پژوهش‌های برنامه‌ریزی و اقتصاد کشاورزی، ۷].

ایستگاه‌های مورد بررسی: با توجه به بررسی‌های انجام شده و همچنین طول دوره آماری موجود، ایستگاه‌های مناسب در هر زیرحوزه انتخاب شدند. طول دوره آماری در دو زیرحوزه‌ی زاینده‌رود و پلاسجان ۲۹ سال و از سال ۱۳۵۳ تا ۱۳۸۲ و در زیرحوزه‌ی سمنندگان با توجه به طول دوره ایستگاه آب‌سنجی مندرجان ۲۴ سال از ۱۳۵۸ تا ۱۳۸۲ انتخاب گردید و بر اساس این دوره آماری، سایر ایستگاه‌های باران‌سنجی و دماسنجی انتخاب شدند.


واحدهای پردازشگر محاسبه گردد. ثابت η مبین اندازه گام می باشد. این روش الگوریتم پس انتشار نامیده می شود. شبکه های عصبی برگشتی: گروهی از شبکه های عصبی هستند که شامل حلقه ها یا اتصالات پس خور می باشند. در حالی که دست های از توپولوژی های شبکه رو به جلو دارای محدودیت می باشند، این شبکه ها هر ساختار اختیاری در هر گره شبکه را می پذیرد و می توانند با هر گره دیگر حتی با خودشان مرتبط باشند (شکل ۳). شبکه های عصبی زمان تاخیری در واقع پرسپترون های چند لایه ای هستند که دارای ساختار حافظه کوتاه مدت هستند [کولیبازی و دیگران، ۱۵] و [کومار و دیگران، ۲۳]. بیشتر داده های واقعی دارای اطلاعاتی در ساختار خود هستند که وابسته به زمان می باشد. از جمله ساختارهای مهم شبکه های عصبی برگشتی زمان تاخیری مدل گاما می باشد. سیگنال حاصل از حافظه گاما را می توان بصورت زیر بیان نمود:

$$x_o(n) = u(n) \quad (3)$$

$K, \dots, 2, 1, k$ $x_k(n) = (1 - \mu)(x_k(n-1)) + \mu x_{k-1}(n-1)$ (۴) باید در نظر داشت که سیگنال در نقطه k ، نسخه اصلاح شده ورودی است که در برگزیده ولتاژ وقایع گذشته است و حافظه ای را به وجود می آورد.

برای هر اجرا، تحلیل حساسیت داده ها، تغییر در ورودی ها، تغییر در تعداد لایه های مخفی، تغییر در تعداد واحدهای پردازشگر، تعداد تکرار و تعداد نمونه های آموزشی با استفاده از ملاک های خطایی مورد ارزیابی قرار گرفتند و هر ساختار با ساختار دیگر مقایسه و بهترین ساختار و مدل ایجاد شده با استفاده از روش سعی و خطا تعیین گردید. در تحلیل خطاها و به منظور بررسی کارایی مدل های توسعه داده شده از روش های میانگین مربع خطا، میانگین مربع خطای نرمال شده میانگین خطای مطلق و ضریب همبستگی استفاده شد.

نتایج




شکل ۳: ساختار کلی شبکه های عصبی زمان تاخیری (TLNN)

در حوزه ی آبخیز پلاسجان ورودی های اولیه مدل شامل ۷ ایستگاه باران سنجی (ماهانه) و ۵ ایستگاه دماسنج (ماهانه) و خروجی مدل جریان متوسط ماهانه ایستگاه اسکندری بودند. ۲۴۰ نمونه برای مرحله آموزش، ۸۴ نمونه برای تست انتخاب گردید. به منظور کاهش تعداد ورودی ها و افزایش توان همگرایی شبکه تحلیل حساسیت خروجی نسبت به ورودی ها در MLP انجام گرفت و سپس این تحلیل بر روی نمونه های منتخب نیز انجام گرفت. در شکل (۴) نتایج این تحلیل ارائه شده است. با توجه به نتایج بدست آمده تاثیر ورودی های $P_1, P_2, P_3, P_4, P_5, T_1, T_2, T_3$ بر خروجی بیشتر از سایر ورودی های منتخب است. لذا در اجرای مدل این ورودی ها انتخاب شدند. این تحلیل در روش TLNN نیز انجام گرفت که با توجه به نتایج بدست آمده تاثیر ورودی های $P_1, P_2, P_3, P_4, P_5, T_1, T_2, T_3$ بر خروجی بیشتر از سایر ورودی های بود (شکل ۵). در شکل های ۶ و ۷ خط برازش بین دبی مشاهداتی و برآورد در ایستگاه اسکندری برای دو مدل ارائه شده است.

