

## کاربرد شبکه عصبی مصنوعی در پیش‌بینی جریان رودخانه با استفاده از شاخص‌های اقلیمی مطالعه موردی: حوضه آبریز نازلوچای

علیرضا برهانی داریان      دانشیار دانشکده عمران، دانشگاه صنعتی خواجه نصیرالدین طوسی  
احمد فاتحی مرج      استادیار پژوهشکده حفاظت خاک و آبخیزداری کشور

### چکیده

از حدود چند دهه پیش موضوع استفاده از پدیده‌های اقلیمی برای پیش‌بینی داده‌های هواشناسی و هیدرولوژیک مطرح شده است. تحقیقات موجود در این زمینه غالباً مربوط به پیدا کردن ارتباط بین بارش و دما با پدیده‌های اقلیمی بوده است. در این مقاله پس از بررسی‌های بسیار مشخص گردید که امکان پیش‌بینی درازمدت (از یک سال قبل) جریان رودخانه با استفاده از پدیده‌های اقلیمی انسو (النینو و نوسانات جنوبی-ENSO) و ناو (نوسانات اطلس شمالی-NAO) میسر است. برای اینکار از داده‌های ایستگاه هیدرومتری تپیک واقع در حوضه آبخیز نازلوچای از زیرحوضه‌های دریاچه ارومیه استفاده شده است. بررسی‌ها نشان می‌دهد که حدود ۸۰ درصد آورد سالانه رودخانه در فصل بهار اتفاق می‌افتد. تحقیق بر روی ارتباط دبی در فصل‌های مختلف با پدیده‌های مورد اشاره نشان داد که بهترین ارتباط بین دبی فصل بهار با شاخص‌های SOI (مربوط به انسو) و NAO (ناو) بهار سال قبل است. از طرفی، بررسی‌های معمول حاکی از عدم امکان دستیابی به یک مدل قابل قبول برای پیش‌بینی دبی حتی در فصل بهار داشت. اما تحقیقات بیشتر مشخص ساخت که می‌توان با استفاده از روش شبکه عصبی مصنوعی (ANN) با معماری مشخص به نتایج برجسته و قابل قبولی برای پیش‌بینی دبی بهار سال بعد با استفاده از شاخص‌های بهار سال جاری دست یافت. نظر به دوری فاصله کانون پدیده انسو و نیز NAO از ایران، انتظار نمی‌رفت ارتباطاتی در این حد قوی بین آنها و جریان‌های رودخانه در ایران وجود داشته باشد. براساس نتایج این تحقیق می‌توان با بکارگیری شبکه عصبی و با استفاده از شاخص‌های اقلیمی یکسال قبل، دبی یک سال بعد را با دقت مناسبی پیش‌بینی نمود.

کلمات کلیدی: پیش‌بینی جریان رودخانه، شاخص‌های اقلیمی، انسو، ناو، شبکه عصبی، حوضه‌ی نازلوچای.

## Application of Artificial Neural Network in Stream flow Forecasting using Climatic Indices (Case Study: Nazloochay River Basin)

A. Borhani Dariane      Civil Engineering K.N.T. University of Tech., Tehran

A. Fatehi Marj      Soil Conservation Watershed management Research Institute

### Abstract

Climatic indices are used to forecast seasonal stream flow through the application of neural network techniques. This research has been carried out in Nazloochay River Basin in northwest of Iran. The spring season stream flow of this basin is about 80% of the annual flow, and the previous research shows that it is influenced by the Southern Oscillation Index (SOI) and North Atlantic Oscillation (NAO). A feed-forward three layers Artificial Neural Network (ANN) is used to forecast the spring stream flow with one-year lead time. It is believed that considering the lead time of one year and the long distance between the basin in Iran and the locations of climatic phenomenon (SOI and NAO), the findings in this paper are very important and distinguished, both from water resources management aspects and teleconnections outlook.

**Key words:** Stream flow forecasting, Neural network, SOI, NAO, Nazloochay river.

## ۱- مقدمه

محققین بررسی شده و برای پیش‌بینی بارندگی و جریان رودخانه‌ها مورد استفاده قرار گرفته است. هیوز و ساندرز [۱۳] بارندگی ماهانه را برای یک دوره ۹۶ ساله، بین سال‌های ۱۹۰۱ تا ۱۹۹۶، روی منطقه اروپا بررسی نموده و از شاخص‌های SOI و NINO3,4 برای همبستگی با بارندگی استفاده کردند. آنها با استفاده از همبستگی ماهانه، فصلی و سالانه بین بارندگی و NINO3,4 به این نتیجه رسیدند که همبستگی فصلی بارندگی (دوره مارس، آوریل و می) با NINO3,4 فصلی (دوره دسامبر، ژانویه و فوریه) از میزان متناظر ماهانه و سالانه بیشتر است. نیکلسون [۱۵] از آمار بارندگی ماهانه استاندارد شده ۱۲۲ ایستگاه در ۷ منطقه در اقیانوس آرام و ۱۰ منطقه در اقیانوس اطلس طی دوره آماری ۱۹۴۶ تا ۱۹۹۶ استفاده نموده و برای پیش‌بینی بارش امکان استفاده از شاخص‌های NINO3,4 و SOI را بررسی کردند. در دوره آماری یاد شده ۲۰ واقعه النینو (El Nino) وجود داشته است که در اکثر مناطق همراه با باران کمتر از میانگین بوده است. همچنین، این مقاله نشان می‌دهد که کمبود بارندگی در سال النینو از نیمه دوم سال شروع و تا نیمه اول سال بعد نیز ادامه دارد. گریب و همکاران [۱۱] تأثیر ENSO را بر بارندگی در نواحی جنوبی برزیل بررسی کردند. در این بررسی مشخص شد که بارندگی بهاره تحت تأثیر ENSO است. اما این تأثیر به‌صورت کاهش بارندگی در دوران لانینا (La Nina) دیده شده است که غالباً در ماه‌های اکتبر و نوامبر می‌باشد. همچنین، افزایش بارندگی در پاییز و زمستان در دوران النینو (فاز منفی ENSO) وجود داشته است. پیسیاتانو و همکاران [۱۶] گزارش کرده‌اند که افزایش بارندگی در اروگوئه در دوران SOI مثبت (لانینا) مشاهده شده است. سیلورمن و دراکوپ [۱۸] پس از بررسی ارتباط بین بارندگی ماهانه و شاخص‌های فشار هوا و SOI متوجه شدند که این همبستگی‌ها خطی نبوده و به وسیله مدل‌های آماری چند مرتبه‌ای نیز قابل تشخیص نمی‌باشد ولی ممکن است شبکه عصبی بتواند این ارتباطات را مشخص کند. کانیلی [۸] امکان پیش‌بینی دراز مدت جریان چندین رودخانه در ایالات متحده را با استفاده از شاخص‌های اقلیمی بررسی کرد. وی همبستگی بین شاخص‌های NAO، PDO، NINO3,4،

