

## مقایسه عملکرد مدل‌های هوش مصنوعی در تخمین پارامترهای کیفی آب رودخانه در دوره‌های کم‌آبی و پرآبی

مجید منتصری<sup>\*1</sup> - سروین زمان زاد قویدل<sup>2</sup>

تاریخ دریافت: 1392/03/20

تاریخ پذیرش: 1395/04/28

### چکیده

وقوع متناوب دوره‌های کم‌آبی و پرآبی در حوضه آبریز زربنه رود علاوه بر تأثیر روی وضعیت کمی آب‌های سطحی، باعث تغییراتی در کیفیت آب این حوضه شده است. لذا، مدل‌بندی و پیش‌بینی پارامترهای کیفی آب رودخانه زربنه رود در دوره‌های کم‌آبی و پرآبی، یکی از ضرورت‌های تحقیقاتی در این رودخانه پرآب شمال غرب ایران بوده است. در این مطالعه، روش‌های شبکه‌های عصبی مصنوعی به ازای پنج الگوریتم آموزشی مختلف و سامانه استنتاجی عصبی-فازی تطبیقی مبتنی بر مدل دسته‌بندی تفریقی، جهت تخمین میزان جامدات محلول TDS به کار گرفته شدند. بدین منظور از داده‌های کیفیت آب هفت ایستگاه هیدرومتری در حوضه آبریز مذکور با طول دوره آماری 18 ساله (1372-1389) استفاده گردید. ابتدا دوره مطالعاتی مذکور بر اساس میزان جریان در رودخانه به دو دوره کم‌آبی و پرآبی تفکیک شده، سپس در یک آنالیز اولیه آماری، پارامترهای مؤثر اصلی در تخمین TDS تعیین و برای مدل‌بندی استفاده گردید. برای مدل‌بندی 75 درصد داده‌ها برای کالیبره کردن و 25 درصد برای ارزیابی مدل استفاده شده است. ارزیابی عملکرد مدل‌های به کار رفته بر اساس آزمون‌های آماری مختلف، ضریب همبستگی، ریشه میانگین مربعات خطا و میانگین قدر مطلق خطا انجام گرفت. نتایج حاصل حاکی از عملکرد قابل قبول هر دو روش شبکه‌های عصبی مصنوعی با الگوریتم آموزشی لونیگ-مارگارت و سامانه استنتاجی عصبی-فازی تطبیقی در دوره‌های کم‌آبی و پرآبی بود. مقایسه عملکرد روش‌های به کار گرفته شده، نشان داد که عملکرد روش عصبی-فازی تطبیقی در هر دو دوره مطالعاتی بهتر از شبکه‌های عصبی مصنوعی می‌باشد.

**واژه‌های کلیدی:** جامدات محلول، زربنه رود، سامانه استنتاجی عصبی-فازی تطبیقی، شبکه عصبی مصنوعی

### مقدمه

بدلیل تغییرات کمی آب رودخانه و اثر مؤثر آن در پتانسیل خود پالایشی رودخانه‌ها، تغییرات قابل توجهی در فصول کم‌آبی و پرآبی در نقاط مختلف دنیا نشان داده که این موضوع در مطالعات متعدد گزارش شده و ذیلاً مواردی از آن آورده شده است. پارک و همکاران (28) با بررسی تأثیرات تغییر اقلیم بر کیفیت آب به این نتیجه دست یافتند که تغییرات در میزان بارش برف و بارندگی‌های تابستانی در ارتباط با تغییرات اقلیمی در شمال شرق آسیا تأثیرات معنی‌داری بر کیفیت آب‌های سطحی دارد. هردینکا و همکاران (15) با بررسی اثرات دوره‌های کم‌آبی و پرآبی بر کیفیت آب رودخانه‌های واقع در بوهیمیا به این نتیجه رسیدند که هر دو دوره کم‌آبی و پرآبی تأثیرات معنی‌داری بر کیفیت آب‌های سطحی دارد. ساداتی و همکاران (30) اقدام به بررسی وضعیت کمی و کیفی رودخانه گرگر با استفاده از نمونه‌گیری و آزمایشات در چند ایستگاه مهم در مسیر این رودخانه کردند. آن‌ها دریافتند که با توجه به وقوع دوره‌های کم‌آبی علاوه بر کاهش آبدی رودخانه، کیفیت آب نیز افت

رودخانه‌ها بعنوان یکی از منابع اصلی آب شیرین جهت تأمین مصارف مختلف از جمله آب شرب، کشاورزی و محیط زیست، از پایه‌های اساسی توسعه پایدار جوامع انسانی در دنیای امروز محسوب می‌شوند. این در حالی است که پیشرفت‌های صنعتی و رفاهی همراه با افزایش جمعیت، موجب افزایش تنش‌های فزاینده‌ای بر کمیت و کیفیت آب رودخانه‌ها در اکثر نقاط دنیا گردیده و موجودیت رودخانه‌ها این منابع حیاتی و با ارزش را در معرض تهدید و خطر قرار داده است. لذا ارزیابی و مدل‌سازی کمی و کیفی جریان‌های رودخانه‌ای و نحوه تغییرات زمانی و مکانی آنها مخصوصاً کیفیت آب رودخانه‌ها، بدلیل تأثیر کاملاً مستقیم از فعالیت‌های انسانی اهمیت ویژه‌ای در مطالعات منابع آب را بخود اختصاص داده است (26). کیفیت آب رودخانه‌ها

1 و 2 - دانشیار و دانشجوی دوره دکتری گروه مهندسی آب، دانشگاه ارومیه

\* - نویسنده مسئول: (Email: m.montaseri@urmia.ac.ir)

DOI: 10.22067/jsw.v30i6.22357

آب در مخزن سدی در کشور تایلند مورد استفاده قرار دادند. آن‌ها از مقادیر ساعتی سطح آب در ساعات پیشین در مخزن به منظور پیش-بینی سطح آب در ساعات آتی استفاده کردند و چنین عنوان نمودند که روش فازی-عصبی دقت قابل قبولی در پیش‌بینی سطح آب مخزن در سه ساعت بعدی داشت. سنگرور و همکاران (33) از روش شبکه عصبی مصنوعی برای تخمین میزان غلظت اکسیژن محلول در آب رودخانه ملن<sup>7</sup> ترکیه استفاده کردند. بر اساس نتایج به دست آمده ضریب همبستگی بین مقادیر اندازه‌گیری شده و داده‌های حاصل از مدل بیش‌تر از 0/92 برآورد شد. نجاح و همکاران (27) توانایی شبکه عصبی را در پیش‌بینی شاخص‌های کیفی آب رودخانه جوهر<sup>8</sup> مالزی و توانایی برآورد مقدار EC و TDS و کدورت در این حوزه را مورد تأکید قرار دادند. ساین و همکاران (34) از شبکه‌های عصبی مصنوعی برای مدل‌سازی میزان اکسیژن محلول و اکسیژن مورد نیاز بیولوژیکی در رودخانه گمتی<sup>9</sup> هند استفاده کردند. نتیجه این تحقیق منجر به ارائه روش شبکه عصبی مصنوعی به عنوان یکی از روش‌های قابل استفاده با عملکرد مناسب برای برآورد پارامترهای کیفی شد. کریمی و همکاران (18) جهت پیش‌بینی تغییرات روزانه سطح تراز آب دریاچه داروین هاربر<sup>10</sup> استرالیا از روش‌های شبکه عصبی مصنوعی و سامانه استنتاجی عصبی - فازی تطبیقی به ترتیب با الگوریتم‌های آموزشی و نوع تابع عضویت مختلف استفاده کردند. آن‌ها گزارش کردند که الگوریتم آموزشی لونیبرگ-مارگارت در روش شبکه عصبی مصنوعی و تابع عضویت مثلثی در روش سامانه استنتاجی عصبی فازی تطبیقی بهترین عملکرد را در فواصل زمانی مختلف برای پیش‌بینی تراز آب دریاچه مذکور را دارند. پورعلی بابا و همکاران (29) با استفاده از پارامترهای هواشناسی درجه حرارت، ساعت آفتابی، سرعت باد و رطوبت نسبی اقدام به تخمین میزان تبخیر و تعرق روزانه دو ایستگاه هواشناسی کره جنوبی با روش‌های شبکه عصبی مصنوعی و سامانه استنتاجی عصبی - فازی تطبیقی نمودند که بر اساس نتایج به دست آمده هر دو روش به عنوان روش‌های قابل استفاده و مطلوب برای تخمین میزان تبخیر و تعرق روزانه معرفی شدند.

بطور کلی تکنیک‌های هوش مصنوعی بعنوان روش‌های نوین ساده و با ارجحیت نسبی نسبت به روش‌های پیچیده و مفصل سنتی، دارای قابلیت کاربرد در مدل‌سازی کیفیت آب رودخانه‌ها بوده و می‌تواند همراه با کاهش اندازه‌گیری‌های مستقیم پارامترهای کیفیت آب، در برنامه‌ریزی و مدیریت بهینه کیفیت آب رودخانه نقش مهمی را ایفا نماید. لذا در این مطالعه، به دلیل پیچیدگی و تعدد فرآیندهای

کرده است. لشنی‌زند و همکاران (24) اقدام به بررسی اثرات دوره‌های کم‌آبی و پرآبی بر کیفیت آب‌های سطحی حوضه آبریز کشکان کردند که نتایج حاصله نشان داد که رابطه معنی‌داری بین دوره‌های کم‌آبی و پرآبی با کیفیت شیمیایی آب وجود دارد. دادفر و همکاران (8) در بررسی ارتباط بین پارامترهای کیفیت شیمیایی آب و جریان رودخانه به این نتیجه رسیدند که در همه موارد رابطه بین پارامترهای کیفی آب و دبی معنی‌دار بوده به طوری که در سال‌های خشکسالی که دبی کاهش می‌یابد، به همان اندازه کیفیت شیمیایی آب نیز تحت تأثیر قرار می‌گیرد و کاهش می‌یابد.