در حوزه ی آبخیز سمندگان ورودی های اولیه مدل شامل ۶ ایستگاه باران سنجی (ماهانه) و ۳ ایستگاه دماسنج (ماهانه) و خروجی مدل جریان متوسط ماهانه ایستگاه آب سنجی مندرجان بودند. ۲۱۶ نمونه برای مرحله آموزش، ۷۲ نمونه برای تست انتخاب گردید. با توجه به نتایج بدست آمده تاثیر ورودی های $P_1, P_2, P_3, P_4, P_5, T_1, T_2, T_3$ بر خروجی بیشتر از سایر ورودی های منتخب است (شکل ۸). تحلیل حساسیت ورودی ها در روش TLNN انجام گرفت (شکل ۹). با توجه به نتایج بدست آمده تاثیر ورودی های $P_1, P_2, P_3, P_4, P_5, T_1, T_2, T_3$ بر خروجی بیشتر از سایر ورودی های منتخب است. در شکل های ۱۰ و ۱۱ خط برازش بین دبی مشاهداتی و برآورد در ایستگاه مندرجان برای دو مدل ارائه شده است.

در حوزه ی آبخیز زاینده رود ورودی های اولیه مدل شامل ۴ ایستگاه باران سنجی (ماهانه) و ۳ ایستگاه دماسنج (ماهانه) و خروجی مدل جریان متوسط ماهانه ایستگاه قلعه شاهرخ بودند. ۲۴۰ نمونه برای مرحله آموزش، ۸۴ نمونه برای تست انتخاب گردید. به منظور




شکل ۲: ساختار کلی شبکه های عصبی پرسپترون چند لایه (MLP)

بحث و نتیجه گیری

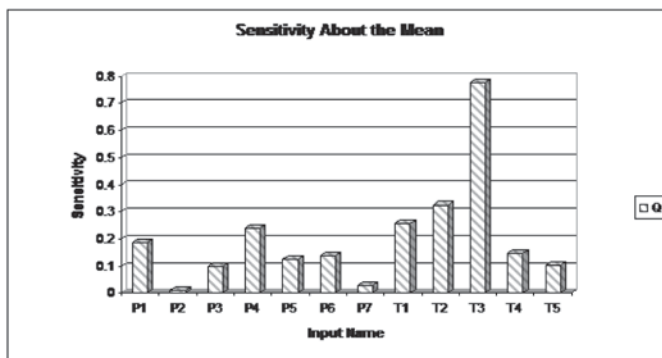
با توجه به توانایی شبکه‌های پرسپترون و شبکه‌های عصبی زمان تاخیری در برآورد، این دو شبکه برای مدل‌سازی انتخاب و اقدام به تعیین ساختار مناسب هر شبکه جهت دستیابی به بهترین برآورد گردید. سپس این دو نوع مدل از لحاظ کارایی مورد بررسی قرار گرفتند.