از آنجا که پیش‌بینی جریان رودخانه در منابع آب از اهمیت زیادی برخوردار است، محققین طی چندین دهه گذشته روش‌های مختلفی را در این زمینه مورد تحقیق و بررسی قرار داده‌اند. روش‌های پیش‌بینی راجع را بطور عمده میتوان به روش‌های مبتنی بر سری‌های زمانی، مدل‌های رگرسیونی و مدل‌های حوضه‌آبریز تقسیم‌بندی نمود [۲۰]. در این بین، روش‌های سری زمانی از محدودیت بیشتری برخوردار بوده و در مجموع دقت کمتری در پیش‌بینی دراز مدت جریان رودخانه دارند. از طرف دیگر، مدل‌های حوضه آبریز که برای پیش‌بینی جریان استفاده می‌شوند بسیار پیچیده بوده و تهیه و تولید آنها نیازمند هزینه بسیار بوده و به آمار و اطلاعات وسیعی نیاز دارند که اغلب موجود نمی‌باشد. اما، اگرچه مدل‌های رگرسیونی، که ساختارهای ساده و پیچیده را می‌تواند شامل شوند، کمتر با این مشکلات روبرو هستند لکن اغلب بدلیل پیچیدگی‌های موجود در فرآیند تبدیل بارش و برف به جریان رودخانه قادر به پیش‌بینی دقیق جریان بالاخص در فاصله‌های زمانی طولانی‌تر نمی‌باشند. از طرفی، کارایی مدل‌های رگرسیونی بطور عمده مربوط به پیش‌بینی‌های میان مدت بوده و در دراز مدت علاوه بر دلایلی که ذکر شده با توجه به دخالت عوامل دیگر قادر به پیش‌بینی و یا حتی نشان دادن رابطه پارامترهای مختلف و جریان رودخانه نمی‌باشند [۱۹]. مروری بر تحقیقات گذشته بخوبی این مسئله را روشن می‌سازد. از سوی دیگر، با توسعه و رواج روش شبکه عصبی مصنوعی از یک دهه قبل به این طرف، امکان کشف و آشکارسازی بهتر ارتباط بین پارامترهای مختلف با بارش و جریان رودخانه بطور چشمگیری میسر گردیده است.

پدیده‌های اقلیمی که در این تحقیق مورد استفاده قرار گرفته‌اند پدیده‌هایی هستند که به‌صورت شاخص‌های عددی نظیر NAO<sup>۱</sup>، SOI<sup>۲</sup>، PNA<sup>۳</sup>، PDO<sup>۴</sup> و NOI<sup>۵</sup> تعریف شده‌اند. این شاخص‌ها با استفاده از اندازه‌گیری‌های درجه حرارت و فشار هوا در نقاط مختلف اقیانوس‌ها تهیه می‌شوند. همبستگی و روابط این شاخص‌ها، با بارندگی در مناطق مختلف توسط

<sup>۱</sup> North Atlantic Oscillation

<sup>۲</sup> Southern Oscillation Index

<sup>۳</sup> Pacific North America

<sup>۴</sup> Pacific Decadal Oscillation

<sup>۵</sup> North Oscillation Index

و SST<sup>1</sup> را با جریان رودخانه‌ها در ماه‌های آوریل تا ژوئیه بررسی کرده و به این نتیجه رسید که همبستگی SST با آورد رودخانه در این ماه‌ها بیشتر از دیگر شاخص‌ها است. توتل و پیکوتا [۲۳] با استفاده از SST و شاخص SOI دبی فصلی دو رودخانه در حوضه کلرادو را پیش‌بینی کردند. آنها با استفاده از شاخص‌های SST و SOI فصل بهار، دبی فصل زمستان سال بعد آن دو رودخانه را پیش‌بینی کردند. در این تحقیق مشخص شد که شاخص SOI برای سال‌های النینو دقت بیشتری دارد. هملت و لتنمایر [۱۲] با استفاده از شاخص‌های ENSO و PDO امکان پیش‌بینی جریان رودخانه کلمبیا واقع در ایالات متحده آمریکا را بررسی کردند. آنها نشان دادند که نتایج این پیش‌بینی از پیش‌بینی هواشناسی دقیق‌تر است. ایمز [۷] نیز برای پیش‌بینی دبی رودخانه یاکیما (Yakima) در ایالت واشینگتن آمریکا از شاخص‌های اقلیمی استفاده کرد. در این رابطه، دبی رودخانه با هر یک از شاخص‌های اقلیمی SST، PDO، و SOI همبستگی داده شد. همبستگی مزبور برای دبی سه ماهه آوریل، می و ژوئن با شاخص‌های اقلیمی تا ۱۲ ماه قبل انجام شد. نتایج بدست آمده نشان می‌دهد که مجموع دبی سه ماهه آوریل، می و ژوئن (فصل بهار) با SOI مربوط به ۵ تا ۶ ماه قبل و با PDO مربوط به ۸ ماه قبل همبستگی بیشتری دارد. این همبستگی بترتیب برابر با  $(R=0.45) \cdot 0.45$  و  $(R=0.50) \cdot 0.50$  است.

در ایران نیز مطالعاتی طی چند سال اخیر در این زمینه انجام شده است. ناظم السادات [۶] تأثیر ENSO را بر بارندگی‌های زمستانه برخی از ایستگاه‌های ایران بررسی نموده است. او میزان بارندگی زمستانه هر ایستگاه را در زمان النینو (فاز منفی) و لانینا (فاز مثبت) با شاخص SOI پاییز (بدون تأخیر) مقایسه نموده و به این نتیجه رسید که اکثر ایستگاه‌ها در زمان النینو بیشتر از زمان لانینا بارندگی دارند. غیور [۲] تأثیر پدیده انسو را بر ناهنجاری‌های بارش تابستان و پائیز منطقه جنوب شرق ایران بررسی کرد. او با استفاده از آزمون‌های آماری به این نتیجه رسید که خشکسالی‌های پائیزه عموماً طی لانینا (فاز سرد) به وقوع می‌پیوندد. همچنین، تحقیق دیگری که توسط ناظم‌السادات و همکاران [۱۴] در شمالغرب ایران انجام شده است نشان می‌دهد که نوسانات بارندگی پاییز این منطقه از

ایران با بارندگی ایالت نیوساوت‌ولز<sup>۲</sup> استرالیا به طور قابل توجه ارتباط دارد. همچنین، نتایج این تحقیق حاکی از آن است که تأثیر فاز مثبت و منفی انسو بر بارندگی در شمالغرب ایران قوی‌تر از تأثیر آن در ایالت مزبور در استرالیا است. فاتحی مرج و همکاران [۳، ۴] تأثیر سیگنال‌های اقلیمی را بر بارش و جریان رودخانه در حوضه دریاچه ارومیه بررسی کردند. نتایج این تحقیقات نشان می‌دهد تأثیر SOI و NAO بهار بر جریان رودخانه‌ها در بهار سال بعد قابل توجه و از شاخص‌های دیگر اقلیمی بیشتر است. کولن و همکاران [۹] در تحقیق خود نشان دادند تأثیر NAO بر روی جریان فصل زمستان (DJFM) رودخانه کارون در ایران قابل توجه است ( $R=-0.29$ ).