از طرفی، تعداد زیادی از پارامترهای مؤثر بر کیفیت آب دارای رابطه پیچیده‌ی غیرخطی با یکدیگر می‌باشند که روش‌های سنتی عملکرد مناسبی برای حل این چنین مسائلی نداشته‌اند (34، 35 و 36). در سال‌های اخیر استفاده از مدل‌های هوش مصنوعی<sup>1</sup> در زمینه‌های مختلف مهندسی آب مورد توجه بسیاری قرار گرفته و قابلیت مهم این قبیل مدل‌ها درک رفتار غیرخطی پدیده‌ها و فرآیندهایی است که تعریف دقیق و درک خاصی از رفتار آن‌ها وجود ندارد (7، 23، 19، 20، 11، 12، 10 و 31). شبکه‌های عصبی مصنوعی<sup>2</sup> و سامانه استنتاجی عصبی- فازی تطبیقی<sup>3</sup> به همراه دو روش افزاز شبکه<sup>4</sup> و دسته‌بندی تفریقی<sup>5</sup>، نمونه‌های بارزی از مدل‌های هوش مصنوعی هستند که در سال‌های اخیر مورد توجه بسیاری از محققین در سیستم‌های آبی قرار گرفته است. تاکنون تحقیقات متعددی با استفاده از روش‌های هوش مصنوعی برای مدل‌بندی و پیش‌بینی پدیده‌های مختلف هیدرولوژیکی از جمله پارامترهای کیفیت آب، میزان بار رسوب رودخانه، تبخیر از سطح آزاد آب، تبخیر و تعرق پتانسیل گیاه مرجع، بارندگی، رواناب، دبی سیل ورودی به مخازن و ... انجام شده است (32). با این وجود به کارگیری روش عصبی- فازی تطبیقی (مدل دسته‌بندی تفریقی) در مقایسه با سایر روش‌های هوش مصنوعی، به طور محدود در پژوهش‌های مختلف سیستم‌های آبی در منابع گزارش شده است. ذیلا مروری اجمالی از کاربرد روش‌های ذکر شده در مطالعات مختلف سیستم‌های منابع آب ارائه شده است.

چانگ و چن (4) از مدل فازی-عصبی به منظور پیش‌بینی جریان رودخانه داچا<sup>6</sup> در مرکز تایلند استفاده نمودند. آن‌ها جهت مدل‌سازی از داده‌های بارش و جریان استفاده کردند. نتایج بدست آمده حاکی از عملکرد بهتر روش فازی-عصبی در مقایسه با مدل‌های سری زمانی بود. چانگ و چانگ (3) مدل فازی-عصبی را به منظور تخمین سطح

1- Artificial Intelligence Methods

2- Artificial Neural Networks (ANNs)

3- Adaptive neuro fuzzy inference system (ANFIS)

4- Grid Partitioning (ANFIS-GP)

5- Subtractive Clustering (ANFIS-SC)

6- Dacha

7- Melen

8- Johor

9- Gomti

10- Darwin Harbor

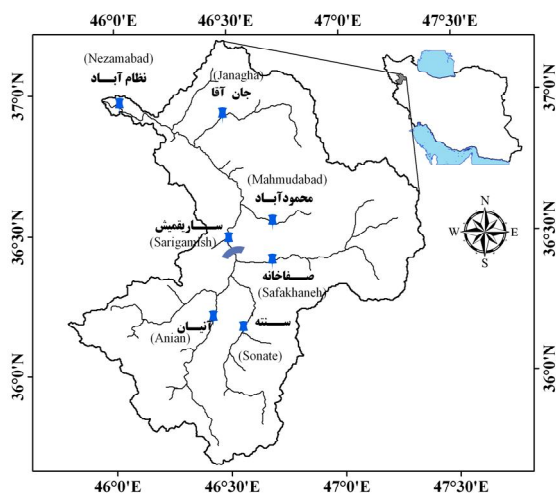
مشترک 18 ساله، به عنوان ایستگاه‌های مبنا استفاده شده است. موقعیت جغرافیایی حوضه آبریز زرينه‌رود و مشخصات عمومی ایستگاه‌های هیدرومتری مبنا در شکل 1 و جدول 1 آمده است. در این مطالعه، جهت تخمین پارامتر کیفی TDS، دوره مطالعاتی 18 ساله (1372-1389) براساس جریان‌های رودخانه‌ای، به دوره‌ها یا فصول کم‌آبی و پرآبی تقسیم‌بندی شد که 5 ماه از سال (ماه‌های خرداد، تیر، مرداد، شهریور، مهر) به عنوان دوره یا فصل کم‌آبی و 7 ماه از سال (ماه‌های آبان، آذر، دی، بهمن، اسفند، فروردین، اردیبهشت) به عنوان دوره یا فصل پرآبی در نظر گرفته شد. داده‌ها کیفیت آب رودخانه زرينه‌رود با مجموع تعداد 776 نمونه در ایستگاه‌های مبنا برای دوره آماری 1372 الی 1389 در دسترس بوده و حداکثر تعداد نمونه مربوط به ایستگاه آنیان در دوره پرآبی و حداقل تعداد نمونه مربوط به ایستگاه‌های جان‌آقا و محمودآباد در دوره کم‌آبی می‌باشد (جدول 1). این نمونه‌ها شامل پارامترهای بی‌کربنات ( $\text{HCO}_3^-$ )، کلرید ( $\text{Cl}$ )، سولفات ( $\text{SO}_4$ )، کلسیم ( $\text{Ca}$ )، منیزیم ( $\text{Mg}$ )، سدیم ( $\text{Na}$ )، جامدات محلول (TDS) و دبی جریان رودخانه است. جدول 2 مشخصات آماری پارامترهای مختلف کیفیت آب رودخانه زرينه‌رود را به‌زای داده‌های هفت ایستگاه مبنا در دو دوره کم‌آبی و پرآبی نشان می‌دهد. با توجه به جدول 2 مشاهده می‌شود که ضریب تغییرات پارامتر کیفی TDS در دو دوره مطالعاتی قابل توجه بوده و این تغییرات در دوره‌های کم‌آبی بیشتر از دوره‌های پرآبی می‌باشد. همچنین میانگین غلظت تمامی پارامترهای کیفیت آب در دوره مطالعاتی کم‌آبی بیشتر از دوره مطالعاتی پرآبی بوده، که این امر نشانگر وجود رابطه معکوس بین پارامترهای کیفیت آب با جریان رودخانه می‌باشد.

کیفی منابع آب سطحی، با استفاده از روش‌های هوش مصنوعی که قابلیت فراگیری و درک روابط حاکم بر این گونه فرآیندها را بدون نیاز به معادلات حاکم دارد، روشی نوین جهت مدل‌بندی و پیش‌بینی میزان جامدات محلول در شبکه رودخانه‌ای حوضه آبریز زرينه‌رود، به عنوان یکی از حوضه‌های آبریز مهم و پرآب منطقه و کشور و منبع اصلی تأمین آب کشاورزی دشت‌های میاندوآب و رحیم‌خان و آب شرب شهرهای تبریز و سقز در دوره یا فصول کم‌آبی و پرآبی ارائه شده است.

## مواد و روش‌ها

### حوضه آبریز و داده‌ها

رودخانه پرآب زرينه‌رود، رواناب‌های سطحی حوضه آبریز وسیع زرينه‌رود با وسعتی برابر 13685 کیلومتر مربع در جنوب دریاچه ارومیه را زهکشی نموده و در مسیر خود تقاضاهای متعدد از مصارف مختلف شرب و کشاورزی را تأمین کرده و در نهایت به دریاچه ارومیه تخلیه می‌شود. اکثریت محدوده بالادست حوضه آبریز زرينه‌رود در مناطق کوهستانی و بسیار مرتفع قرار گرفته و دارای زمستان بسیار سرد و پربرف و تابستان ملایم و خشک است و از نظر اقلیمی جز مناطق استپی سرد طبقه‌بندی می‌شود (1). حوضه آبریز زرينه‌رود دارای 14 ایستگاه هیدرومتری بوده که توسط شرکت آب منطقه‌ای آذربایجان غربی تأسیس و مورد بهره‌برداری قرار می‌گیرند. داده‌های کیفیت آب در تمامی ایستگاه‌های مذکور در دسترس نبوده، تنها تعداد ایستگاه هیدرومتری محدودی دارای آمار با کیفیت و کمیت مناسب داده‌های کیفیت آب رودخانه می‌باشند. لذا در این تحقیق از داده‌های هفت ایستگاه هیدرومتری با کیفیت مناسب و طول دوره آماری



شکل 1- موقعیت جغرافیایی ایستگاه‌های آب‌سنجی مبنا رودخانه زرينه رود در محدوده مطالعاتی