حوزه‌ی آبخیز پلاسجان: ساختار بهینه شبکه پرسپترون چند لایه در این زیرحوزه، ساختاری با ۷ ورودی (۴ ایستگاه باران‌سنجی و ۳ ایستگاه دماسنجی)، ۲ لایه مخفی با ۱۱ واحد پردازشگر در هر


کاهش تعداد ورودی‌ها و افزایش توان همگرایی شبکه، تحلیل حساسیت خروجی نسبت به ورودی‌ها انجام گرفت و با توجه به نتایج بدست آمده ورودی‌های $P_1, P_2, P_3, P_4, P_5, P_6, P_7, T_1, T_2, T_3$ بر خروجی تاثیر بیشتری داشتند (شکل ۱۲). تحلیل حساسیت با روش TLNN مبین تاثیر بیشتر ورودی‌های $P_1, P_2, P_3, P_4, P_5, P_6, P_7, T_1, T_2, T_3$ بر خروجی بود (شکل ۱۳). در شکل‌های ۱۴ و ۱۵ خط برازش بین دبی مشاهده‌ای و برآورد در ایستگاه قلعه شاهرخ برای دو مدل ارائه شده است. با توجه به تحلیل‌های انجام شده کارایی مدل پرسپترون چند لایه با مدل شبکه عصبی زمان تاخیری در سه زیرحوضه مورد مقایسه قرار گرفتند که نتایج بدست آمده در جدول (۱) ارائه شده است.




شکل ۵: تحلیل حساسیت خروجی نسبت به ورودی‌های اولیه با روش TLNN در حوزه پلاسجان




شکل ۴: تحلیل حساسیت خروجی نسبت به ورودی‌های اولیه با روش MLP در حوزه پلاسجان



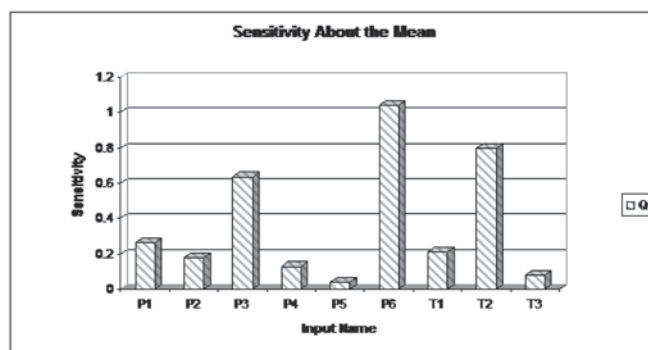
شکل ۷: خط برازش بین دبی مشاهده‌ای و برآورد ایستگاه اسکندری در مرحله تست مدل TLNN




شکل ۶: خط برازش بین دبی مشاهده‌ای و برآورد ایستگاه اسکندری در مرحله تست مدل MLP




شکل ۹: تحلیل حساسیت خروجی نسبت به ورودی‌های اولیه با روش TLNN در حوزه سمندگان



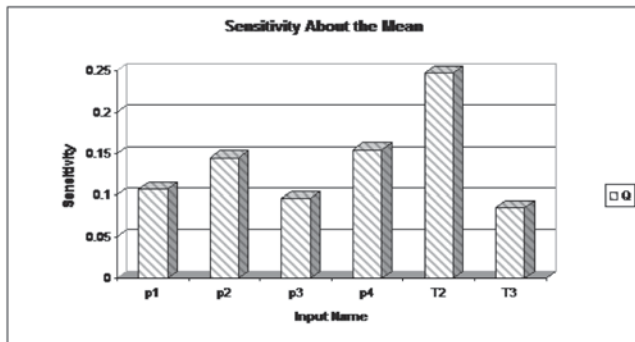
شکل ۸: تحلیل حساسیت خروجی نسبت به ورودی‌های اولیه با روش MLP در حوزه سمندگان




شکل ۱۱: خط برازش بین دبی مشاهداتی و برآورد ایستگاه مندرجان در مرحله تست مدل TLNN




شکل ۱۰: خط برازش بین دبی مشاهداتی و برآورد ایستگاه مندرجان در مرحله تست مدل MLP




شکل ۱۳: تحلیل حساسیت خروجی نسبت به ورودی‌های اولیه با روش TLNN در حوزه زاینده رود



شکل ۱۲: تحلیل حساسیت خروجی نسبت به ورودی‌های اولیه با روش MLP در حوزه زاینده رود



شکل ۱۵: خط برازش بین دبی مشاهداتی و برآورد در ایستگاه قلعه شاهرخ در مرحله تست مدل TLNN



شکل ۱۴: خط برازش بین دبی مشاهداتی و برآورد در ایستگاه قلعه شاهرخ در مرحله تست مدل MLP

متفاوتی داشته باشد (خسروی و دیگران، ۸۹). ۴۰۰۰ تکرار برای آموزش بهینه شبکه مناسب تشخیص داده شد. باید در نظر داشت که منحنی یادگیری در این نوع شبکه بسیار حساس و نیاز به دقت در آموزش شبکه می‌باشد.