سیلورمن و دراگوب [۱۸] پیش‌بینی بارندگی یک سال بعد در ایالت کالیفرنیا را با استفاده از روش شبکه عصبی بررسی نمودند. نتایج تحقیق فوق نشان می‌دهد که الگوی باران پیش‌بینی شده به الگوی بارندگی مشاهده شده نزدیک است. همچنین، شمس‌الدین [۱۷] برای مدل‌سازی باران-رواناب، از شبکه عصبی استفاده کرد. او از این مدل‌سازی برای شش حوضه‌ی مختلف در سطح جهان استفاده کرد و نتیجه گرفت که شبکه عصبی مخصوصاً شبکه پیشخور توانایی خوبی برای مدل‌سازی بارش-رواناب دارد. دانه و همکاران [۱۰] با استفاده از آمار روزانه بارندگی، تبخیر همان روز و دبی یک روز قبل، به کمک شبکه عصبی دبی یک روز بعد را برای دو رودخانه در حوضه Da Nhim در ویتنام پیش‌بینی کردند. آن‌ها نتایج شبکه عصبی را با مدل تانک مقایسه نموده و نتیجه گرفتند که برای پیش‌بینی دبی یک روز بعد، شبکه عصبی نتایج بهتری عرضه می‌کند. همچنین، تینگسانچای و گواتام [۲۲] برای پیش‌بینی دبی سی‌لاب با داده‌های بارندگی، تبخیر و رواناب، از دو مدل یک‌پارچه<sup>۳</sup> (کلی) بنام تانک و مدل بارش-رواناب و نیز شبکه عصبی استفاده کردند. نتیجه اعتبارسنجی مدل‌ها برای مقادیر پیش‌بینی شده نشان می‌دهد که جذر میانگین مربعات خطای دبی یک روز بعد برای مدل‌های تانک و مدل بارش-رواناب برابر با ۰/۵۵ و برای شبکه عصبی برابر با ۰/۳۲ مترمکعب بر ثانیه است که نشان از دقت بیشتری شبکه عصبی نسبت به دو مدل دیگر دارد. شمس‌الدین [۱۷] شبکه‌های پیشخور با روش آموزش پس انتشار خطا را بعنوان مناسب‌ترین نوع شبکه عصبی در پیش‌بینی جریان رودخانه‌ها معرفی می‌نماید.


<sup>2</sup> New South Wales

<sup>3</sup> Lumped Model

<sup>1</sup> See Surface Temperature

مهمترین عنصر پردازش در سیستم‌های زیستی است. در شبکه عصبی مصنوعی هر نرون زمانی فعال می‌شود که مجموع سیگنال‌های رسیده به بدنه آن از حد آستانه مشخصی تجاوز نماید. هر نرون تعدادی ورودی را از داده‌های اصلی و یا از خروجی نرون‌های دیگر دریافت می‌کند. اتصال‌هایی که بین نرون‌ها وجود دارد، دارای وزن هستند. این وزن‌ها در هنگام عبور داده‌ها از آن اتصال، در داده عبوری تأثیر می‌گذارند. هر شبکه عصبی مصنوعی معمولاً از سه نوع لایه ورودی، میانی و خروجی تشکیل می‌شود [۱۲ و ۱۸].

**ساختار شبکه:** در یک شبکه عصبی مصنوعی، لایه اول یا لایه ورودی شامل اندازه‌گیری‌ها و یا بردار ورودی است و لایه آخر یا لایه خروجی مقادیری است که شبکه محاسبه می‌کند. در هر لایه تعدادی گره یا سلول عصبی (نرون) وجود دارد. این گره‌ها از طریق وزن‌ها به گره‌های بعدی متصل می‌شوند. هر گره دو قسمت دارد که در قسمت اول آن مجموع حاصل‌ضرب مقادیر و وزن‌ها و در قسمت دوم تابع تحریک قرار دارد که این مقادیر از آن عبور و به لایه بعدی می‌روند. شکل (۱) شمای کلی از یک شبکه عصبی مصنوعی چند لایه را نشان می‌دهد.



شکل ۱- ساختار کلی یک شبکه عصبی چند لایه

را تحت عنوان معماری شبکه مطرح کرد، بر اساس انتخاب نوع شبکه، توابع یادگیری و تعداد لایه‌ها همراه با تعداد نرون‌ها (گره‌ها) مشخص می‌شود. در واقع، این معماری شبکه است که نحوه جریان داده‌های ورودی را برای رسیدن به خروجی مطلوب تعیین می‌کند. تابع پایه به صورت معادله (۱) محاسبه می‌شود:

در ایران رضایی [۱] با استفاده از شبکه عصبی و مدل رگرسیون چند متغیره دبی اوج تعدادی از زیرحوضه‌های حوضه سفیدرود را مدل‌سازی نمود. او از داده‌های بارندگی یک روز قبل، شیب حوضه، طول آبراه، ارتفاع، شیب و مساحت سازندهای زمین شناسی به‌عنوان ورودی استفاده کرد و نشان داد برآورد دبی اوج با استفاده از شبکه عصبی دقیق‌تر از مدل رگرسیون است.

بررسی منابع موجود نشان می‌دهد محققینی که از شبکه عصبی برای مدل‌سازی و یا پیش‌بینی دبی رودخانه استفاده کرده‌اند، معمولاً از بارندگی و خصوصیات فیزیوگرافی حوضه به‌عنوان ورودی بهره جسته و دبی رودخانه برای یک زمان کوتاه مدت (یک یا دو روز بعد) را به عنوان خروجی پیش‌بینی کرده‌اند. اما در این تحقیق پیش‌بینی دراز مدت جریان رودخانه مدنظر بوده و کارایی شبکه عصبی به منظور پیش‌بینی دبی فصلی یک سال بعد رودخانه مورد بررسی قرار می‌گیرد.