Figure 1- Geographical location of selected hydrometric stations in study area

جدول 1- مشخصات عمومی حوضه آبریز زربینه رود در ایستگاه‌های هیدرومتری مبنا

Table 1- General characteristics of Zarrineh River basin in selected hydrometric stations

ایستگاه Station	نام رودخانه River	مساحت Area (km <sup>2</sup> )	ارتفاع از سطح دریا Elevation (m)	طول جغرافیایی Longitude (°E)	عرض جغرافیایی Latitude (°N)	تعداد نمونه Number of samples	
						دوره کم‌آبی Dry period	دوره پرآبی Wet period
آنیان Anian	جیغاتوچای Jeghatu chay	1221	1460	46 ° 26'	36 ° 12'	27	91
سنه Sonate	خرخه‌چای Khorkhore chay	1404	1434	46 ° 33'	36 ° 10'	26	74
صفاخانه Safakhaneh	ساروق‌چای Sarug chay	2219	1475	46 ° 42'	36 ° 24'	30	84
ساریقمش Sarigamish	زربینه‌رود Zarrineh roud	7160	1380	46 ° 29'	36 ° 29'	42	80
جان‌آقا Janagha	آجرلو Ajrlu	467	1410	46 ° 28'	36 ° 57'	22	80
محمودآباد Mahmudabad	قوره‌چای Ghavre chay	384	1500	46 ° 26'	36 ° 35'	22	78
نظام‌آباد Nezamabad	زربینه‌رود Zarrineh roud	11158	1283	46 ° 56'	37 ° 03'	41	79

جدول 2- پارامترهای آماری مربوط به داده‌های ایستگاه‌های هیدرومتری مبنا حوضه آبریز زربینه‌رود

Table 2- Statistical parameters of base hydrometric stations of Zarrineh River basin

پارامترها Parameters	Q	HCO <sub>3</sub>	CL	SO <sub>4</sub>	Ca	Mg	Na	TDS
واحد Unit	(m <sup>3</sup> .s <sup>-1</sup> )	(meq.L <sup>-1</sup> )	(meq.L <sup>-1</sup> )	(meq.L <sup>-1</sup> )	(meq.L <sup>-1</sup> )	(meq.L <sup>-1</sup> )	(meq.L <sup>-1</sup> )	(mg.L <sup>-1</sup> )
حد اقل Min	دوره‌های کم‌آبی Dry periods	0.008	1	0.1	0.1	1	0.1	130
	دوره‌های پرآبی Wet periods	0.047	0.9	0.05	0.04	1	0.1	84.5
حد اکثر Max	دوره‌های کم‌آبی Dry periods	68.11	2.6	2.8	5.6	5.8	6.5	793
	دوره‌های پرآبی Wet periods	785	8.4	4.2	5	7	2.4	676
میانگین Average	دوره‌های کم‌آبی Dry periods	7.47	3.36	0.58	1.29	2.68	52.1	303.4
	دوره‌های پرآبی Wet periods	46.98	3.05	0.43	1.02	2.59	1.25	253.01
ضریب تغییرات CV (%)	دوره‌های کم‌آبی Dry periods	199.2	32.04	85.52	15.88	33.04	70	105.81
	دوره‌های پرآبی Wet periods	208.0	30.83	71.79	76.08	29.18	62.93	95.23

و گرادیان کاهشی با نرخ آموزش تطبیقی<sup>5</sup> و نیز روش سامانه استنتاجی عصبی - فازی تطبیقی مبتنی بر مدل دسته‌بندی تفریقی، به

3- Fletcher Conjugate Gradient (CGF)

4- One Step Secant (OSS)

5- Gradient descent with adaptive learning rate backpropagation(GDA)

در این مطالعه، روش‌های شبکه‌های عصبی مصنوعی با پنج الگوریتم مختلف پس انتشار خطای لونیبرگ-مارگارت<sup>1</sup>، گرادیان توام مقیاس شده<sup>2</sup>، گرادیان توام فلتچر<sup>3</sup>، الگوریتم متقاطع تک مرحله‌ای<sup>4</sup>،

1- Levenberg-Marquardt (LM)

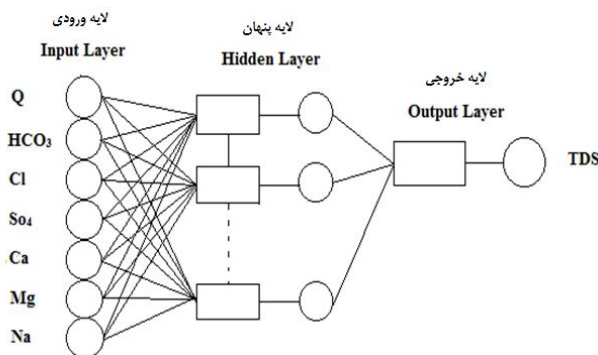
2- Scaled Conjugate Gradient (SCG)

تکنیک، ساختمان مدل مطابق شکل 2 از سه لایه یعنی: ورودی، پنهان و خروجی تشکیل یافته است. در لایه ورودی و خروجی بترتیب داده‌های پایه و داده‌های آزمایش یا اندازه‌گیری پدیده مورد نظر به مدل معرفی می‌شود. مقادیر لایه یا لایه‌های پنهان در مرحله یادگیری یا آموزش بازای مقادیر معلوم لایه‌های ورودی و خروجی وزن‌دهی و تعیین می‌گردد. سپس مدل آموزش یافته برای پیش‌بینی رخدادهای آتی به‌ازای مقادیر معلوم لایه ورودی مورد استفاده قرار می‌گیرد. توسعه یک مدل شبکه عصبی مصنوعی با تعریف و تعیین تعداد لایه‌های پنهان، تعداد نرون‌ها در لایه‌های ورودی، پنهان و خروجی، تابع محرک کنترل‌کننده مقدار خروجی هر نرون در لایه‌های پنهان، شیوه یادگیری یا آموزش، الگوریتم تصحیح وزن‌دهی و ساختمان مدل انجام می‌گردد (2).

ازای داده‌های هفت ایستگاه هیدرومتری با دوره آماری 18 ساله، جهت مدل‌بندی استفاده شده است. مدل‌بندی در محیط بسته نرم‌افزاری MATLAB و با استفاده از تسهیلات و امکانات آن کدنویسی شده است. سپس نتایج حاصل برای بررسی و مقایسه عملکرد مدل‌های مختلف ارزیابی شده و مدل برتر تعیین شده است.

### روش شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی بعنوان یکی از تکنیک‌های اصلی سیستم هوش مصنوعی براساس سیستم عصبی و مغز انسان توسعه داده شده است. در این تکنیک دینامیک با پردازش داده‌های مشاهداتی، ساختمان روابط و وابستگی حاکم بر پدیده مورد نظر یادگیری و تعیین می‌شود. سپس مدل آموزش یافته برای پیش‌بینی رخدادهای آتی این پدیده مورد استفاده قرار می‌گیرد (16). در این



شکل 2- نمودار شماتیک یک شبکه عصبی چند لایه با ورودی‌های مدل  
Figure 2- Schematic diagram of a multi-layered neural network with the model inputs

جانگ (17) در سال 1993 برای اولین بار سامانه استنتاجی عصبی- فازی تطبیقی را بعنوان یک ابزار کارآمد جهت تخمین توابع پیوسته حقیقی در دامنه‌های محدود و با هر درجه‌ای از دقت را معرفی نمود. مدل ANFIS در برگرفته دو مدل شبکه‌های عصبی و مدل فازی می‌باشد. بخش فازی رابطه‌ای بین ورودی و خروجی برقرار نموده و پارامترهای مربوط به توابع عضویت بخش فازی به وسیله شبکه‌های عصبی تعیین می‌شود. لذا خصوصیات هر دو مدل فازی و عصبی در آن نهفته است. منطق فازی بر مبنای تئوری مجموعه‌های فازی می‌باشد که بین طبقات مختلفی از موضوعات، ارتباطی با مرز نرم برقرار می‌کند، به نحوی که عضویت از جنس درجه باشد و با پارامتر درجه بتوان میزان عضویت را نشان داد. در این رهیافت، نظریه کلاسیک عضویت دو رقمی در یک مجموعه به گونه‌ای اصلاح می‌شود که عضویت‌های بین صفر و یک را نیز در بر بگیرد. در فرآیند استنباط فازی، پنج مرحله باید انجام گیرد: (1) فازی‌سازی متغیرهای ورودی، (2) به کار بردن عملگرهای (و؛یا) در بخش مقدمه، (3)

نتیجتاً در این مطالعه جهت مدل‌بندی میزان جامدات محلول در آب رودخانه زرینه‌رود به‌ازای پارامترهای مختلف کیفیت آب و جریان رودخانه در دوره‌های کم‌آبی و پرآبی، یک ساختار سه لایه (لایه ورودی، پنهان و خروجی) و پنج الگوریتم مختلف برای آموزش مدل، استفاده از تابع محرک متغیر لوگ-سیگموئید<sup>1</sup> و تانژانت-سیگموئید<sup>2</sup> در لایه پنهان، کاربرد تابع محرک خطی<sup>3</sup> در لایه خروجی، تعداد متغیر نرون‌ها در لایه پنهان و تعداد تکرار برابر یک هزار بار، مطابق نمودار شماتیک شکل 2 استفاده گردیده است.