حوزه‌ی آبخیز سمندگان: ساختار بهینه شبکه پرسپترون چند لایه در این زیرحوزه، ساختاری با ۶ ورودی (۴ ایستگاه باران‌سنجی و ۲ ایستگاه دماسنجی)، ۲ لایه مخفی با ۱۲ واحد پردازشگر در هر لایه، گشتاور ۰/۹، تابع فعال تانژانت هیپربولیک بود. بهترین آموزش شبکه در ۸۰۰۰ تکرار صورت می‌گرفت. تحلیل حساسیت عمل‌ها بیانگر حساسیت بیشتر داده‌های جریان به ورودی بارش

لایه، گشتاور ۰/۹، تابع فعال تانژانت هیپربولیک بود. بهترین آموزش شبکه در ۹۰۰۰ تکرار صورت می‌گرفت. تحلیل حساسیت عمل‌ها بیانگر حساسیت بالای داده‌های جریان به ورودی دما بود. با توجه به وضعیت توپوگرافی حوزه و نقش مهم برف در تامین جریان‌های سطحی منطقه، دما موجب ذوب برف و تغذیه رودخانه و افزایش دبی می‌گردد. ساختار مناسب شبکه‌های عصبی برگشتی زمان تاخیری شامل ۶ ورودی (۴ ایستگاه باران‌سنجی و ۲ ایستگاه دماسنجی)، ۲ لایه مخفی با ۶ واحد پردازشگر در هر لایه، گشتاور ۰/۹، تابع فعال تانژانت هیپربولیک، ساختار حافظه Laguarre axon و عمق در عمل‌های نمونه ۶ می‌باشد. هرچند تابع فعال‌سازی می‌تواند اثرات

جدول ۱: مقایسه کارایی مدل‌های اجرا شده در زیر حوزه‌های مورد مطالعه

معیار خطا												
زیرحوضه												
زاینده رود				مندرجان				اسکندری				
TLNN		MLP		TLNN		MLP		TLNN		MLP		
تست	آموزش	تست	آموزش	تست	آموزش	تست	آموزش	تست	آموزش	تست	آموزش	
۱۴/۰	۱۴/۰	۶۵/۰	۲۴/۰	۲/۰	۱۷/۰	۲۲/۰	۱۶/۰	۴/۰	۱۹/۰	۳/۱	۲۱/۰	میانگین مربع خطا
۱۶/۰	۱۴/۰	۲/۳	۲۳/۰	۱۱/۵	۱۴/۰	۱/۸	۱۳/۰	۷/۲	۱۶/۰	۶۶/۷	۱۷/۰	میانگین مربع خطای نرمال شده
۲۷/۰	۲۶/۰	۴۵/۰	۳۵/۰	۳۱/۰	۲۸/۰	۳۳/۰	۲۵/۰	۵/۰	۲۴/۰	۵/۰	۳/۰	میانگین خطای مطلق
۰	۰	۰۰۷/۰	۰۰۶/۰	۰۰۸/۰	۰۲/۰	۰۰۳/۰	۰	۰۱/۰	۰۰۱/۰	۰۰۲/۰	۰	حداقل خطای مطلق
۵۹/۱	۷۲/۱	۱۳/۲	۸۶/۱	۸/۱	۶۹/۱	۶۶/۲	۲۳/۲	۴/۲	۵/۲	۵	۴۹/۲	حداکثر خطای مطلق
۹۱/۰	۹۳/۰	۸/۰	۸۸/۰	۸۵/۰	۹۲/۰	۸۱/۰	۸۹/۰	۸۸/۰	۹۲/۰	۷۹/۰	۹/۰	ضریب همبستگی