## ۲- مبانی شبکه‌های عصبی

استفاده از شبکه‌های عصبی مصنوعی از اوایل قرن بیستم شروع شد و در دهه‌های اخیر گسترش بیشتری یافته است. نرون

شبکه استفاده شده برای پیش‌بینی دبی رودخانه، شبکه عصبی پیشخور چند لایه است که به آن شبکه پرسپترون چند لایه (MLP)<sup>۱</sup> هم می‌گویند. معمولاً از قانون یادگیری پس انتشار خطا (BPE)<sup>۲</sup> برای آموزش این شبکه استفاده می‌شود. به عبارتی، توپولوژی شبکه‌های پرسپترون چند لایه با قانون پس انتشار خطا تکمیل می‌شوند [۵]. ساختار شبکه، که می‌توان آن

<sup>۱</sup> Multi Layer Perceptron

<sup>۲</sup> Back Propagation Error

پس از بررسی بسیار از میان تعداد شاخص‌های مختلف مانند: SOI(Southern Oscillation Index), PDO(Pacific Decadal Oscillation), NAO(North Atlantic Oscillation), PNA(Pacific North Atlantic), NINO3.4(El Nino Oscillation), و NOI(North Oscillation Index) انتخاب گردید. بررسی‌ها که توسط فاتحی‌مرج و همکاران [۳] انجام شد نشان داد که تأثیر دو پدیده‌ی نوسانات جنوبی (SOI) و نوسانات اطلس شمالی (NAO) از پدیده‌های دیگر بر جریان بهار رودخانه در این حوضه بیشتر است. از طرفی، جریان فصل بهار در حدود ۸۰ درصد آورد سالانه را شامل می‌شود. برای بکارگیری جریان رودخانه در مدل ابتدا داده‌ها با استفاده از تابع لگاریتم نرمال‌سازی شدند. با توجه به تابع محرک انتخاب شده برای شبکه مورد نظر، مقادیر شاخص‌ها و دبی به بازه [۱،۱] تبدیل شد که پس از پیش‌بینی، مجدداً به مقادیر اولیه برگردانده شده است. متوسط مقادیر شاخص‌ها و دبی برای فصول مختلف در هر سال محاسبه شد. به علت محدودیت تعداد داده‌ها، از مجموع ۴۹ سال، ۴۴ سال (۹۰ درصد) برای آموزش و بقیه (۱۰ درصد) برای آزمایش مدل در نظر گرفته شد.

در این تحقیق، پس از بررسی‌های بسیار مشخصات شبکه بشرح زیر تعیین گردید. در این راستا، شبکه طراحی شده برای پیش‌بینی دبی رودخانه از یک لایه ورودی با دو ورودی، یک لایه میانی و یک لایه خروجی تشکیل شده است که به‌صورت پیش‌رو عمل می‌کند. همچنین، همانطور که در بالا اشاره شد نتایج بررسی‌ها ساختار مناسب شبکه را مشخص ساخت. براین اساس، از شبکه عصبی پیش‌خور چند لایه<sup>۲</sup> برای ساختار مدل و از الگوریتم پس انتشار خطا (BPE) برای به‌هنگام‌سازی استفاده شد. در شبکه عصبی طراحی شده دو بردار داده که در واقع شاخص‌های اقلیمی SOI و NAO فصل بهار، تابستان، پاییز و زمستان است، به‌عنوان ورودی شبکه و شاخص دبی بهار سال بعد به‌عنوان مقدار واقعی یا خروجی شبکه منظور شده است. در این شبکه از تابع TrainLM<sup>۳</sup> بعنوان تابع یادگیری برای پس انتشار خطا استفاده شد. همچنین تابع آموزش استفاده شده در این شبکه تابع آموزش LearnGDM<sup>۴</sup> که از گرادیان نزولی با استفاده از وزن‌ها و ارب<sup>۵</sup> استفاده می‌کند.

$$\text{net}(i) = \sum_{j=1}^n w_{ij} \times x_j + b_i \quad (1)$$

که در آن،  $i$  مشخص کننده لایه قبل و  $j$  مشخص کننده لایه بعد،  $b_i$  مقدار آستانه هر نرون است. توابع تحرک مختلفی مانند توابع خطی مثبت، تانژانت هیپربولیک<sup>۱</sup>، زیگموئید، می‌توان استفاده کرد که بر اساس بررسی‌ها و دامنه داده‌های ورودی و خروجی در این تحقیق از تابع تانژانت هیپربولیک به صورت معادله (۲) استفاده شده است.

$$f(\text{net}) = \frac{(e^{\text{net}} - e^{-\text{net}})}{(e^{\text{net}} + e^{-\text{net}})} \quad (2)$$

اجرای شبکه عصبی در دو مرحله آموزش و آزمایش شبکه است. در مرحله آموزش داده‌های ورودی و خروجی به سیستم داده می‌شود و شبکه سعی می‌کند با اصلاح وزن‌ها مقادیر خروجی محاسبه شده را به مقادیر واقعی نزدیک کند. در مرحله آزمایش ورودی‌های جدید که در مرحله قبل استفاده نشده‌اند، در دامنه تغییرات داده‌های قبلی به سیستم وارد می‌شوند و خروجی‌های آن ثبت می‌گردد. با مقایسه خروجی‌های مرحله دو با مقادیر واقعی کارایی شبکه ارزیابی می‌شود.

### ۳- کاربرد روش

منطقه مورد مطالعه در این تحقیق، زیرحوضه‌ی نازلوچای واقع در حوضه‌ی دریاچه ارومیه است. در این زیرحوضه از آمار ایستگاه هیدرومتری تپیک استفاده شده است. موقعیت زیرحوضه و ایستگاه در شکل (۲) نشان داده شده است. بارندگی متوسط سالانه حوضه نازلوچای در حدود ۳۰۰ میلی‌متر و آورد متوسط رودخانه در ایستگاه تپیک در فصل‌های بهار، تابستان، پاییز و زمستان به ترتیب برابر با ۱۱۰، ۸۶۰، ۱۲۰ و ۱۸۰ میلیون مترمکعب است.

برای پیش‌بینی طولانی مدت دبی فصل بهار رودخانه از داده‌های دبی متوسط ماهانه ایستگاه تپیک در حوضه نازلوچای بمدت ۴۹ سال (۱۹۵۱-۲۰۰۰) و نیز شاخص نوسانات جنوبی (SOI) و شاخص نوسانات اطلس شمالی (NAO) متناظر با داده‌های دبی این ایستگاه استفاده شده است. این دو شاخص