### سامانه استنتاجی عصبی- فازی تطبیقی

- 1- Log-Sigmoid
- 2- Tan-Sigmoid
- 3- Linear Transfer Function

$$TDS = p_2HCO_3 + q_2Ca + r_2 \quad (2)$$

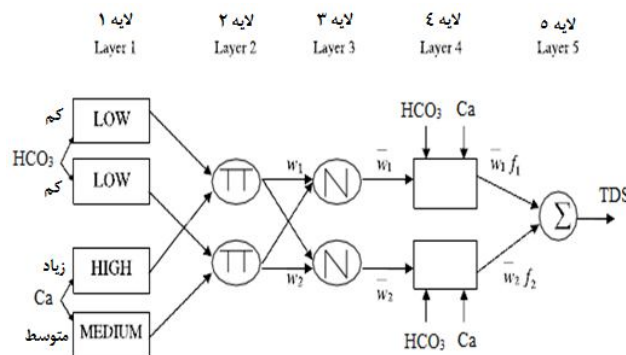
در شکل 3 نمای مدل سامانه استنتاجی عصبی-فازی تطبیقی مثال ساده فوق با دو ورودی  $HCO_3$  و  $Ca$ ، یک خروجی نشان داده شده است. لازم به ذکر است که در این مطالعه سامانه استنتاجی عصبی-فازی تطبیقی مبتنی بر مدل دسته‌بندی تفریقی برای مدل‌بندی میزان TDS به‌ازای پارامترهای کیفی و کمی جریان رودخانه مورد استفاده قرار گرفته است. روش دسته‌بندی تفریقی براساس روش دسته‌بندی نقاط مرتفع جهت کاهش پیچیدگی‌های محاسباتی روش اولیه توسعه و پیشنهاد شده است (5).

استنتاج از مقدمه به نتیجه، (4) ترکیب نتایج قوانین، (5) غیرفازی کردن (3). بعنوان مثال در یک سامانه استنتاج فازی،  $HCO_3$  و  $Ca$  دو ورودی و TDS خروجی آن است. در این سامانه مدل فازی مرتبه اول سوگنو با دو قانون فازی اگر-آنگاه به صورت زیر بیان می‌شود:

قانون 1: اگر  $HCO_3$  در حالت LOW و  $Ca$  در حالت High باشد  
آنگاه:

$$TDS = p_1HCO_3 + q_1Ca + r_1 \quad (1)$$

قانون 2: اگر  $HCO_3$  در حالت LOW و  $Ca$  در حالت MEDIUM باشد آنگاه:



شکل 3- نمای مدل سامانه استنتاجی عصبی-فازی تطبیقی برای مثال ساده ذکر شده  
Figure 3- Overview of the Adaptive Neuro Fuzzy Inference System for mentioned simple example

از مقادیر مشاهداتی برآورد شده باشند. لذا هر چند ضریب همبستگی به عنوان یک شاخص و معیار بسیار مهم در ارزیابی عملکرد مدل‌های پیش‌بینی محسوب می‌شود ولی این شاخص به تنهایی به عنوان معیاری جهت مقایسه عملکرد مدل‌های بدست آمده کافی نبوده و لازم است علاوه بر آن، شاخص‌های دیگری همچون ریشه میانگین مربعات خطا، قدر مطلق میانگین خطا و برازش گرافیکی پراکندگی داده‌های مشاهداتی و برآوردی مدل برای ارزیابی مدل‌ها استفاده شود (25، 9 و 31). رابطه ریاضی شاخص‌های کمی سه‌گانه مذکور بوسیله روابط 3 الی 5 نشان داده شده است. بر اساس این شاخص‌های آماری کمی، مدل برتر دارای مقدار حداکثر  $|R|$  و حداقل RMSE و MAE خواهد بود.

$$R = \frac{Cov(O_i, E_i)}{\sqrt{Var(O_i).Var(E_i)}} \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - E_i)^2} \quad (4)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - E_i| \quad (5)$$

ضمناً در کاربرد سامانه مذکور از شعاع دسته متغیر با یکصد تکرار و ورودی‌های همسان با شبکه عصبی مصنوعی برای تعیین بهترین مدل استفاده شده است.

### آزمون ارزیابی مدل

در این تحقیق سه آزمون ارزیابی کمی و یک روش گرافیکی در این تحقیق جهت ارزیابی عملکرد مدل‌های پیش‌بینی مورد نظر از سه آزمون آماری کمی معتبر و رایج شامل ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE) و قدر مطلق میانگین خطا (MAE) و یک روش گرافیکی (نمودار پراکندگی داده‌های مشاهداتی و برآوردی از مدل) استفاده گردید. ضریب همبستگی، شدت رابطه خطی<sup>1</sup> و نوع رابطه (مستقیم یا معکوس) مقادیر مشاهداتی و برآوردی مدل را بیان می‌کند. با این وجود روش مذکور، میزان انحراف مقادیر برآوردی مدل از مقادیر مشاهداتی را نشان نداده یعنی ممکن است تمامی مقادیر برآوردی مدل با یک نسبت مشخص کوچکتر یا بزرگتر

1- Linearity

ایستگاه هیدرومتری به عنوان ایستگاه‌های مبنا انتخاب گردید. در مرحله بعد، آزمون F جهت بررسی توزیع مکانی مناسب ایستگاه‌های مبنا در دوره‌های کم‌آبی و پرآبی انجام گرفت. نتایج آزمون بیانگر وجود اختلاف آماری معنی‌دار در سطح اطمینان 95% ( $F_{calculated} > F_{critical}$ ) بوده و در نتیجه داده‌های ایستگاه‌های مبنا در دوره‌های مطالعاتی مذکور مستقل از هم طبقه‌بندی شده و می‌تواند به عنوان معرف واقعی از کیفیت آب رودخانه زرينه‌رود در نقاط مختلف رودخانه باشد. برای تعیین پارامترهای ورودی مدل‌های پیش‌بینی مورد نظر جهت تخمین میزان TDS، ابتدا ضرایب همبستگی پیرسون با استفاده از نرم‌افزار SPSS، بین پارامترهای کیفیت آب و جریان رودخانه در دوره‌های پرآبی و کم‌آبی محاسبه گردید (جدول 3 و 4). سپس بر اساس معنی‌دار بودن ضرایب همبستگی در سطح اطمینان 95% پارامترهای ورودی مدل‌ها مشخص شدند. نتیجتاً 7 مؤلفه مؤثر یعنی جریان رودخانه به‌مراه 6 مؤلفه کیفیت آب بی‌کربنات، کلرید، سولفات، کلسیم، منیزیم و سدیم در 7 ایستگاه مبنا، به عنوان متغیرهای ورودی برای مدل‌های پیش‌بینی در نظر گرفته شدند. در مرحله بعد، 75 و 25 درصد داده‌های مشاهداتی ایستگاه‌های مبنا به‌طور تصادفی به ترتیب برای آموزش و آزمون مدل‌ها، در دو مجموعه تفکیک شده است.

که در آنها،  $O_i$ : مقادیر مشاهداتی،  $E_i$ : مقادیر برآوردی مدل،  $Var(O_i, E_i)$ ،  $Cov(O_i, E_i)$ : به ترتیب کوواریانس و واریانس بین داده‌های مشاهداتی و برآوردی می‌باشند.

### نتایج و بحث

داده‌های کیفیت آب در حوضه آبریز زرينه‌رود، توسط دفتر آزمایشگاه کیفیت شیمیایی امور مطالعات سازمان آب منطقه‌ای استان آذربایجان غربی در طی سال‌های 1372 تا 1389 برداشت و جمع‌آوری شده است. در بررسی‌های زیست محیطی سیستم‌های منابع آب، عموماً شرایط بحرانی سیستم نظیر دوره‌های کم‌آبی و پرآبی، مورد توجه قرار می‌گیرند. در حوضه آبریز زرينه‌رود بیشترین درصد جریان آب فصلی در بهار بوده و بیش از 50 درصد حجم جریان‌های سالیانه را به خود اختصاص می‌دهد. کمترین درصد فصلی جریان حوضه آبریز مذکور با حدود 3 و 7 درصد حجم جریان سالیانه به ترتیب به فصل‌های تابستان و اوایل پاییز مربوط می‌شود. در این تحقیق، داده‌های کیفیت آب در تمامی ایستگاه‌های هیدرومتری در رودخانه زرينه‌رود از نظر طول دوره آماری، تعداد نمونه‌برداری، زمان نمونه‌برداری در طی ماه‌های مختلف سال و موقعیت مکانی ایستگاه‌ها نسبت به سد مخزنی بوکان مورد بررسی قرار گرفته و سپس هفت

جدول 3- ضرایب همبستگی بین پارامترهای کیفیت آب و جریان در دوره کم‌آبی

Table 3- Correlation coefficients between the parameters of water quality and discharge during the dry period

پارامترها Parameters	TDS (mg.L <sup>-1</sup> )	Flow (m <sup>3</sup> .s <sup>-1</sup> )	HCO <sub>3</sub> (meq.L <sup>-1</sup> )	Cl (meq.L <sup>-1</sup> )	So <sub>4</sub> (meq.L <sup>-1</sup> )	Ca (meq.L <sup>-1</sup> )	Mg (meq.L <sup>-1</sup> )	Na (meq.L <sup>-1</sup> )
TDS (mg.L <sup>-1</sup> )	1							
Flow (m <sup>3</sup> .s <sup>-1</sup> )	-0.342*	1						
HCO <sub>3</sub> (meq.L <sup>-1</sup> )	0.671*	-0.346*	1					
Cl (meq.L <sup>-1</sup> )	0.750*	-0.162*	0.223*	1				
So <sub>4</sub> (meq.L <sup>-1</sup> )	0.186*	-0.050	0.157*	0.088	1			
Ca (meq.L <sup>-1</sup> )	0.662*	-0.295*	0.659*	0.405*	0.165*	1		
Mg (meq.L <sup>-1</sup> )	0.201*	-0.072	0.062	0.031	0.019	0.077	1	
Na (meq.L <sup>-1</sup> )	0.795*	-0.187*	0.531*	0.714*	0.093	0.258*	0.038	1