مرحله آزمون بسیار کمتر است به طوری که میانگین مربع خطا در MLP در مرحله تست بیشتر از ۳ برابر TLNN می‌باشد. همچنین TLNN دارای ضریب همبستگی بالاتری نسبت به MLP در این زیرحوزه می‌باشد. در ایستگاه مندرجان، کارایی دو شبکه عصبی در مرحله آموزش تا حدودی یکسان، اما میانگین مربع خطا در مرحله آزمون در TLNN کم‌تر از MLP (۱۰ درصد کمتر) می‌باشد. در ایستگاه قلعه شاهرخ کارایی TLNN در برآورد جریان بسیار بیشتر از MLP می‌باشد. به طوری که میانگین مربع خطا در مرحله آموزش و آزمون MLP به ترتیب بیشتر از ۱/۷ و ۴/۶ برابر میزان خطا در TLNN است. از طرفی ضریب همبستگی نیز در TLNN بسیار بهتر از MLP می‌باشد. بررسی دو مدل ایجاد شده با ساختارهای بهینه توسعه یافته، مبین کفایت بهتر مدل TLNN در قیاس با MLP به ویژه در زیرحوزه‌های آبخیز زاینده‌رود و پلاسجان می‌باشد. با توجه به اینکه TLNN از ساختار حافظه استفاده می‌کند که مرتبط با داده‌ها یا ورودی‌های قبلی است (تاخیر)، به خوبی می‌تواند عکس‌العمل حوزه را نسبت به ورودی‌ها شبیه‌سازی کند [یزدانی و دیگران، ۳۲] و نتایج دقیق‌تری را در پیش‌بینی ارائه نماید.

نتیجه‌گیری

نتایج به دست آمده از تحلیل حساسیت دبی نسبت به ورودی‌های دما و بارش در حوضه آبخیز پلاسجان، بیانگر این است که دو مدل شبکه عصبی حساسیت زیادتری نسبت به ورودی‌های دمایی در قیاس با بارش داشته‌اند. دلیل عمده حساسیت بیشتر دبی به دما در این حوزه می‌تواند نقش سهم ذوب برف در تغذیه رودخانه باشد که با افزایش دما، برف بیشتری ذوب شده و جریان در رودخانه را افزایش می‌دهد. در حوضه آبخیز سمندگان و در مدل TLNN دبی به هر دو نوع ورودی حساسیت داشته اما میزان حساسیت آن نسبت به دما کمی بیشتر می‌باشد. اما در روش MLP حساسیت

بود. با توجه به موقعیت این حوزه و کم بودن ارتفاعات برفگیر در قیاس با زیرحوزه پلاسجان، حساسیت دبی نسبت به بارش بیشتر است و سهم ذوب برف در تغذیه رودخانه کمتر است. ساختار مناسب شبکه‌های عصبی زمان تاخیری شامل ۶ ورودی (۳ ایستگاه بارانسنج و ۳ ایستگاه دمایی)، دو لایه مخفی با ۶ واحد پردازشگر در هر لایه، گشتاور ۰/۹، تابع فعال تانژانت هایپربولیک، ساختار حافظه Gamma axom و عمق در عامل‌های نمونه ۶ می‌باشد. ۵۰۰۰ تکرار برای آموزش بهینه شبکه مناسب بود تحلیل حساسیت عامل‌ها بیانگر حساسیت بیشتر داده‌های جریان به ورودی دما در این ساختار بود.