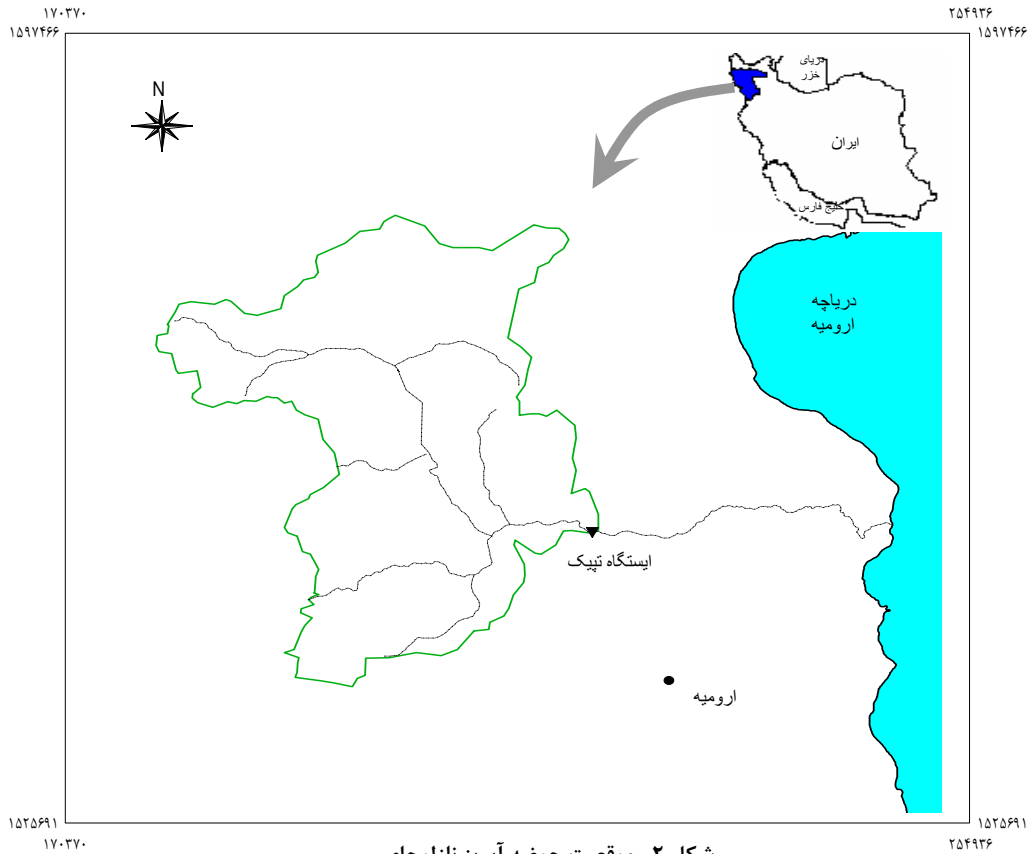
<sup>۲</sup> Feedforward Neural Network

<sup>۳</sup> Levenberg-Marquardt Backpropagation


<sup>۴</sup> Gradient Descent w/Momentum Weight/bias Learning Function

<sup>۵</sup> Bias

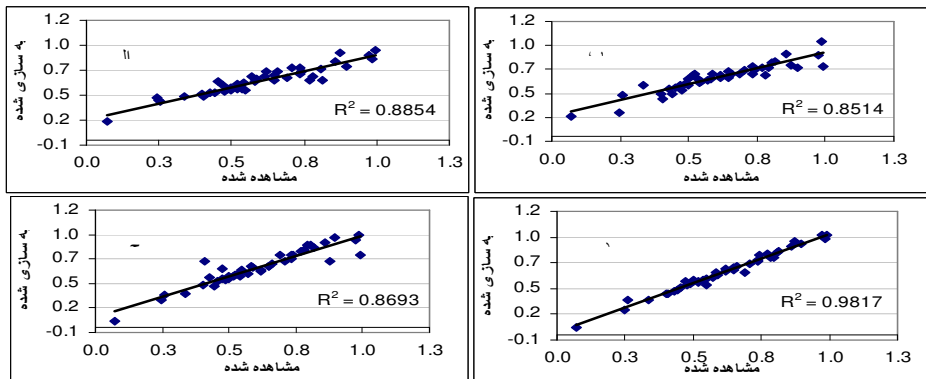
<sup>۱</sup> Hyperbolic Tangent Sigmoid Transfer Function



شکل ۲- موقعیت حوضه آبریز نازلوچای



شکل ۳- شمای شبکه عصبی مصنوعی طراحی شده برای پیش‌بینی دبی



شکل ۴- همبستگی مقادیر دبی مشاهده و شبیه‌سازی شده. شاخص‌های (الف-۴) زمستان با دبی بهار بعد، (ب-۴) پاییز با دبی بهار بعد، (ج-۴) تابستان با دبی بهار بعد و (د-۴) بهار با دبی بهار بعد

شبکه با هر اجرا این مقادیر را محاسبه و با استفاده از تفاوت مقادیر واقعی و محاسبه شده میزان خطا را محاسبه می‌کند. با تغییر وزن‌ها در مراحل بعدی میزان خطا را کاهش می‌دهد تا اینکه مقادیر نهایی به مقادیر واقعی نزدیک شود. تعیین تعداد لایه‌ها و تعداد نرون‌ها در هر لایه و همچنین نحوه ارتباط آنها با یکدیگر از مواردی است که در معماری شبکه از اهمیت برخوردار است. معیار خاصی برای تعیین تعداد لایه‌ها و تعداد نرون‌ها در لایه میانی ارائه نشده است ولی معمولاً از روش سعی و خطا استفاده می‌کنند (برای نمونه مراجعه شود به [۱۸، ۲۱]. شکل (۳) شمای شبکه عصبی طراحی شده در این تحقیق را نشان می‌دهد. این شبکه دارای یک لایه ورودی، یک لایه میانی و یک لایه خروجی است.

جدول ۱- نتایج آماری دوره آموزش با ورودی‌های (شاخص‌های SOI و NAO) فصول قبل به وسیله شبکه عصبی

فصل	NME	MSE	NRMSE	R
زمستان قبل	0.002	0.001	0.137	0.88
پاییز قبل	-0.004	0.007	0.137	0.85
تابستان قبل	-0.007	0.005	0.117	0.86
بهار قبل	-0.001	0.001	0.032	0.98

#### ۴- نتایج و بحث

##### ۴-۱- آموزش شبکه عصبی و تهیه مدل پیش‌بینی

مرحله آموزش شبکه بعد از طراحی آن است. نتایج آموزش شبکه نشان می‌دهد که بهترین حالت آموزش با ورودی‌های بهار و خروجی بهار سال بعد حاصل شده است. نتیجه آموزش برای پیش‌بینی دبی بهار با استفاده از شاخص‌های SOI و NAO برای یک، دو، سه و چهار فصل قبل در شکل (۴) نشان داده شده است.

شکل (۴) همبستگی مقادیر آموزش داده شده و مقادیر واقعی را برای بهار با استفاده از شاخص‌های بهار سال قبل نشان می‌دهد. بطوریکه در این شکل دیده می‌شود، ضریب تعیین مقادیر مشاهده شده و شبیه‌سازی شده قابل توجه است ( $R^2=0.98$ ) و حتی از سه حالت قبل یعنی زمستان، پاییز، و تابستان بیشتر است شکل (۴). میزان میانگین مربعات خطا (MSE) که یکی دیگر از معیارهای قضاوت برای مناسب بودن مدل است نیز در این حالت برابر  $0.0004$  (متر مکعب بر ثانیه به توان ۲) بوده و کمترین مقدار بین چهار حالت است. مقدار این معیار در سه حالت دیگر که از شاخص زمستان، پاییز، و تابستان قبل استفاده شده بترتیب برابر با  $0.0005$ ،  $0.0045$  و  $0.0006$  (متر مکعب بر ثانیه به توان ۲) است.