\*معنی‌داری در سطح 95%

جدول 4- ضرایب همبستگی بین پارامترهای کیفیت آب و جریان در طول دوره پرآبی

Table 4- Correlation coefficients between the parameters of water quality and discharge during the wet period

پارامترها Parameters	TDS (mg.L <sup>-1</sup> )	Flow (m <sup>3</sup> .s <sup>-1</sup> )	HCO <sub>3</sub> (meq.L <sup>-1</sup> )	Cl (meq.L <sup>-1</sup> )	So <sub>4</sub> (meq.L <sup>-1</sup> )	Ca (meq.L <sup>-1</sup> )	Mg (meq.L <sup>-1</sup> )	Na (meq.L <sup>-1</sup> )
TDS (mg.L <sup>-1</sup> )	1							
Flow (m <sup>3</sup> .s <sup>-1</sup> )	-0.256*	1						
HCO <sub>3</sub> (meq.L <sup>-1</sup> )	0.801*	-0.231*	1					
Cl (meq.L <sup>-1</sup> )	0.297*	-0.072	0.228*	1				
So <sub>4</sub> (meq.L <sup>-1</sup> )	0.502*	-0.131	0.402*	0.884*	1			
Ca (meq.L <sup>-1</sup> )	0.782*	-0.224*	0.796*	0.407*	0.562*	1		
Mg (meq.L <sup>-1</sup> )	0.735*	-0.235*	0.714*	0.588*	0.745*	0.562*	1	
Na (meq.L <sup>-1</sup> )	0.270*	-0.060	0.259*	0.960*	0.904*	0.394*	0.589*	1

\*معنی‌داری در سطح 95%

نرمال سازی داده‌ها جهت استفاده در مدل بندی شبکه عصبی براساس رابطه 6 انجام پذیرفته است.

$$X_N = \frac{X_R - X_{min}}{X_{max} - X_{min}} \quad (6)$$

که در آن،  $X_N$  داده نرمال شده،  $X_R$  مقدار داده مشاهداتی،  $X_{min}$ : کمترین مقدار داده‌های مشاهداتی و  $X_{max}$ : بیشترین مقدار داده‌های مشاهداتی است. بعد از آماده سازی داده‌های اولیه برای مدل بندی میزان جامدات محلول TDS آب رودخانه زربنه رود در دوره‌های کم آبی و پرآبی، روش‌های شبکه عصبی مصنوعی و عصبی-فازی تطبیقی در محیط نرم‌افزاری MATLAB به کار گرفته شده است. جهت رسیدن به ساختار بهینه شبکه‌های عصبی مصنوعی به ازای الگوریتم‌های مختلف مورد نظر، پارامترهای هر شبکه از جمله تعداد

نرون‌ها (1 تا 25 نرون) در لایه پنهان، توابع محرک در لایه پنهان و لایه خروجی در هر الگوریتم به روش سعی و خطا مورد آزمون قرار گرفت. نهایتاً برای پنج الگوریتم مورد نظر برای دو دوره کم آبی و پرآبی 500 مدل اجرا و بهترین مدل بر اساس حداقل میزان مربعات خطا، تعداد تکرار 1000 و سرعت آموزش 0/01، برای هر الگوریتم تعیین گردید. ضمناً در روش عصبی-فازی تطبیقی مدل دسته بندی تفریقی، تحلیل حساسیت مدل بر مبنای پارامتر شعاع دسته که محدوده تغییرات آن در بازه صفر تا 1 می باشد، انجام گرفت. بهترین مدل با استفاده از سامانه استنتاجی نوع سوگونو، اندازه گام 0/02، الگوریتم آموزشی هیبرید که ترکیب روش گرادین کاهشی و حداقل مربعات خطا می باشد، تعیین گردید. مشخصات مدل‌های بهینه عصبی-فازی تطبیقی در جدول 5 آورده شده است.

جدول 5- مشخصات مدل‌های بهینه عصبی-فازی تطبیقی (مدل دسته بندی تفریقی)

Table 5- Characteristics of optimize Adaptive Neuro Fuzzy models

توابع اصلی و داخلی The main and internal functions	ساختار مدل Model structure				
	دوره مطالعاتی پرآبی Wet period		دوره مطالعاتی کم آبی Dry period		
Prod	و AND	شعاع دسته Radii values	0.58	شعاع دسته Radii values	0.72
Probor	یا OR	تعداد گره‌ها Number of Nodes	42	تعداد گره‌ها Number of Nodes	58
Prod	دلالت Implication	تعداد پارامترهای خطی Number of linear parameters	16	تعداد پارامترهای خطی Number of linear parameters	24
Max	تجمع Aggregation	تعداد پارامترهای غیرخطی Number of nonlinear parameters	28	تعداد پارامترهای غیرخطی Number of nonlinear parameters	42
Wtaver	غیرفازی سازی Defuzzification	تعداد قوانین فازی Number of fuzzy rules	2	تعداد قوانین فازی Number of fuzzy rules	3

شده است. نتایج مذکور حاکی از دقت نسبی بالاتر روش سامانه استنتاجی عصبی-فازی تطبیقی نسبت به روش شبکه عصبی مصنوعی است.

در شکل 5 و 6 نمودار مقادیر TDS مشاهداتی و برآوردی توسط مدل‌های شبکه‌های عصبی مصنوعی با الگوریتم آموزشی لونیبرگ-مارگارت و سامانه عصبی-فازی تطبیقی مبتنی بر مدل دسته بندی تفریقی، به ترتیب برای دوره‌های مطالعاتی کم آبی و پرآبی همراه با نمودارهای نکویی برازش مربوط به داده‌های دوره آزمون نشان داده شده است.

همچنین نتایج حاصل و مشخصات مدل‌های بهینه شبکه‌های عصبی مصنوعی در جدول 6 نشان داده شده است. بر اساس این جدول مشاهده می شود که الگوریتم آموزشی لونیبرگ-مارگارت به ترتیب برای دوره‌های کم آبی و پرآبی، با تعداد نرون 2 و 5 در لایه پنهان، بهترین عملکرد را در میان سایر الگوریتم‌های آموزشی شبکه عصبی مصنوعی داشته است. مقایسه بین روش‌های شبکه عصبی مصنوعی و عصبی-فازی تطبیقی مدل دسته بندی تفریقی، بیانگر عملکرد بهتر روش عصبی-فازی تطبیقی در دو دوره مطالعاتی کم آبی و پرآبی با شعاع دسته 0/72 و 0/58 است. نتایج ارزیابی عملکرد مدل‌های مختلف به ازای سه شاخص کمی در شکل 4 ارائه شده و بهترین گزینه مدل‌های بکار رفته با پیکان در روی شکل مشخص

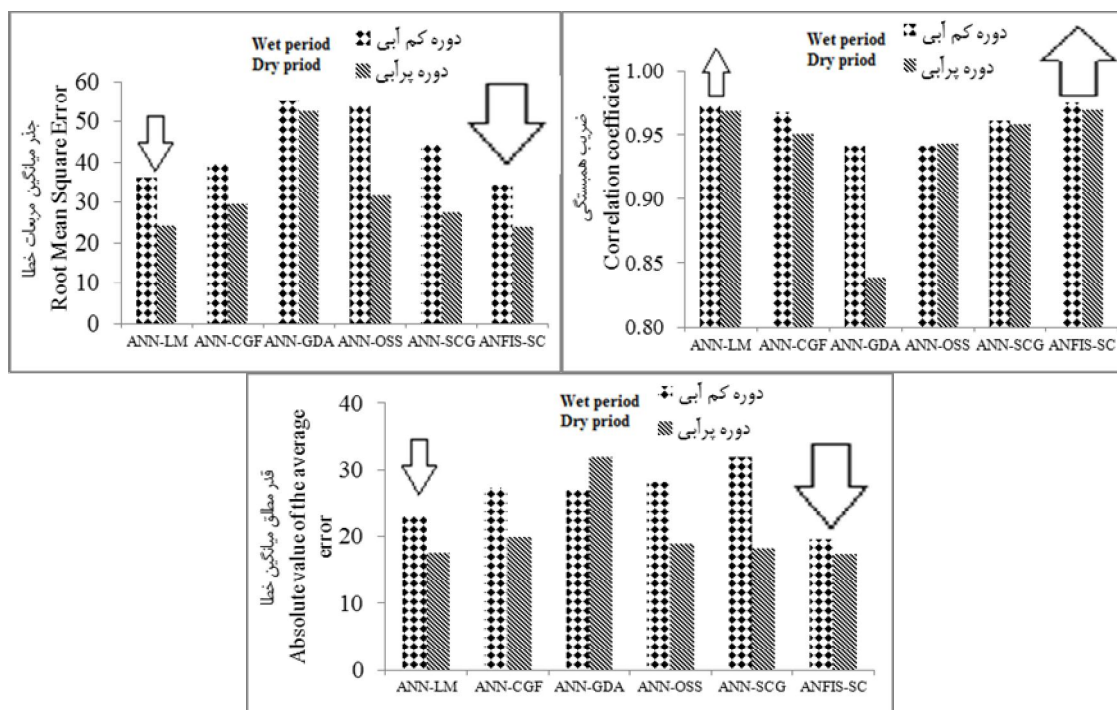


جدول 6- مشخصات مدل‌های بهینه شبکه‌های عصبی مصنوعی و پارامترهای آماری محاسبه شده جهت تخمین میزان جامدات محلول رودخانه‌های حوضه آبریز زرینه‌رود در دوره‌های مطالعاتی