حوزه‌ی آبخیز زاینده‌رود: ساختار بهینه شبکه پرسپترون چند لایه در این زیرحوزه، ساختاری با ۶ ورودی (۳ ایستگاه بارانسنجی و ۳ ایستگاه دماسنجی)، ۳ لایه مخفی با ۱۲ واحد پردازشگر در هر لایه، گشتاور ۰/۹، تابع فعال تانژانت هایپربولیک بود. بهترین آموزش شبکه در ۷۰۰۰ تکرار صورت می‌گرفت. تحلیل حساسیت عامل‌ها بیانگر حساسیت بیشتر داده‌های جریان به ورودی دمایی می‌باشد که بعلاوه سهم ذوب برف در تغذیه رودخانه زاینده‌رود در فصل بهار و تابستان است. ساختار مناسب شبکه‌های عصبی زمان تاخیری شامل ۶ ورودی (۴ ایستگاه بارانسنج و ۲ ایستگاه دماسنجی)، ۲ لایه مخفی با ۶ واحد پردازشگر در هر لایه، گشتاور ۰/۹، تابع فعال تانژانت هایپربولیک، ساختار حافظه TDNN axom و عمق در پارامترهای نمونه ۶ می‌باشد. ۳۰۰۰ تکرار برای آموزش بهینه شبکه مناسب بود.

مقایسه کارایی دو نوع شبکه عصبی توسعه داده شده: با توجه به نتایج جدول (۱) در ایستگاه اسکندری کارایی شبکه عصبی زمان تاخیری در مرحله آموزش و تست شبکه بهتر از شبکه پرسپترون چند لایه می‌باشد. به طوری که میانگین مربع خطا در مرحله آموزش در TLNN ۹ درصد کمتر از MLP می‌باشد. همچنین خطا در

حین یادگیری، موجب تقویت یادگیری و افزایش توان تعمیم آن در پیش‌بینی گردد. بهتر است قبل از مدل‌سازی با شبکه‌های عصبی مصنوعی این تحلیل انجام شود.

منابع

1-Adeloye, A. 2009. The relative utility of regression and artificial neural networks models for rapidly predicting the capacity of water supply reservoirs. *Environmental Modeling & Software*, 24:1233-1240.

2-Arian, M. 2002. Determining optimal using model of Babokan reservoir dam with dynamic programming- Artificial Neural Network, MSc thesis of Irrigation engineering, Tarbiat Modarres University.

3-ASCE-I, 2000. Artificial neural networks in hydrology, I: preliminary concepts. *Journal of Hydrologic Engineering*, 5(2):115-123.

4-Bagheri, A. 2009. Real time use of Dams using Neural forecasting, MSc thesis of Civil engineering, Industrial University of Sharif.

5-Bhattacharya, B., Lobbrecht, A.H. & Solomatine, D. P. 2003. Neural Networks and Reinforcement Learning in Control of Water system. *Journal of water Resources Planning and management*, 129(6):1-8.

6- Breitscheidel, A., Cser, J. & Van der veer, P. 1998. Applicability of ANNs in hybrid water models. *Hydroinformatics'98*, Volume 2, Rotterdam, Netherlands.

7-Chen, C.S., Chen, B.P., Chou, F.N. and Yang, C. C. 2010. Development and application of a decision group back-propagation neural network for flood forecasting. *Journal of Hydrology*, 385:173-182.

8- Coulibaly P., antil F., Aravena R. & Bobee, B. 2001. Artificial neural networks modeling of water table depth fluctuations. *Water resources research*, 37(4): 885-896.

9-Damangir, H. 2002. Dynamic training of artificial neural network and its use for real time flood forecasting, MSc thesis of Civil engineering,

10-Dorum, A., Yarar, A., Sevimli, M.F. and

بارش بیشتر از دما بوده است. در این زیرحوزه سهم برف در تامین جریان‌های سطحی منطقه در قیاس با زیرحوزه پلاسجان کم‌تر است و بارش نقش زیادتری در تامین جریان‌های سطحی دارد. تحلیل نتایج حساسیت دبی در زیرحوزه آبخیز زاینده‌رود مبین این است که هرچند که بیشترین حساسیت دبی نسبت به دما می‌باشد، اما در مجموع دو متغیر بر دبی تاثیرگذار بوده و در مدل TLNN به خوبی مشهود است. در این زیرحوزه نیز ذوب برف نقشی مهم در تغذیه رودخانه دارد. در مجموع می‌توان بیان نمود که با توجه به سهم برف در تامین منابع آب سطحی در این زیرحوزه‌ها، دما به علت نقش آن بر ذوب برف بر دبی ماهانه تاثیر زیادی در مدل‌سازی دارد.