در این تحقیق، پس از بررسی‌های بسیار مشخصات شبکه بشرح زیر تعیین گردید. در این راستا، شبکه طراحی شده برای پیش‌بینی دبی رودخانه از یک لایه ورودی با دو ورودی، یک لایه میانی و یک لایه خروجی تشکیل شده است که به صورت پیش‌رو عمل می‌کند. همچنین، همانطور که در بالا اشاره شد نتایج بررسی‌ها ساختار مناسب شبکه را مشخص ساخت. براین اساس، از شبکه عصبی پیشخور چند لایه<sup>۱</sup> برای ساختار مدل و از الگوریتم پس انتشار خطا (BPE) برای به هنگام‌سازی استفاده شد. در شبکه عصبی طراحی شده دو بردار داده که در واقع شاخص‌های اقلیمی SOI و NAO فصل بهار، تابستان، پاییز و زمستان است، به‌عنوان ورودی شبکه و شاخص دبی بهار سال بعد به‌عنوان مقدار واقعی یا خروجی شبکه منظور شده است. در این شبکه از تابع TrainLM<sup>۲</sup> بعنوان تابع یادگیری برای پس انتشار خطا استفاده شد. همچنین تابع آموزش استفاده شده در این شبکه تابع آموزش LearnGDM<sup>۳</sup> که از گرادیان نزولی با استفاده از وزن‌ها و اریب<sup>۴</sup> استفاده می‌کند. شبکه با هر اجرا این مقادیر را محاسبه و با استفاده از تفاوت مقادیر واقعی و محاسبه شده میزان خطا را محاسبه می‌کند. با تغییر وزن‌ها در مراحل بعدی میزان خطا را کاهش می‌دهد تا اینکه مقادیر نهایی به مقادیر واقعی نزدیک شود.

تعیین تعداد لایه‌ها و تعداد نرون‌ها در هر لایه و همچنین نحوه ارتباط آنها با یکدیگر از مواردی است که در معماری شبکه از

<sup>۱</sup> Feedforward Neural Network

<sup>۲</sup> Levenberg-Marquardt Backpropagation

<sup>۳</sup> Gradient Descent w/Momentum Weight/bias Learning Function

<sup>۴</sup> Bias

جدول (۱) نتایج آماری دوره آموزش شبکه با استفاده از شاخص‌های فصول قبل را نشان می‌دهد. چنان که مشاهده می‌شود مدلی که از شاخص‌های فصل بهار قبل استفاده می‌کند بر اساس معیارهای مختلف عملکرد مناسبتری دارد. با استفاده از شاخص SOI و NAO و مدل  $ARIMA^1$  نیز دبی بهار شبیه سازی که نتایج آن در جدول (۲) ارائه شده است. چنانچه جدول (۲) نشان می‌دهد  $R^2$  بدست آمده از مدل‌های مختلف  $ARIMA$  بسیار کم و در بهترین حالت  $ARIMA(2,0,1)$  برابر  $0/13$  است که در مقایسه با  $R^2$  بدست آمده توسط شبکه عصبی بسیار کمتر است. همچنین مقادیر پیش‌بینی شده توسط مدل  $ARIMA$  در شکل (۵) نشان داده شده است. چنانچه شکل (۵) نشان می‌دهد مقادیر پیش‌بینی شده با مقادیر اندازه‌گیری شده تفاوت قابل توجه دارد، مضافاً اینکه روند تغییرات نیز در مقادیر پیش‌بینی شده دیده نمی‌شود.

جدول ۲- دقت نتایج شبیه سازی مدل  $ARIMA$

ردیف	$R^2$	ARIMA
1	0.000	1,1,1
2	0.070	1,0,1
3	0.003	1,1,0
4	0.131	2,0,1
5	0.007	2,1,1
6	0.010	2,1,2
7	0.112	2,0,2
8	0.120	1,0,2

جدول ۲- دقت نتایج شبیه سازی مدل  $ARIMA$

ردیف	$R^2$	ARIMA
1	0.000	1,1,1
2	0.070	1,0,1
3	0.003	1,1,0
4	0.131	2,0,1
5	0.007	2,1,1
6	0.010	2,1,2
7	0.112	2,0,2
8	0.120	1,0,2

هر یک از پارامترهای جدول (۱) با استفاده از معادلات ۳ تا ۷ محاسبه شده است.

$$ME = Q_f - Q_m \quad (3)$$

$$NME = ME / Q_m \quad (4)$$

$$MSE = 1/n * \sum (Q_f - Q_i)^2 \quad (5)$$

$$NRMSE = MSE / Q_m \quad (6)$$

$$R^2 = 1 - (\sum (Q_f - Q_i)^2) / (\sum (Q_f - Q_m)^2) \quad (7)$$

#### ۴-۲- آزمون شبکه عصبی

با توجه به نتایج مرحله آموزش، مناسبترین گزینه برای پیش‌بینی دبی متوسط فصل بهار استفاده از شاخص‌های بهار سال قبل است. در اینجا این گزینه مورد آزمایش قرار می‌گیرد. آزمون یکی از مراحل مهم طراحی شبکه عصبی است. منظور از آزمون شبکه، بررسی عملکرد واقعی مدل کالیبره شده می‌باشد، بطوریکه مشخص شود مدل در حد لازم آموزش دیده، وزن‌ها تثبیت شده، شبکه در خطاهای محلی متوقف نشده، و بالاخره شبکه دچار افراط برآزش<sup>۲</sup> نگردیده است. مهمترین معیار مورد استفاده برای ارزیابی عملکرد شبکه، میانگین مربعات خطاست. بدیهی است که میانگین مربعات خطا باید کم باشد، اما در همان حال فوق برآزش نیز رخ ندهد. برای این منظور آموزش شبکه زمانی متوقف می‌شود که منحنی خطای آزمون به حداقل برسد و به عبارت دیگر MSE مربوط به ارزیابی در حال افزایش باشد. در این حالت وزن‌ها تثبیت شده و شبکه آماده است تا با وارد کردن بردار ورودی جدید که قبلاً در آموزش استفاده نشده است، مقادیر متناظر آن را پیش‌بینی کند. با توجه به اینکه در هر بار که شبکه آموزش می‌بیند، وزن‌های نهایی شده تفاوت داشته و به طبع آن مقادیر دبی محاسبه شده نیز باهم متفاوتند، معمولاً حالت بهتر برای پیش‌بینی آن حالتی را در نظر می‌گیرند که در دوره آموزش ضریب دترمینان آن بیشتر و مجموع مربعات خطای آن کمتر باشد [۱۸].

لکن بررسی‌ها در این کاربرد نشان داد که مقدار متوسط چندین اجرا دارای دقت بیشتری است. بر همین اساس، در این بررسی میانگین پیش‌بینی حاصل از چندین اجرا بعنوان مقادیر پیش‌بینی شبکه در نظر گرفته شده است. دبی مشاهده و متوسط مقادیر پیش‌بینی شده فصل بهار به همراه خطای پیش‌بینی در جدول (۳) نشان داده شده است.