Table 6- Characteristics of optimized artificial neural networks and the calculated statistical parameters to estimate the TDS in Zarrineh River basin

دوره‌های مطالعاتی Study periods	نام و ساختار مدل Name and model structure	آموزش Training			آزمون Test		
		R	RMSE (mg/L)	MAE (mg/L)	R	RMSE (mg/L)	MAE (mg/L)
کم‌آبی Dry period	ANN1(LM, Logsig, Purelin,7→2→1)*	0.987	21.00	16.48	0.972	36.69	22.10
	ANN2(CGF, Tansig, Purelin,7→6→1)	0.979	26.01	18.85	0.967	39.69	27.38
	ANN3(GDA, Tansig, Purelin,7→6→1)	0.983	23.44	16.80	0.941	4.58	1.80
	ANN4(OSS, Logsig, Purelin,7→8→1)	0.983	23.67	17.29	0.941	4.91	1.00
	ANN5(SCG, Logsig, Purelin,7→5→1)	0.969	31.75	23.56	0.961	1.38	0.36
پرآبی Wet period	ANN1(LM, Logsig, Purelin,7→5→1)	0.977	20.59	15.88	0.968	1.60	0.25
	ANN2(CGF, Logsig, Purelin,7→8→1)	0.963	26.01	19.90	0.950	0.48	0.20
	ANN3(GDA, Tansig, Purelin,7→11→1)	0.929	35.77	23.56	0.839	0.78	0.36
	ANN4(OSS, Logsig, Purelin,7→9→1)	0.973	22.23	17.23	0.943	0.48	0.20
	ANN5(SCG, Logsig, Purelin,7→9→1)	0.974	21.85	16.93	0.958	0.61	0.67
کم‌آبی Dry period	ANFIS1	0.988	20.29	15.82	0.975	0.83	0.25
پرآبی Wet period	ANFIS2	0.974	22.01	17.11	0.969	0.27	0.39

(علامت اختصاری الگوریتم، نوع تابع محرک در لایه پنهان، نوع تابع محرک در لایه خروجی، تعداد ورودی‌ها، تعداد نرون در لایه پنهان، تعداد خروجی)

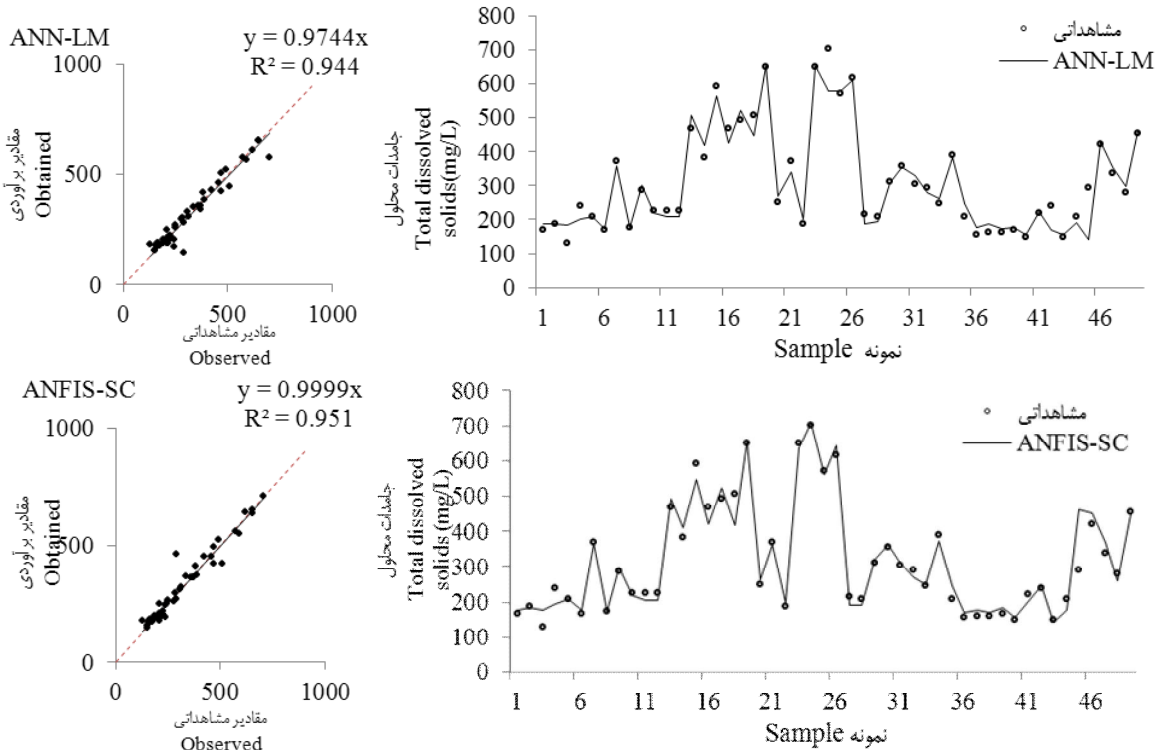


شکل 4- ارزیابی نتایج مدل‌ها براساس معیارهای آزمون ضریب همبستگی، جذر میانگین مربعات خطا و قدر مطلق میانگین خطا در دوره‌های کم‌آبی و پرآبی در مرحله آموزش

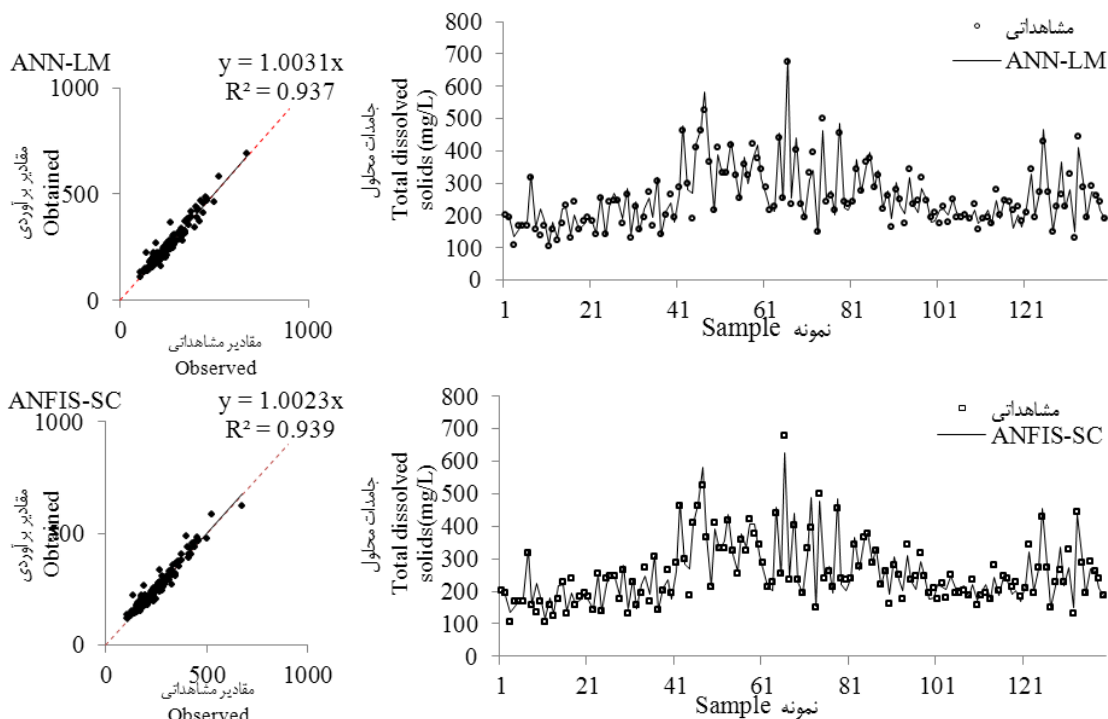
Figure 4- Evaluating the results of models based on correlation coefficient, Root Mean Square Error and Mean Average Error in dry and wet periods in the training step

پیش‌بینی داده‌های کیفیت و کمیت جریان رودخانه‌ای بایستی پتانسیل لازم را برای حفظ تصادفی بودن، مستقل بودن و نداشتن روند در داده‌های پیش‌بینی یا برآوردی را داشته باشند. لذا بدین منظور یک ارزیابی تکمیلی از عملکرد مدل‌های بدست آمده با استفاده از مقدار باقیمانده انجام پذیرفته است. شکل 7 نمودار تغییرات مقادیر باقیمانده (یعنی اختلاف مقادیر برآوردی و مشاهداتی) و مقادیر برآوردی مدل سامانه استنتاجی عصبی-فازی تطبیقی برای دو دوره کم و پرآبی را نشان می‌دهد. بر اساس نمودار تغییرات فوق، مقادیر باقیمانده دارای رفتار کاملاً تصادفی در اطراف محور برابر صفر بوده که بطور مستقل و بدون روند معنی‌داری در اطراف محور مذکور پراکنده شده‌اند. این امر بیانگر پتانسیل بالای مدل سامانه استنتاجی عصبی-فازی تطبیقی بطور خاص و سایر مدل‌های هوش مصنوعی بطور عام جهت مدل‌بندی مشخصات کیفی جریان‌های رودخانه‌ای در دوره‌های کم-آبی و پرآبی است.

