

مقدمه

آب یک منبع حیاتی است که سلامتی و زندگانی انسان را تأمین می‌کند. در نتیجه مطالعه کیفیت منابع آب از مهم‌ترین اولویت‌های حفاظت محیط‌زیست و از عامل‌های مهم در دستیابی به توسعه پایدار در بیشتر جوامع است [۵]. در حال حاضر کیفیت و کیفیت منابع آبی در جهان یک موضوعی نگران‌کننده برای جوامع مختلف می‌باشد. امروزه به خاطر کاهش مقدار آب موجود در دنیا و کاهش آن، رو به آبهای با کیفیت پایین آورده است. بنابراین ارزیابی تغییرات دراز مدت کیفیت آب یک چالش اساسی می‌باشد [۸]. با این حال مطالعات کیفیت آب به علت کاهش چشمگیر منابع آبی در سال‌های اخیر بسیار با اهمیت‌تر گردیده است. از طرفی اندازه‌گیری پارامترهای کیفیت آب بسیار با هزینه بوده و اگر به توان بعضی پارامترها را از روی پارامترهای دیگر اندازه‌گیری شده برآورد کرد، یک مسلسل مهم می‌باشد. در این میان پارامترهای کیفیت آب، کل جامدات محلول یکی از شاخص‌های مهم ارزیابی کیفیت آب می‌باشد [۱۸]. میزان کل جامدات محلول در آب مشخص کننده کلی پایداری منابع آبی به عنوان آب آشامیدنی و هم چنین استفاده‌های صنعتی و کشاورزی است [۳]. بنابراین با روش‌های مختلفی از جمله تکنیک‌های هوش مصنوعی می‌توان پارامترهای کیفیت آب مانند کل جامدات محلول در آب را پیش‌بینی کرد.

در سال‌های اخیر استفاده از تکنیک‌های هوش مصنوعی شامل شبکه عصبی مصنوعی^۱، نرو فازی^۲، برنامه‌ریزی بیان ژن^۳ و ماشین پشتیبان بردار^۴ برای پیش‌بینی و برآورد پارامترهای مختلف زیاد شده است [۱۴]. مطالعات زیادی در مورد پیش‌بینی کیفیت آب انجام شده است که شامل: دیامونتوپولا و همکاران [۸] جهت پیش‌بینی پارامترهای کیفیت آب در رودخانه اکسیوس^۵ (شمال یونان) از تکنیک شبکه عصبی مصنوعی برای پیش‌بینی پارامترهای کیفیت بسیار مناسب بوده و هم چنین یک ابزار کارا برای برآورد مقادیر اندازه‌گیری نشده یا مفقوده می‌باشد. پیش‌بینی پارامترهای معدنی آب بوسیله پارامترهای فیزیکی آب در هند توسط کاندووال و سینق [۶] مطالعه شده است. این محققین جهت پیش‌بینی پارامترهای سولفات Cl⁻, COD, TDS

- 4- ANNs
- 5- ANFIS
- 6- GEP
- 7- SVM
- 8- Axios

ارزیابی کارایی مدل‌های M₅ و MLP در برآورد میزان کل جامدات محلول (مطالعه موردی: حوزه آبخیز لیقوان)

مجید کاظم زاده^{*}، وحید عظیمی^۲ و شهرام خلیقی سیگارودی^۳
تاریخ دریافت: ۱۳۹۳/۰۸/۱۹ تاریخ پذیرش: ۱۳۹۳/۱۱/۰۵

چکیده:

پارامتر کل جامدات محلول عامل مهمی در بررسی کیفیت آب بوده و اثر زیادی در جابه‌جایی و یونیزه شدن و تبدیل شیمیایی مواد دارد. هم‌چنین غلظت املاح محلول در تخصیص آب برای مصارف شرب انسان، دام، کشاورزی و صنعتی نقش مهمی دارد. بنابراین هدف از این پژوهش پیش‌بینی میزان کل جامدات محلول تحت یک مطالعه موردی در حوزه آبخیز لیقوان با استفاده از مدل‌های M₅ و MLP می‌باشد. منطقه مورد مطالعه یکی از زیر حوزه‌های دریاچه ارومیه و داده‌های انتخاب شده از دو ایستگاه آب‌سنجدی بصورت ماهانه طی دوره ۱۳۸۹ تا ۱۳۵۱ است. در حالت کلی نتایج نشان MLP داد با توجه به معیارهای ارزیابی کارایی مدل‌های M₅ و M₅ توانایی خوبی در پیش‌بینی کل جامدات محلول داشته و هم‌چنین در بیشتر موارد هر دو نتایجی یکسانی را نشان داده است. در ایستگاه لیقوان در بین شش سناریو بر حسب ترکیب ورودی‌های مدل‌های M₅ و MLP، سناریوهای پنج و شش پیش‌ترین ضریب همبستگی را بین مقادیر مشاهداتی و برآورده نشان داده و با توجه به نزدیک بودن معیارهای ارزیابی این سناریوهای سناریوهای پنج و شش بهترین سناریوها معرفی گردیدند. در ایستگاه هروی نتایج نشان داد سناریو پنج بهترین سناریو ورودی برای پیش‌بینی کل جامدات بوده است. در حالت کلی سناریو پنج با پارامترهای ورودی Na^+ , Ca^{2+} , HCO_3^- , Mg^{2+} , TDS بهترین نتیجه را نشان داد.

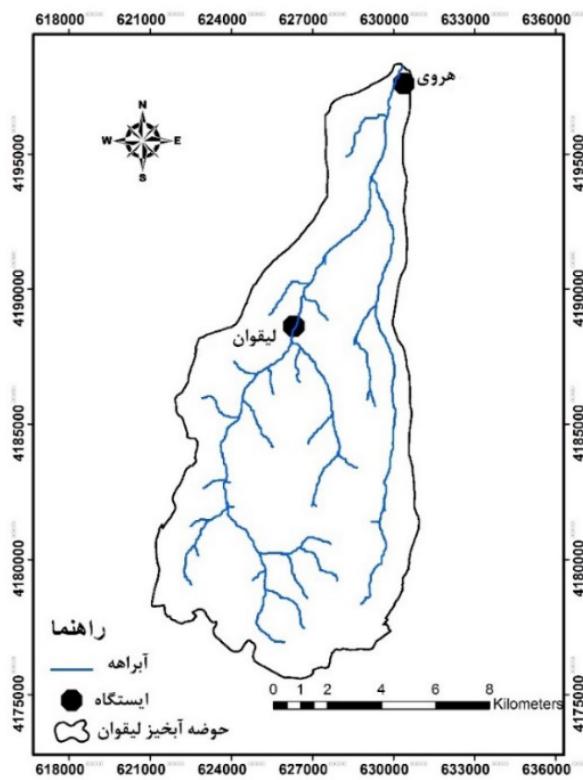
کلید واژه‌ها: کل جامدات محلول، مدل M₅ و MLP، پیش‌بینی، حوزه آبخیز لیقوان

۱ - دانشجوی کارشناسی ارشد دانشکده منابع طبیعی دانشگاه تهران

*نویسنده مسئول Mkazemzadeh@ut.ac.ir

۲ - دانشجوی کارشناسی ارشد پردیس فنی و مهندسی دانشگاه شهید بهشتی

۳ - استادیار دانشکده منابع طبیعی دانشگاه تهران



شکل ۱- موقعیت جغرافیایی ایستگاه‌های آب‌سنجی
Fig 1. Geographic location of hydrometric stations