نتایج پیش‌بینی دبی بهار که برای سال‌های ۱۹۹۵ الی ۱۹۹۹ انجام شده است، نشان می‌دهد که علیرغم فاصله یکساله، پیش‌بینی‌ها از دقت نسبتاً خوبی برخوردار بوده و به مقادیر واقعی نزدیکند. این موضوع در شکل‌های (۶) و (۷) نیز بخوبی

<sup>2</sup> Over fitting

<sup>1</sup> Auto Regression Moving Average



طولانی یکساله بین زمان پیش‌بینی و وقوع، نتایج حاصله بسیار مطلوب است. بررسی‌ها نشان می‌دهد نتایجی با این دقت حاصل نشده است. انتظار می‌رود با توجه به ناتمام بودن تحقیق حاضر، بهبودهای بیشتری در ادامه تحقیق حاصل شود.

**جدول ۴- نتایج آماری دوره آموزش و ارزیابی برای دبی بهار با استفاده از شاخص‌های بهار سال قبل.**

دوره	پارامترهای آماری	NME (بدون بعد)	MSE (m <sup>3</sup> /s) <sup>2</sup>	NRMSE (بدون بعد)	R <sup>2</sup>
آموزش		-0.001	0.001	0.032	0.98
ارزیابی (پیش‌بینی)		-0.337	0.044	0.441	0.92


در این مرحله، پیش‌بینی دبی فصول تابستان و پاییز و زمستان، نتایج غیر قابل قبولی ارائه کرده است. با توجه به اینکه دبی بهار در رودخانه مورد نظر، نزدیک به ۸۰ درصد آورد سالانه را به خود اختصاص داده است، بنابراین، اهمیت پیش‌بینی دبی بهار برای این حوضه ارزش فوق‌العاده‌ای دارد و حتی عدم پیش‌بینی ۲۰ درصد باقیمانده مانعی برای برنامه‌ریزی بر اساس این پیش‌بینی نخواهد بود.

آشکار است. همچنان که جدول (۲) نشان می‌دهد، تفاوت مقادیر پیش‌بینی شده برای سال ۱۹۹۹ از بقیه سال‌ها بیشتر است که دلیل آن تفاوت زیاد دبی واقعی با میانگین دراز مدت این سال است بطوریکه سال ۱۹۹۹ جزو یکی از سال‌های استثنایی و خشکترین سال‌ها در بین سال‌های آماری در این ایستگاه است.


**جدول ۳- مقایسه مقادیر مشاهده و پیش‌بینی دبی بهار**

عنوان	دبی متوسط بهار (متر مکعب بر ثانیه)				
سال	1995	1996	1997	1998	1999
دبی بهار مشاهده	61.5	30.0	34.2	15.8	8.8
دبی بهار پیش‌بینی	64.9	26.9	39.6	19.8	21.9
خطا	3.4	-3.1	5.4	4.0	13.1


جدول شماره (۴) متوسط نتایج آماری شبکه عصبی را در دوره آموزش و ارزیابی نشان می‌دهد. همانطور که در این جدول مشاهده می‌شود، ضریب R<sup>2</sup> مقادیر پیش‌بینی شده ۰/۹۲ و از مقدار آن در آموزش کمتر است. همچنین، ضرایب دیگر دوره پیش‌بینی (ارزیابی) نیز که بیانگر خطا است از حالت آموزش بیشتر است. افزایش ضرایب خطا و کاهش همبستگی در مرحله ارزیابی امری طبیعی است. در مجموع، با توجه به فاصله



**شکل ۵- دبی پیش‌بینی با استفاده از مدل ARIMA (2,0,1)**



**شکل ۶- مقایسه دبی متوسط مشاهده و پیش‌بینی شده فصل بهار توسط شبکه عصبی (ایستگاه تپیک)**



شکل ۷- همبستگی بین دبی متوسط مشاهده و پیش‌بینی شده فصل بهار توسط شبکه عصبی (ایستگاه تپیک)

### ۵- نتیجه‌گیری

بطور معمول، پیش‌بینی دبی رودخانه‌ها فقط برای یک یا چند روز انجام می‌شود و پیش‌بینی برای یک سال بعد رودخانه با استفاده از بارندگی یا عوامل دیگر امکان پذیر نیست. این پیش‌بینی با استفاده از شاخص‌های اقلیمی و با روش همبستگی نیز بخاطر روابط پیچیده پدیده‌های اقلیمی با آورد رودخانه از دقت زیادی برخوردار نیست. حتی استفاده از شبکه عصبی نیز در مطالعات گذشته به نتایج مطلوبی منجر نشده است.

اگرچه مطالعات گذشته در سطح جهان غالباً بر محور بررسی روابط بین شاخص‌های اقلیمی و بارش بوده، اما اندک مطالعاتی نیز که پیش‌بینی جریان را مدنظر قرار داده نهایتاً به روش‌های غیردقیق و احتمالاتی نظیر ESP<sup>1</sup> روی آورده است. علت این امر، عدم دستیابی به نتایج قوی بین شاخص‌ها و جریان و یا بارش در این گونه مطالعات است. در مطالعاتی که در حوضه آبریز نالوچای انجام گرفت اگر چه در ابتدا نتایج حاصله ضعیف و غیرقابل استفاده برای پیش‌بینی بود لکن تحقیقات و تلاش‌های بعدی و بررسی انواع روش‌های گذشته و نیز استفاده مناسب از روش شبکه عصبی منجر به نتایج قابل قبول، و بعضاً دور از انتظار، در این حوضه شد. نظر به دوری فاصله کانون پدیده انسو و نیز NAO از ایران، انتظار نمی‌رفت ارتباطاتی تا این حد قوی بین آنها و جریان‌های رودخانه در ایران وجود داشته باشد. براساس نتایج این تحقیق می‌توان با بکارگیری شبکه عصبی و با استفاده از شاخص‌های اقلیمی یکسال قبل، دبی یک سال بعد را با دقت مناسبی پیش‌بینی نمود. همبستگی بین دبی مشاهده و پیش‌بینی نشان می‌دهد که

مقایسه دبی مشاهده، آموزش داده شده، و پیش‌بینی شده نشان می‌دهد شبکه عصبی با دقت بسیار خوبی توانسته پیش‌بینی درازمدت دبی بهار رودخانه را انجام دهد. این در حالی است که نتایج پیش‌بینی توسط مدل ARIMA از دقت بسیار پایینی برخوردار است که دلیل آن عدم وجود رابطه خطی بین شاخص‌های SOI و NAO با دبی در همه سال‌های آماری است. ضرایب تعیین بدست آمده در این تحقیق برای دوره آموزش و آزمون به ترتیب ۰/۹۸ و ۰/۹۲ است. مقایسه ضریب تعیین بین مقادیر مشاهده و پیش‌بینی (دوره آزمون) نشان می‌دهد که مقدار آن از ضرایب تعیین حاصل از پیش‌بینی بارندگی یک سال بعد که توسط سیلورمن و دراکوب [۱۸] با استفاده از شبکه عصبی و شاخص‌های اقلیمی انجام شده است، برتر است (0.6 < R < 0.85). دانچه و همکاران [۱۰] نیز در پیش‌بینی دبی رودخانه با استفاده از شبکه عصبی، با ورودی‌های بارندگی، تبخیر و دبی یک روز قبل برای دوره آموزش و آزمون ضرایب تعیین را به ترتیب برابر با ۰/۹۹ و ۰/۹۶ بدست آوردند. همچنین تینگسانچالی و گواتام [۲۲] در یک کار مشابه برای پیش‌بینی دبی یک روز بعد با استفاده از شبکه عصبی ضرایب تعیین دوره آموزش و آزمون را به ترتیب ۰/۹۹ و ۰/۹۲ بدست آوردند. لازم به ذکر است که نتایج دانچه و همکاران [۱۰] و تینگسانچالی و گواتام [۲۲] مربوط به پیش‌بینی یک روز بعد است. مضافاً آنکه حتی نتایج نه چندان خوب سیلورمن و دراکوب [۱۸] مربوط به پیش‌بینی بارش است و همانطور که ذکر شد در پیش‌بینی دبی حتی در مناطق آمریکای شمالی که در مجاورت پدیده انسو قرار دارند، نتایجی با این دقت مشاهده نمی‌شود.