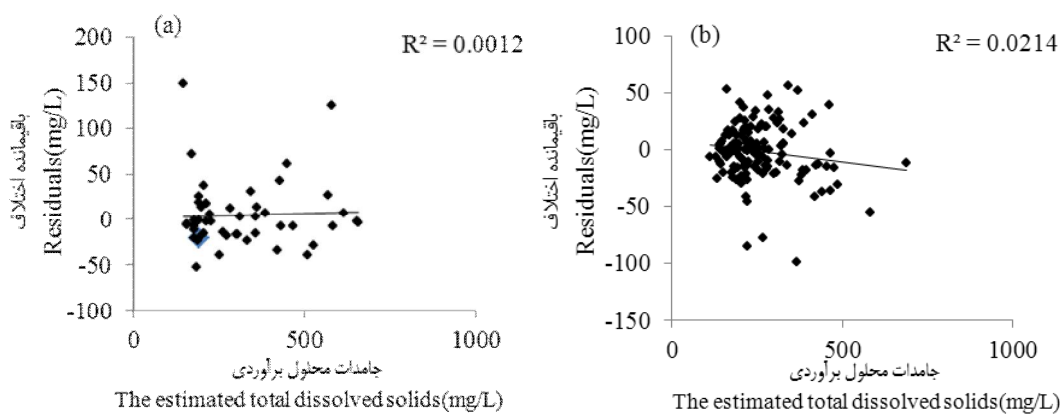
با توجه به نمودارها مشاهده می‌شود که در دوره مطالعاتی کم‌آبی مدل عصبی-فازی تطبیقی مقادیر حداکثر را بهتر از شبکه‌های عصبی مصنوعی تخمین زده است. همچنین در دوره‌های پرآبی روش شبکه عصبی مصنوعی مقدار حداکثر غلظت را بیشتر از مقدار واقعی و روش فازی-عصبی تطبیقی کم‌تر از مقدار واقعی تخمین زده است. با وجود اینکه ضریب همبستگی بین داده‌های مشاهداتی و برآوردی هر دو مدل شبکه عصبی مصنوعی (با الگوریتم آموزشی لونیبرگ-مارگارت) و عصبی-فازی تطبیقی (مدل دسته‌بندی تفریقی) در سطح معنی‌داری 99% برای دوره مطالعاتی کم‌آبی و پرآبی معنی‌دار می‌باشد، ولی مقدار این ضریب در دوره‌های کم‌آبی که میانگین غلظت و ضریب تغییرات TDS بیشتر بوده و غلظت‌های حداکثر را شامل می‌شود، نسبت به دوره‌های پرآبی که غلظت‌های حداقل را شامل می‌شود، بیش‌تر است. داده‌های کمیت و کیفیت جریان رودخانه‌ای بعنوان متغیرهای تصادفی شناخته شده و از طرف دیگر اندازه‌گیری مستقیم چنین داده‌هایی بطور محدود در هر سال انجام می‌پذیرد. لذا مدل‌های



شکل 5- نمودار نکویی برازش و منحنی‌های مشاهداتی و برآوردی مدل ANN-LM و ANFIS-SC برای داده‌های آزمون در دوره کم‌آبی  
Figure 5- Best fit curve and observed and estimated curves of ANN-LM and ANFIS-SC for test data in dry periods



شکل 6- نمودار نکویی برازش و منحنی های مشاهداتی و برآوردی مدل ANN-LM و ANFIS-SC برای داده های آزمون در دوره پربابی  
Figure 6- Best fit curve and observed and estimated curves of ANN-LM and ANFIS-SC for test data in wet periods



شکل 7- نمودارهای باقیمانده اختلاف و برآوردی مدل ANFIS-SC برای داده های آزمون در دوره کم آبی (a)، پربابی (b)  
Figure 7- The curve of remaining difference and estimated of ANFIS-SC model for test data in a) dry and b) wet periods

پیش بینی جامدات محلول در آب (TDS) به ازای جریان رودخانه و سایر پارامترهای کیفی آب رودخانه بوده است. نتایج حاصل بیانگر عملکرد بسیار مطلوب روش سامانه استنتاج عصبی-فازی تطبیقی مبتنی بر مدل دسته بندی تفریقی و روش شبکه عصبی مصنوعی با الگوریتم آموزشی پس انتشار خطای لوبنرگ-مارگات در مدل بندی پارامترهای کیفی آب جریان های رودخانه ای از جمله جامدات محلول در آب (TDS) در فصول کم آبی و پربابی رودخانه با حفظ خصوصیات

### نتیجه گیری

در این مطالعه برای مدل بندی مشخصات کیفی آب رودخانه زربینه رود در 7 ایستگاه آب سنجی به تفکیک در فصول کم آبی و پربابی از روش های هوش مصنوعی یعنی 5 مدل شبکه عصبی مصنوعی و سامانه استنتاج عصبی-فازی تطبیقی استفاده شده است. بدین منظور داده های مشاهداتی 18 ساله (1372 - 1389) بکار گرفته شده و هدف

علاوه بر این، نتایج این مطالعه در راستای گزارش عملکرد مطلوب روش‌های مذکور در مدل‌بندی پیش‌بینی میزان غلظت اکسیژن محلول آب رودخانه و مشخصه بیولوژیکی آن توسط سنگرور و همکارانش (33) و ساین و همکارانش (34) است. ضمناً عملکرد مطلوب روش‌های مذکور برای مدل‌بندی پدیده‌های دیگر هیدرولوژیکی نیز توسط محققین در نقاط مختلف دنیا از جمله گولدال و تنگال (13)، کوبانر (6)، کیشی و همکارانش (21 و 22) در منابع معتبر گزارش شده است.

هیدرولوژیکی داده‌های مشاهداتی یعنی تصادفی بودن، مستقل بودن و نداشتن روند است. با این وجود روش سامانه استنتاج عصبی-فازی تطبیقی بر اساس معیار ارزیابی کمی مورد استفاده (یعنی  $R^2$  بالاتر و RMSE و MAE پایین‌تر) دارای عملکرد نسبی بالاتری در مقایسه با روش شبکه عصبی مصنوعی داشته است. ضمناً نتایج پیش‌بینی دوره‌پرابی دارای دقت بالاتری نسبت به دوره کم‌آبی بوده که این امر ناشی از حساسیت بالاتر داده‌های دوره کم‌آبی به عوامل طبیعی و خطاهای انسانی مانند اندازه‌گیری است.

## منابع

- Ahmadi P. 2011. Optimizing utilization of Zarrineh River irrigation and drainage network using genetic algorithm. Master's Thesis, Urmia University.
- Caudill M. 1987. Neural networks primer: Part I. *AI Expert*, 2(12): 46-52.
- Chang F.J., and Chang Y.T. 2006. Adaptive neuron-fuzzy inference system for prediction of water level in reservoir. *Advances in Water Resources*, 29(1):1-10.
- Chang F.J., and Chen Y.C. 2001. Counter propagation fuzzy-neural network modeling approach to real time streamflow prediction. *Journal of Hydrology*, 245:153-164.
- Chiu S.L. 1995. Extracting fuzzy rules for pattern classification by cluster estimation. In: *The 6th Internat. Fuzzy Systems Association World Congress*, pp. 1-4.
- Cobaner M. 2011. Evapotranspiration estimation by two different neuro-fuzzy inference systems. *Journal of Hydrology*, 398: 292-302.
- Coulibaly P., Anctil F., Aravena R., and Bobee B. 2001. Artificial neural network modeling of water table depth fluctuations. *Water Resources Research*, 37(4): 885-896.
- Dadfar S., Khaligi Sigarodi Sh., Shah Bandari R.V., and Kamrani F. 2010. The relationship between chemical water quality and river discharge parameters (Case Study: Taleghan). *National Conference of clean water approach*, Tehran.
- Farbodnam N., Ghorbani M.A. and Alami M. 2009. River Flow Prediction Using Genetic Programming (Case Study: Lighvan River Watershed). *Journal of Water and Soil*, 19(1): 107-123.
- Goyal M.K., and Ojha C.S.P. 2011. Estimation of scour downstream of a ski-jump bucket using support vector and M5 model tree. *Water Resources Management*, 25 (9): 2177-2195.
- Güven A. 2009. Linear genetic programming for time-series modeling of daily flow rate. *Journal of Earth System Science*, 118 (2): 137-146.
- Güven A., and Talu N.E. 2010. Gene-expression programming for estimating suspended sediment in Middle Euphrates Basin. Turkey. *CLEAN-Soil Air Water*, 38(12): 1159-1168.
- Güldal V., and Tongal H. 2010. Comparison of recurrent neural network, adaptive neuro-fuzzy inference system and stochastic models in Egirdir Lake level forecasting. *Water Resources Management*, 24(1): 105-128.
- Hesami Rostami R., Afshar A., and Mosavi J. 2005. Flood forecasting model using neuro-fuzzy inference system and compare it with regression comparative examples with solutions: Karkhe River. *The First Annual Conference of Water Resources Management of Iran*, Tehran.
- Hrdinka T., Novicky O., Hanslik E., and Riede M. 2012. Possible impacts of floods and droughts on water quality. *Journal of Hydro-environment Research*, 145-150.
- Jain SK., Das A., and Srivastava D.K. 1999. Application of ANN for reservoir inflow prediction and operation. *Journal of Water Resources Planning and Management ASCE*, 125(5): 263-271.
- Jang J.S.R. 1993. ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man and Cybernetics*, 23 (3): 665-685.
- Karimi S., Kisi O., Shiri J., and Makarynsky O. 2013. Neuro-fuzzy and neural network techniques for forecasting sea level in Darwin Harbor, Australia. *Computers & Geosciences*, 52: 50-59.
- Kisi O. 2006. Daily pan evaporation modeling using a neuro-fuzzy computing technique. *Journal of Hydrology*, 329: 636-646.
- Kisi O. 2007. Evapotranspiration modeling from climate data using a neural computing technique. *Hydrological Processes*, 21(6): 1925-1934.
- Kisi O., Nia A.M., Gosheh M.G., Tajabadi M.R.J., and Ahmadi A. 2012. Intermittent streamflow forecasting by using several data driven techniques. *Water Resources Management*, 26(2): 457-474.