آب سطحی روخانه جوهرار^۳ (مالزی) ارزیابی کردند. نتایج کار آنها نشان داد که استفاده از شبکه‌های عصبی مخصوصاً مدل‌های تابع پایه شعاعی^۴ بر خلاف مدل‌های رگرسیونی ساده‌مدی توانند با صحت بیشتر رفتار پارامترهای کیفیت آب را توصیف کنند. زمان زاد قویدل و متصری [۱۸] کاربرد روش‌های مختلف داده مینما را در پیش‌بینی کل جامدات محلول در زاینده رود ارزیابی کردند. آنها به این نتیجه رسیدند که مدل‌های ANFIS-SC، ANFIS-GP، GEP و ANN می‌توانند به طور موثر در پیش‌بینی تغییرات کل جامدات محلول استفاده شوند. هم چنین در بین روش‌های مختلف هوش مصنوعی GEP نسبت به مدل‌های دیگری در پیش‌بینی این پارامتر برتری داشته است. ستاری و همکاران [۱۴] جهت پیش‌بینی دبی روزانه در ترکیه از مدل‌های ماشین پیش‌تیان بردار و M₅ استفاده کردند. نتایج نشان داد که دو مدل استفاده شده کارایی بهتری را در پیش‌بینی دبی روزانه داشتند. حوزه لیقوان در شرق دریاچه ارومیه قرار گرفته است که در سال‌های اخیر استفاده بیش از حد آب رودخانه‌ها باعث کاهش کمیت آب شده و از طرفی در بیشتر موارد با کاهش کمیت آب سبب افزایش غلظت کل جامدات محلول آب می‌شود. بنابراین در این تحقیق با استفاده از مدل‌های M₅ و MLP کل جامدات محلول آب تحت سناریوهای ورودی مختلف و

و TSS از روی پارامترهای pH، دما و سختی، از روش‌های شبکه عصبی مصنوعی و رگرسیون چند متغیره^۵ استفاده کردند. آنها نشان دادند که نتایج شبکه عصبی مصنوعی در مقایسه با رگرسیون چند متغیره در پیش‌بینی پارامترها قابل قبول و رضایت‌بخش بود. یانگ و همکاران [۱۷] کیفیت آب را با استفاده از شبکه عصبی منصوبی در مخزن یوکیاو^۶ چین پیش‌بینی کردند. نتایج آنها نشان داد که روش مورد استفاده کارایی زیادی در پیش‌بینی کیفیت آب مخزن داشته است. اسداله فردی و همکاران [۴] دو نوع شبکه عصبی مصنوعی شامل MLP و RNN را جهت پیش‌بینی کل جامدات محلول در تخلخ رود استفاده کردند. نتایج تحقیق آنها نشان داد که کارایی و عملکرد روش RNN در پیش‌بینی پارامتر TDS بهتر از MLP بوده است.

عباسی مائده و همکاران [۱] کاربرد شبکه عصبی در برآورد تغییرات کل جامدات محلول آب زبرزمینی دشت تهران ارزیابی کردند. این محققان از ۵ سناریو مختلف جهت پیش‌بینی و به عنوان ورودی مدل در نظر گرفتند. آنها دریافتند که با استفاده از پارامترهای کیفی می‌توان مقدار کل جامدات محلول را پیش‌بینی کرد. هم چنین نتایج آنها نشان داد که مدل پنج با پارامترهای ورودی Na^+ ، SO_4^{2-} و Cl^- خطا‌ی کمتری بین مقادیر مشاهده‌ی و برآورد شده داشته است. نجاه و همکاران [۱۱] کاربرد شبکه‌های عصبی در برآورد کیفیت

4- Johar
4- RBF

1- MVR
2- Yuqiao

در این رابطه T مجموعه‌ای از نمونه‌هاست که به هر گره وارد می‌شود، T_i نشان‌دهنده‌ی زیر مجموعه‌ای از نمونه‌هاست که i امین نتیجه تست پتانسیلی را دارند، بیانگر انحراف معیار، i و N شماره داده‌ها می‌باشد [۲]. در این مطالعه از نرم‌افزار $Weka$ ۳,۷,۱۰ که در دانشگاه Waikato کشور نیوزلند توسعه یافته استفاده شده است.