بررسی ضرایب همبستگی در ایستگاه اسکندری نشان‌دهنده این است که مقدار این ضریب در روش TLNN بیشتر از روش MLP بوده و مقدار آن در مرحله آموزش بیشتر از مرحله آزمون می‌باشد. در مدل MLP ضریب همبستگی (۰/۷۹)، اما در روش TLNN مقدار آن خوب است (۰/۸۸). در ایستگاه آب‌سنجی مندرجان، نتایج ضریب همبستگی در مرحله آموزش و آزمون برای برآورد تاحدودی خوب است. اما در ایستگاه آب‌سنجی قلعه شاهرخ، ضریب همبستگی برای مدل MLP نسبتاً خوب، ولی در مدل‌سازی با روش TLNN ضریب همبستگی در دو مرحله آموزش و آزمون خوب می‌باشد.

بررسی میانگین خطای مطلق در پیش‌بینی جریان ماهانه ایستگاه اسکندری حاکی از این است میزان خطای آموزش در روش MLP برابر ۰/۳ و در روش TLNN برابر ۰/۲۴ می‌باشد. اما میزان خطا برای مرحله تست برای دو مدل مذکور مشابه و برابر ۰/۵ می‌باشد. در ایستگاه مندرجان میزان خطای آموزش در روش MLP برابر ۰/۲۵ و در روش TLNN ۰/۲۸ می‌باشد. این میزان خطا در برای فاز آزمون کمی افزایش یافته و به ۰/۳۳ برای مدل MLP و ۰/۳۱ برای مدل TLNN می‌رسد. میانگین خطای مطلق در ایستگاه قلعه شاهرخ نشانگر تفاوت دو مدل در پیش‌بینی در فاز آموزش می‌باشد. خطا مرحله آزمون مدل TLNN کم‌تر از روش MLP بوده در حدود ۰/۲۷ می‌باشد، در حالی که میزان خطا در مدل MLP در این مرحله ۰/۴۵ می‌باشد. با توجه به خطاهای بدست آمده می‌توان گفت که شبکه‌های عصبی زمان تاخیری از قابلیت خوبی در برآورد جریان ماهانه به ویژه در ایستگاه قلعه شاهرخ برخوردارند.

با توجه به اینکه توانایی پیش‌بینی و تعمیم یک مدل شبکه عصبی بستگی زیادی به میزان یادگیری دارد، لازم است در حین آموزش، منحنی آموزش بخوبی بررسی گردد و در صورت لزوم مرحله آموزش تکرار گردد. همچنین به حداقل‌های موضعی در حین اجرای این مرحله توجه گردد. در اجرای شبکه‌های عصبی زمان تاخیری، مرحله آموزش بسیار حساس بوده و لازم است با انتخاب ساختار مناسب حافظه، میزان واگرایی شبکه به حداقل برسد. آنالیز حساسیت داده‌ها می‌تواند ضمن کاهش پیچیدگی شبکه در