- 22- Kisi O., Shiri J., and Tombul M. 2013. Modeling rainfall-runoff process using soft computing techniques. *Computers & Geosciences*, 51: 108–117.
- 23- Kumar M., Raghuvanshi N.S., Singh R., Wallender W.W., and Pruitt W.O. 2002. Estimating evapotranspiration using artificial neural networks. *Journal of Irrigation and Drainage Engineering ASCE*, 128(4): 224–233.
- 24- Lashnizand M., Pavaneh B., and Bazgir M. 2010. The effects of wet and dry periods on the quality of surface water of Kashkan basin. *Journal of Physical Geography*, 3(8):111-125.
- 25- Legates D.R., and Mc Cabe G.J. 1999. Evaluating the use of goodness-of-fit measures in hydrologic and hydroclimatic model validation. *Water Resources Research*, 35(1): 233-241.
- 26- Misaghy F., and Mohammadi K. 2004. Prediction of Zayandehrood river water quality using Artificial Neural Networks. 2th National Conference of soil and water resources, Shiraz University.
- 27- Najah A., Elshafie A., Karim O., and Jaffar O. 2009. Prediction of Johor river water quality parameters using artificial neural networks. *European Journal of Scientific Research*, 28: 422-35.
- 28- Park J.H., Duan L., Kim B.J., Mitchell M., and Shibata H. 2010. Potential effects of climate change and variability on watershed biogeochemical processes and water quality in Northeast Asia. *Environment International*, 212-225.
- 29- Pour-Ali Baba A., Shiri J., Kisi O., Fakheri Fard A., Kim S., and Amini A. 2013. Estimating daily reference evapotranspiration using available and estimated climatic data by adaptiveneuro-fuzzy inference system (ANFIS) and artificial neural network (ANN). *Hydrology Research*, 44.1: 131-146.
- 30- Saadati N., Hoseynizare N., and Gandomkar P. 2006. Study on quality of Maron-Jarahi river water using water quality indexes (drinking, Agriculture and WQI). 7th International Seminar on River Engineering, Shadid Chamran Ahvaz University.
- 31- Sanikhani H., and Kisi O. 2012. River Flow Estimation and Forecasting by Using Two Different Adaptive Neuro-Fuzzy Approaches. *Water Resources Management*, 26: 1715–1729.
- 32- Sani Khani H., Nikpoor M., and Dinpazhouh Y. 2011. Compareing the performance of Grid partitioning and Subtractive clustering methods in estimateing the pan evaporation. The first National Conference on Agricultural Meteorology and Water Management. College of Agriculture and Natural Resources, Tehran University.
- 33- Sengorur B., Dogan E., Koklu R., and Samandar A. 2006. Dissolved oxygen estimation using artificial neural network for water quality control. *Fresenius Environmental Bulletin*, 15: 1064–1067.
- 34- Sighn K.P., Basant A., Malik A., and Jain G. 2009. Artificial neural network modeling of the river water quality-A case study. *Ecological Modelling*, 220: 888–895.
- 35- Wu H.J., Lin Z.Y., and Guo S.L. 2000. The application of artificial neural networks in the resources and environment. *Resources and Environment in the Yangtze Basin*, 9: 237–241 (in Chinese).
- 36- Xiang S.L., Liu Z.M., and Ma L.P. 2006. Study of multivariate linear regression analysis model for ground water quality prediction. *Guizhou Science*, 24: 60–62.

## Comparing the Performance of Artificial Intelligence Models in Estimating Water Quality Parameters in Periods of Low and High Water Flow

M. Montaseri<sup>1\*</sup>- S. Zaman Zad Ghavidel<sup>2</sup>

Received: 10-06-2013

Accepted: 18-07-2016

**Introduction:** A total dissolved solid (TDS) is an important indicator for water quality assesment. Since the composition of mineral salts and discharge affects the TDS of water, it is important to understand the relationships of mineral salts composition with TDS.

**Materials and Methods:** In this study, methods of artificial neural networks with five different training algorithm, Levenberg-Marquardt (LM), Scaled Conjugate Gradient (SCG), Fletcher Conjugate Gradient (CGF), One Step Secant (OSS) and Gradient descent with adaptive learning rate backpropagation (GDA) algorithm and adaptive Neurofuzzy inference system based on Subtractive Clustering were used to model water quality properties of Zarrineh River Basin, to be developed in total dissolved solids prediction. ANN and ANFIS program code were written in MATLAB language. Here, the ANN with one hidden layer was used and the hidden nodes' number was determined using trial and error. Different activation functions (logarithm sigmoid, tangent sigmoid and linear) were tried for the hidden and output nodes. Therefore, water quality data from seven hydrometer stations were used during the statistical period of 18 years (1993-2010). In this research, the study period was divided into two periods of dry and wet flow, and then in a preliminary statistical analysis, the main parameters affecting the estimation of the TDS are determined and used for modeling. 75% of data are used for remaining and 25% of the data are used for evaluation of the model, randomly. In this paper, three statistical evaluation criteria, correlation coefficient (R), the root mean square error (RMSE) and mean absolute error (MAE) were used to assess models' performances.

**Results and Discussion:** By applying correlation coefficients method between the parameters of water quality and discharge with total dissolved solid in two periods, wet and dry periods, the significant (at 95% level) variables entered into the model were Q, HCO<sub>3</sub><sup>-</sup>, Cl, SO<sub>4</sub>, Ca, Na and Mg. The optimal ANN (LM) architecture used in this study consists of an input layer with seven inputs, one hidden and output layer with two and five neurons for dry and wet periods, respectively. Similar ANN (LM), ANFIS-SC model had the best performance. It is clear that the ANFIS with 0/72 and 0/58 radii value has the highest R and the lowest RMSE for dry and wet periods, respectively. Comparing the ANFIS-SC estimations with the measured data for the test stage demonstrates a high generalization capacity of the model, with relatively low error and high correlation. From the scatter plots it is obviously seen that the ANFIS-SC predictions are closer to the corresponding measured TDS than other models in two periods. As seen from the best straight line equations (assume the equation as  $y=ax$ ) in the scatter plots that the coefficient for ANFIS-SC is closer to 1 than other models. In addition ANFIS-SC performed with the correlation coefficients in dry and wet periods, respectively 0.975, 0.969 and with Root-mean-square errors, respectively 34.41, 23.85 in order to predict dissolved solids (TDS) in the rivers of Zarrineh River Basin. The obtained results showed the efficiency of the applied models in simulating the nonlinear behavior of TDS variations in terms of performance indices. The results are also tested by using t test for verifying the robustness of the models at 99% significance level. Comparison results indicated that the poorest model in TDS simulation was ANN-GDA in dry and wet periods, especially in test period. The observed relationship between residuals and model computed TDS values shows complete independence and random distribution. It is further supported by the respective correlations for ANFIS-SC models ( $R^2 = 0.0012$  for dry period and  $R^2 = 0.0214$  for wet period) which are negligible small. Plots of the residuals versus model computed values can be more informative regarding model fitting to a data set. If the residuals appear to behave randomly it suggests that the model fits the data well. On the other hand, if non-random distribution is evident in the residuals, the model does not fit the data adequately. On the base of these results, we propose ANFIS-SC and ANN (LM) methods as effective tools for the computation of total dissolved solids in river water, respectively.

**Conclusion:** It can be concluded that the ANN with Levenberg-Marquardt training algorithm and ANFIS-SC models can be considered as promising tools for forecasting TDS values, based on water quality parameters. With attention to the aim of current research that is presenting the feasibility of artificial intelligence techniques

1 and 2- Associate Professor and Ph.D. Candidate, Department of Water Engineering, Urmia University  
(\*- Corresponding Author Email: montaseri@hotmail.com)

for modeling TDS values, it is notable that the results presented in this paper are for research purpose and applying the abstained results for real-world needs some complicated steps and building artificial intelligences methods, based on complete data and parameters maybe affected the TDS values.

**Keywords:** Adaptive neuro fuzzy inference system, Artificial neural network, Dissolved solids, Zarrineh River