شبکه عصبی پرسپترون چند لایه یا MLP: شبکه‌های عصبی مصنوعی از فرایند موجود در شبکه‌های عصبی مغز انسان الگوپردازی می‌کنند. ایده آن برای اولین بار در سال ۱۹۴۰ در یکی از دانشکده‌های روانپژوهی مطرح شد. شبکه‌های عصبی مصنوعی در رشته‌های مختلف استفاده شده است که اصول کلی آن شامل طبقه‌بندی، شناسایی و تشخیص الگوها و کنترل سیستم‌ها است [۷]. متداول‌ترین شبکه‌ها در پیش‌بینی و حل مسائل غیرخطی شبکه‌های عصبی پرسپترون چند لایه می‌باشند. به طور کلی ساختار شبکه‌های عصبی پرسپترون چند لایه، از سه قسمت مهم ورودی، لایه پنهان و خروجی تشکیل شده است که در معماری ساختار شبکه در هر لایه تعدادی نرون در نظر گرفته می‌شود. تعداد ورودی‌ها و خروجی‌ها وابسته به ماهیت مسئله مورد تحقیق فرق می‌کند، در حالی که تعداد نرون‌های موجود در لایه پنهانی و همچنین تعداد این لایه‌ها، با سعی ژو خطا مشخص می‌شود. بنابراین در تحقیق از شبکه عصبی مصنوعی پرسپترون چند لایه با استفاده از نرم افزار $Weka$ ۳,۷,۱۰ از استفاده شده است [۱۰].

معیارهای ارزیابی کارایی مدل

در این تحقیق به منظور ارزیابی دقت برآوردهای هریک از مدل‌ها از پنج معیار ارزیابی خطای شامل ریشه میانگین مربع خطای میانگین خطای بایاس، میانگین مطلق خطای و ضریب ناش - ساتکلیف و ضریب تبیین استفاده شده است که در ادامه آورده شده است: در روابط فوق P_i و O_i به ترتیب مقادیر برآوردهای و i و t مربوط به رتبه داده‌ها می‌باشد.

$$RMSE = \sqrt{\sum_{i=1}^t \frac{1}{t} (p_i - o_i)^2} \quad (2)$$

$$R = 1 - \frac{\sum_{i=1}^t (p_i - o_i)^2}{\sum_{i=1}^t (o_i - \bar{o}_i)^2} \quad (3)$$

$$NSC = 1 - \frac{\sum_{i=1}^n (o_i - p_i)^2}{\sum_{i=1}^n (o_i - \bar{o}_i)^2} \quad (4)$$

$$MBE = \frac{\sum_{i=1}^t |p_i - o_i|}{t} \quad (5)$$

$$MBE = \frac{\sum_{i=1}^t (p_i - o_i)}{t} \quad (6)$$

داده‌های ماهانه کیفیت آب طی ۱۳۵۱ تا ۱۳۸۹ در حوزه آبخیز لیقوان برآورده شده است.

منطقه مورد مطالعه

منطقه مورد مطالعه، حوزه لیقوان در شرق دریاچه ارومیه و یکی از زیر حوزه دریاچه ارومیه می‌باشد. مساحت حوزه آبخیز لیقوان با مساحت ۷۶ کیلومتر مربع بین طول‌های شرقی ۴۶ درجه و ۲۰ دقیقه و ۳۰ ثانیه تا ۴۶ درجه و ۲۷ دقیقه و ۳۰ ثانیه و عرض‌های شمالی ۳۷ درجه و ۴۲ دقیقه و ۵۵ ثانیه تا ۳۷ درجه و ۴۹ دقیقه و ۳۰، قرار گرفته است. موقعیت ایستگاه‌ها و منطقه مورد مطالعه در شکل (۱) آورده شده است. این منطقه در مناطق مرتفع کوه سهند قرار گرفته است که در بیشتر فصل‌های بارشی دارای پوشش برف و دارای رژیم برفی می‌باشد.

در این تحقیق با استفاده از پارامترهای Mg^{2+} , HCO_3^- , Ca^{2+} , Na^+ , SO_4^{2-} کیفیت آب، کل جامدات محلول که تحت تاثیر پارامترهای مختلف کیفیت آب می‌باشد، پیش‌بینی شده است. جهت پیش‌بینی از ۳۴۸ سری داده روزانه پارامترهای کیفیت آب در ایستگاه لیقوان و ۲۸۰ سری داده روزانه در ایستگاه هروی در بین سال‌های آبی ۱۳۵۱ الی ۱۳۸۹ استفاده شد. از میان سری داده‌های ایستگاه لیقوان ۲۴۴ سری برای آموزش و ۱۰۴ سری برای آزمون در نظر گرفته شد. هم‌چنین از میان سری داده‌های ایستگاه هروی ۱۹۶ سری برای آموزش و ۸۴ سری برای آزمون انتخاب گردید.