- neural networks. *Journal of Hydrology*, 246: 45-62.
- 20-Kisi, O. 2005. Daily river flow forecasting using artificial neural networks and auto-regressive models. *Turkish Journal of Engineering Environmental Science*, 29: 9-20.
- 21-Kumar D.N., Rajo K.S. & Satish T. 2004. River flow forecasting using recurrent neural networks. *water resource management*, 18:143-161.
- 22-Lange, N.T.G. 1998. Advantages of unit hydrograph derivation by neural networks, *Hydroinformatics'98*, Volume 2: 759-763, Rotterdam, Netherlands.
- 23-Li, C., Guo, S. and Zhang, J. 2009. Modified NLPM-ANN model and its application. *Journal of Hydrology*, 378:137-141.
- 24-Mahdavi, M. 2000. *Applied hydrology*, 2nd edition, University of Tehran Publication.
- 25-Mahnaj, M.B. 2003. *Neural networks basics*, 2nd edition, Amirkabir University Publication.
- 26-Mohammadi, K., Eslami, H.R. & Dayyani Dardashti, Sh. 2005. Comparison of regression, ARIMA and ANN models for reservoir inflow forecasting using snowmelt equivalent (a case study of Karaj). *Journal of Agricultural Science and Technology (JAST)*, 7: (2):17-30.
- 27-Napolitano, G., See, L., Calvo, B., Savi, F. and Heppenstall, A. 2010. *Physics and Chemistry of Earth*. 35:187-194.
- 28-Panagoulia, D. 2006. Artificial neural networks and high and low flows in various regimes. *Hydrological Science Journal*, 51(4): 563-587.
- 29-Rostam Afshar, N., Fahmi, H. and Pire, A. 2007. Prediction and simulation of river flow using neural networks and Fourier model, *Journal of Water Resources Research*, 2(1).
- 30- Stary, M., Seblova, H. & Turecek, B. 1998. The operative control of the passage of floods. *Hydroinformatics'98*, Volume 2: 831-836, Rotterdam, Netherlands.
- 31-Tareghian, R., Kashefpor, M., and Taheri, M. 2007. River flow forecasting using Onucyildiz, M. 2010. Modeling the rainfall-runoff data of Susurluk basin. *Expert systems with applications*, 37:6587-6593.
- 11- Drecourt, J.P. 1999. Application of neural network and genetic programming to rainfall-runoff modeling. D2K Technical Report, Danish Hydraulic Institute.
- 12-Fathavadi, A., Salajeghe, A. and Mahdavi, M. 2009. River flow forecasting using Nero-Fuzzy method and time series models, *Iran-Watershed Management Science & Engineering*, 2(5):21-29.
- 13-Fernando, M., Miriam, M., Eloy, K. & Heinz, F. 2011. Monthly rainfall-runoff modeling using artificial neural networks, *Hydrological Sciences Journal*, 56(3): 349 – 361.
- 14-Hall, M.J. & Minns, W.A. 1998. Regional flood forecasting analysis using artificial neural networks. *Hydroinformatics'98*, Volume 2: 783-789, Rotterdam, Netherlands.
- 15-Institute of Planning Researches and Agricultural Economy. 1998. Integrated studies of rehabilitation and development of agriculture and natural resources in Zayandehrud and Ardestan Basins, No.2: Surface water, Agriculture Ministry, Tehran, Iran.
- 16-Jagadeesh, A., Zhang, B., & Govindaraju, R. 2000. Comparison of ANNs and empirical approaches for predicting watershed runoff. *Journal of Water Resources Planning and Management*, 26(3): 156-166.
- 17-Karimi, H., Ahmadvand, M. and Moazed, H. 2010. Flow forecasting of Karoon River using 6 month former data of rainfall located in downstream, 8th International Conference on River Engineering.
- 18-Khosravi, M., Salajegheh, A., Mahdavi, M. and Mohseni Saravi, M. 2010. Determination of the best output layer activation function in neural network for forecasting peak discharge, *Iran-Watershed Management Science & Engineering*, 4(12):61-64.
- 19-Kim, G. & Barros, A.P. 2001. Quantitative flood forecasting using multisensory data and

34- Yazdani, M.R., Saghafian, B. & Mahdian, M.H.2009. Monthly runoff estimation using artificial neural networks. 1. Journal of Agricultural Science and Technology (JAST),11: 355-362.

35-Zealand, C.M., Burn, D.H.& Simonovic, S.P.1999.Short term stream flow forecasting using artificial neural networks. Journal of Hydrology, 214: 33-48.

using artificial neural networks and auto-regressive models. Turkish Journal of Engineerin

artificial neural network: A case study on Karoon River, First Conference on exploitation of Karoon and Zayandehrud Basins Water Resources.

32-Toth, E., Brath, A. & Montaria, A.2000. Comparison of short-term rainfall prediction models for real-time flood forecasting. Journal of Hydrology, 239: 132-147.

33-Turan, M.E. and Yurdusev, M.A.2009.River flow estimation from flow records by artificial intelligence methods. Journal of Hydrology, 369:71-77.