<sup>1</sup> Ensemble Streamflow Prediction

- [8] Connely, K. B. 2001. Final report: Phase II Long-Range Streamflow Forecasting Using Climate Information. Utah State University, Utah Water Research Laboratory, Logan, Utah, 24pp.
- [9] Cullen, H. M., A. Kaplan, P. A. Arkin and P. B. Demenocal, 2002. Impact of the North Atlantic Oscillation on midele eastern climate and streamflow. *Climatic change* 55:315-338.
- [10] Danh, N. T., H. N. Phien and A. D. Gupta. 1999. Neural Network Model for River Flow Forecasting. *Water South Africa*. 25(1): 33-39.
- [11] Grimm, A. M., S. E. T. Ferraz, and J. Gomes. 1998: Precipitation anomalies in southern Brazil associated with El Nino and La Nina events. *Journal of Climate*, 11, 2863-2880.
- [12] Hamlet, A. F. and P. L. Lettenmaier, 1999. Columbia River Streamflow Forecasting Based on ENSO and PDO Climate Signals. *ASCE, J. Water Reso. Plan. Manag.*. 125(6):333-341.
- [13] Hughes, B. L. and A. M. Saunders. 2001. European drought climatology and prediction using the standardized precipitation index, 13th Conference on Applied Climatology. Available at: <http://www.ametsoc.org/>.
- [14] Nazemosadat, M. J., A. R. Ghasemi, and, H. Cordery. 2003. The linkage between precipitation in Iran and NSW Australia. Third Regional and First National Conference on Climate Change, Isfahan, Iran.
- [15] Nicholson, S. E. 2001. The Relationship between El-Nino and drought. *Journal of Climate*. 14:323-335.
- [16] Pisciotto G. J., A. F. Dias and C. R. Mechoso. 1994. EL Nino Southern Oscillation impact on rainfall in Uruguay. *Journal of Climate*, 7, 1286-1302.
- [17] Shamseldin, A. Y. 1997. Application of a Neural Network Technique to Rainfall-Runoff modeling. *Journal of Hydrology*, 199(3-4): 272-294.
- [18] Silverman, D. and J. A. Dracup. 2000. Artificial neural network and long range precipitation prediction in California, *Journal of Applied Meteorology*, 39(1): 57-59.
- شبکه عصبی به خوبی نوسانات شاخص‌های SOI و NAO را بر دبی رودخانه شبیه‌سازی کرده است. نتایج آموزش شبکه نشان می‌دهد که تأثیر شاخص‌های اقلیمی فصل تابستان، پاییز و زمستان بر دبی فصل بهار بعد در مقایسه با بهار قبل کمتر است. بنابراین شبکه طراحی شده قادر است با استفاده از شاخص‌های بهار سال جاری مقادیر دبی را برای بهار سال بعد با دقت مناسب پیش‌بینی کند.
- ### سپاسگزاری‌ها
- از سازمان مدیریت منابع آب ایران به خاطر پشتیبانی مالی این تحقیق قدردانی می‌شود.
- ### مراجع
- [۱] رضایی، ع. ۱۳۸۳. مدل‌سازی منطقه‌ای دبی‌های اوج زیر حوضه‌های آبخیز سد سفیدرود با استفاده از شبکه‌ها عصبی مصنوعی. رساله دکتری، دانشکده منابع طبیعی دانشگاه تهران.
- [۲] غیور، ح. و م. خسروی. ۱۳۸۰. تأثیر پدیده انسو بر ناهنجاری‌های بارش تابستانی و پاییزی منطقه جنوب شرقی ایران. فصلنامه تحقیقات جغرافیایی شماره ۵۲۳.
- [۳] فاتحی مرج، ا.، ع. برهانی و م. ح. مهدیان. الف ۱۳۸۵. پیش‌بینی فصلی جریان رودخانه‌های دریاچه ارومیه با استفاده از شاخص‌های اقلیمی. *مجله پژوهش و سازندگی*، شماره ۷۱.
- [۴] فاتحی مرج، ا.، ع. برهانی و م. ح. مهدیان. ب ۱۳۸۵. پیش‌بینی بارش با استفاده از پیوند از دور. *مجله علوم و فنون کشاورزی*، دانشگاه صنعتی اصفهان، شماره ۳.
- [۵] منهج، م. ۱۳۸۱. مبانی شبکه‌های عصبی، جلد اول چاپ دوم، مرکز نشر دانشگاه صنعتی امیرکبیر.
- [۶] ناظم السادات، م. ج. ۱۳۸۰. آیا باران می‌بارد؟ خشکسالی و بارندگی مازاد در ایران و ارتباط آنها با پدیده النینو-نوسان جنوبی. شیراز، انتشارات دانشگاه شیراز.
- [7] Ames, D.I P. 1998. Seasonal to Inter Annual Streamflow Forecasts Using Nonlinear Time Series Methods and Climate Information. MSc. Thesis, Civil and Environmental Engineering, Utah State University, Logan, Utah

- Surface Temperatures by Neural Network Models. *Journal of Climate Dynamics*, 13: 135-147.
- [22] Tingsanchali, T. and M. R. Gautam. 2000. Application of Tank, NAM, ARMA and Neural Network Models to Flood Forecasting. *Hydrological Process*. 14: 2473-2487.
- [23] Tootle G. A. and T. C. Piechota. 2004. Forecasting of Lower Colorado River Basin Streamflow using Pacific Ocean Sea Surface Temperatures and ENSO. *World Water Congress*, Salt Lake City, Utah, USA.
- 66.
- [19] Souza Filho F. A., and U. Lall, 2003. Seasonal to interannual ensemble streamflow forecasting for Ceara Brazil. *J. water resources Research*, 39(11): 1307-1320
- [20] Sveinsson Oli G. B. ,J. D. Salas, D. C. Boes, and R. A. Pielke SR. 2003. Modelling the dynamics of long- term variability of hydroclimatic processes. *J. of Hydrology*. 7: 489-501.
- [21] Tangang, F. T., W. W. Hsieh and B. Tang. 1997. Forecasting the Equatorial Pacific Sea