مواد و روش‌ها

مدل M_5 : مدل درختی M_5 زیر مجموعه‌ای از روش‌های داده‌کاوی و یادگیری ماشینی می‌باشد که توسط کوئین لان [۱۲] ارائه گردیده است. داده‌کاوی و یادگیری ماشینی به عنوان یکی از شاخه‌های هوش مصنوعی می‌باشد که از هدف آنها این می‌باشد که با افزایش تعداد داده‌ها عملکرد بهتری را از خود نشان دهند. در این روش فضای محدوده مقادیر داده‌های ورودی به چند زیر بازه یا ناحیه تقسیم شده و برای هر ناحیه یک معادله یا مدل مناسب استخراج می‌شود [۶]. ساختار این مدل‌ها شامل ریشه، گره‌های داخلی و برگ می‌باشد که در حل بسیاری از مسایل طبقه‌بندی و رگرسیون استفاده می‌شوند. تشکیل ساختار این مدل‌ها شامل مراحل ایجاد درخت و هرس کردن آن است که در مرحله ساخت مدل M_5 از یک الگوریتم استنتاتیجی یا معیار تقسیم (انشعاب) برای تولید یک درخت تصمیم استفاده می‌شود [۱۶]. در این روش خطای مدل عموماً با اندازه‌گیری دقت پیش‌بینی مقادیر هدف موارد دیده نشده سنجش می‌شود. فرمول محاسبه کاهش انحراف استاندارد^۱ بصورت رابطه یک می‌باشد.

$$SDR = Sd(T) - \sum_{i=1}^N \frac{|T_i|}{|T|} Sd(T_i) \quad (1)$$

1 - Standard Deviation Reduction

جدول ۱ - همبستگی بین پارامترهای کیفیت آب سطحی در منطقه مورد مطالعه
Table 1. Correlation between parameters of surface water quality in study area

TDS	SO_4^{2-}	Mg^{2+}	HCO_3^-	Ca^{2+}	^+Na	Station	ایستگاه
0.341	0.125	0.002	0.020	0.030	1.000	^+Na	لیقوان
0.313	0.047	0.003	0.310	1.000		Ca^{2+}	
0.668	0.000	0.229	1.000			HCO_3^-	
0.260	0.031	1.000				Mg^{2+}	
0.085	1.000					SO_4^{2-}	Lighvan
1.000						TDS	
0.303	0.010	0.007	0.197	0.014	1.000	^+Na	هرمی
0.354	0.006	0.001	0.322	1.000		Ca^{2+}	
0.584	0.004	0.097	1.000			HCO_3^-	
0.122	0.084	1.000				Mg^{2+}	
0.110	1.000					SO_4^{2-}	Hervi
1.000						TDS	

جدول ۲ - ترکیب ورودی‌های مختلف در شش سناریو
Table 2. Combination of different inputs in 6 scenarios

خروجی	ترکیب ورودی‌ها	سناریو	مدل
Outputs	Inputs combination	Scenario	Model
TDS	HCO_3^-	1	MLP 'M5
TDS	Ca^{2+} , HCO_3^-	2	MLP 'M5
TDS	Na^+ , HCO_3^-	3	MLP 'M5
TDS	Na^+ , Ca^{2+} , HCO_3^-	4	MLP 'M5
TDS	Mg^{2+} , Na^+ , Ca^{2+} , HCO_3^-	5	MLP 'M5
TDS	SO_4^{2-} , Na^+ , Ca^{2+} , HCO_3^-	6	MLP 'M5

توضیح می‌باشد که ترتیب و ترکیب پارامترهای ورودی بر اساس همبستگی بین پارامترهای ورودی و پارامتر خروجی بوده است. بنابراین پارامترهای ورودی تحت شش سناریو مختلف طراحی شده است که به ترتیب بیشترین همبستگی را با کل جامدات محلول داشته‌اند.

با توجه به این که هدف اصلی تحقیق برآورده و پیش‌بینی کل جامدات محلول در حوزه آبخیز لیقوان با استفاده از دو مدل M5 و MLP بوده است. بنابراین جهت ارزیابی کارایی دو مدل و همچنین تعیین بهترین سناریو از معیارهای ارزیابی خط استفاده شده است که نتایج آنها در جدول (۳) آورده شده است. در ایستگاه لیقوان که در بالادست حوزه آبخیز قرار گرفته است، در بین سناریوهای مختلف بر اساس M5 و MLP سناریو پنج بیشترین ضریب همبستگی

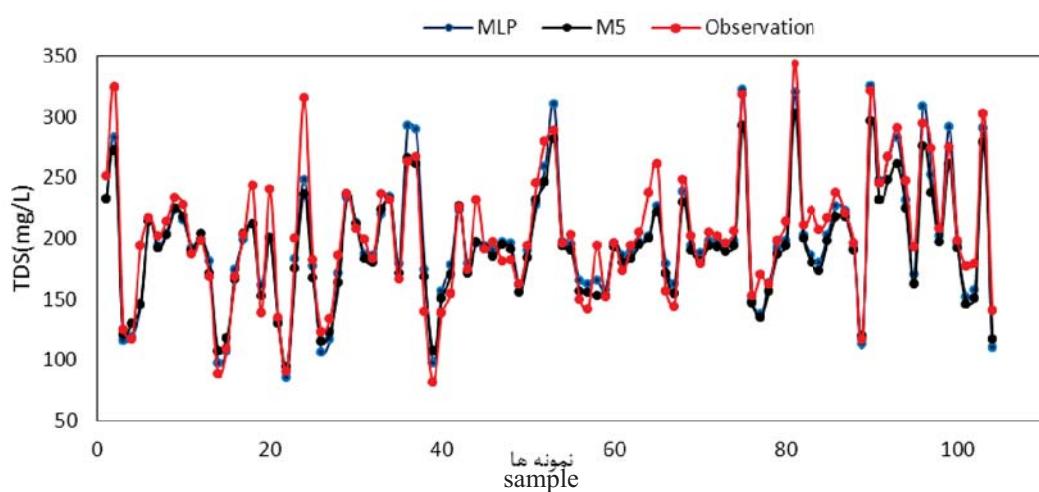
نتایج

جدول (۱) همبستگی بین پارامترهای ورودی مدل‌های پیش‌بینی با خروجی مدل‌ها را نشان می‌دهد. همان طور که مشخص است پارامتر HCO_3^- بیشترین همبستگی را با مقادیر TDS در دو ایستگاه آب سنگی لیقوان و هرمی داشته است. در صورتی که کمترین همبستگی در بین ورودی‌های مدل‌ها با کل جامدات محلول SO_4^{2-} بوده است. ورودی‌های مدل باقیستی به نوعی مستقل از هم باشند تا به عنوان ورودی مدل انتخاب شوند، بنابراین نتایج همبستگی نشان داد که همبستگی بین همه‌ی ورودی‌ها کمتر از ۰/۳۵ بوده است. جهت پیش‌بینی کل جامدات محلول آب در حوزه آبخیز لیقوان ترکیب ورودی‌های مختلف در دو مدل M5 و MLP استفاده شد که ترکیب ورودی‌ها در جدول (۲) نشان داده شده است. لازم به

جدول ۳- معیارهای ارزیابی کارایی مدل‌های M5 و MLP

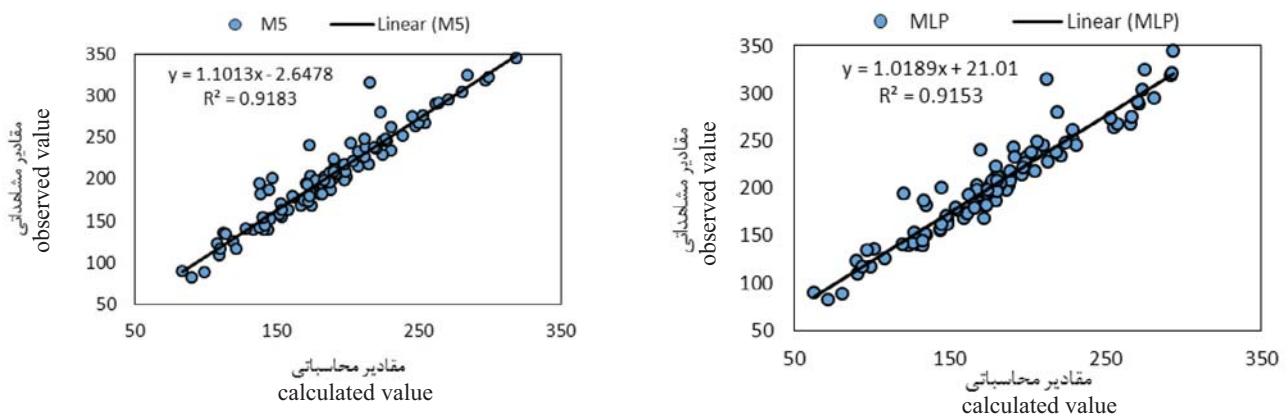
Table 3. Criteria of performance evaluation in MLP and M5 models

تست						آموزش					مدل
Test						Train					Model
MBE	MAE	RMSE	NSE	R	MBE	MAE	RMSE	NSE	R	Scenario	
-4.29	14.69	21.74	0.83	0.87	-0.84	8.53	13.83	0.78	0.91	1	
-6.86	15.79	23.22	0.81	0.87	-0.08	15.09	22.02	0.79	0.82	2	
-6.06	12.86	19.68	0.86	0.92	-0.20	14.92	21.15	0.77	0.81	3	
-7.47	13.73	20.62	0.85	0.91	-1.00	12.15	18.17	0.79	0.88	4	M5
-14.04	14.33	20.28	0.85	0.96	-0.96	8.71	14.07	0.87	0.90	5	(Lighvan)
-9.37	12.86	18.68	0.87	0.95	-0.64	11.40	18.15	0.89	0.86	6	
1.41	21.23	29.45	0.69	0.83	12.54	20.68	27.26	0.77	0.77	1	
-1.64	20.65	29.14	0.70	0.83	9.87	19.34	26.10	0.75	0.78	2	
-4.29	17.49	28.98	0.76	0.89	6.02	16.25	22.86	0.77	0.80	3	
-7.87	14.96	22.95	0.81	0.91	0.17	13.91	20.54	0.82	0.84	4	MLP
-20.04	20.04	25.68	0.87	0.96	-8.05	12.12	16.61	0.89	0.91	5	(Lighvan)
-3.80	11.01	16.01	0.88	0.94	2.02	14.47	18.07	0.89	0.87	6	
-4.31	20.04	25.17	0.77	0.83	0.00	22.08	28.75	0.70	0.70	1	
-4.04	18.20	22.68	0.83	0.87	0.00	21.27	28.00	0.72	0.72	2	
-6.60	17.71	22.90	0.82	0.88	0.00	20.62	27.28	0.75	0.74	3	
-6.62	14.86	19.00	0.83	0.93	0.00	19.45	25.84	0.79	0.77	4	M5
-15.07	15.74	20.35	0.88	0.95	0.00	10.81	16.34	0.84	0.91	5	(Hervi)
-7.42	14.66	19.02	0.87	0.92	-0.01	14.37	20.90	0.83	0.86	6	
-14.07	22.41	29.07	0.66	0.83	-7.74	22.53	29.61	0.67	0.71	1	
-11.61	20.74	26.53	0.74	0.87	-5.53	22.00	28.97	0.69	0.71	2	
-13.97	19.91	26.78	0.73	0.88	-6.14	20.93	28.04	0.72	0.73	3	
-1.75	15.53	19.45	0.80	0.90	4.53	20.15	25.99	0.79	0.77	4	MLP
-13.39	14.66	19.14	0.81	0.95	2.14	10.91	16.45	0.84	0.92	5	(Hervi)
-3.69	14.64	19.07	0.81	0.91	-4.53	15.85	21.15	0.83	0.84	6	



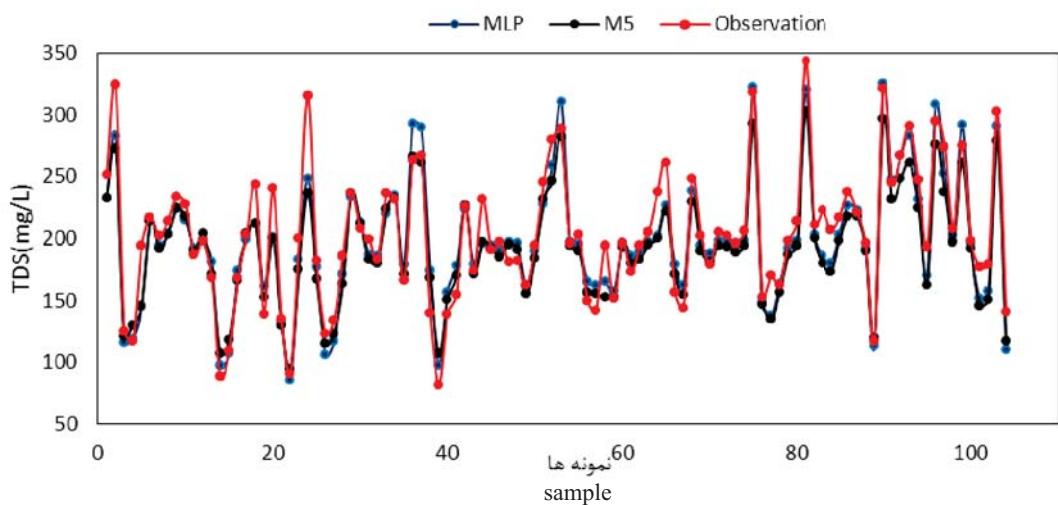
شکل ۲- مقادیر محاسباتی و مشاهداتی کل جامدات محلول برای سناریو پنج (ایستگاه لیقوان)

Fig 2. Estimation and observation magnitudes of total dissolved solids for 5 scenarios (Lighvan station)



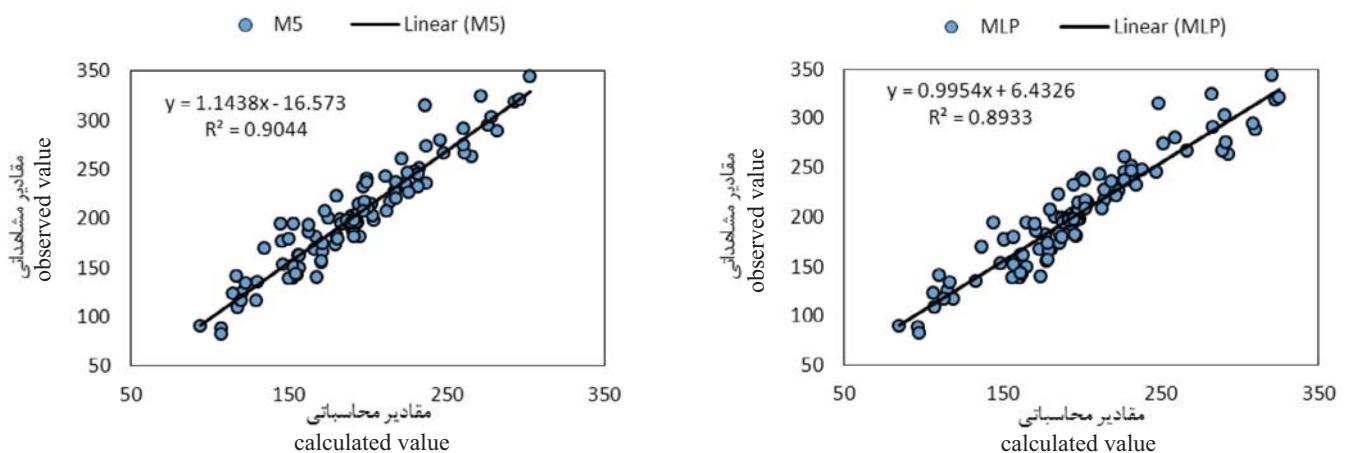
شکل ۳- مقادیر محاسباتی و مشاهداتی کل جامدات محلول برای سناریو پنجم در مدل‌های M₅ و MLP (ایستگاه لیقوان)

Fig 3. Estimation and observation magnitudes of total dissolved solids for 5th scenario in MLP and M5 models
(Lighvan station)



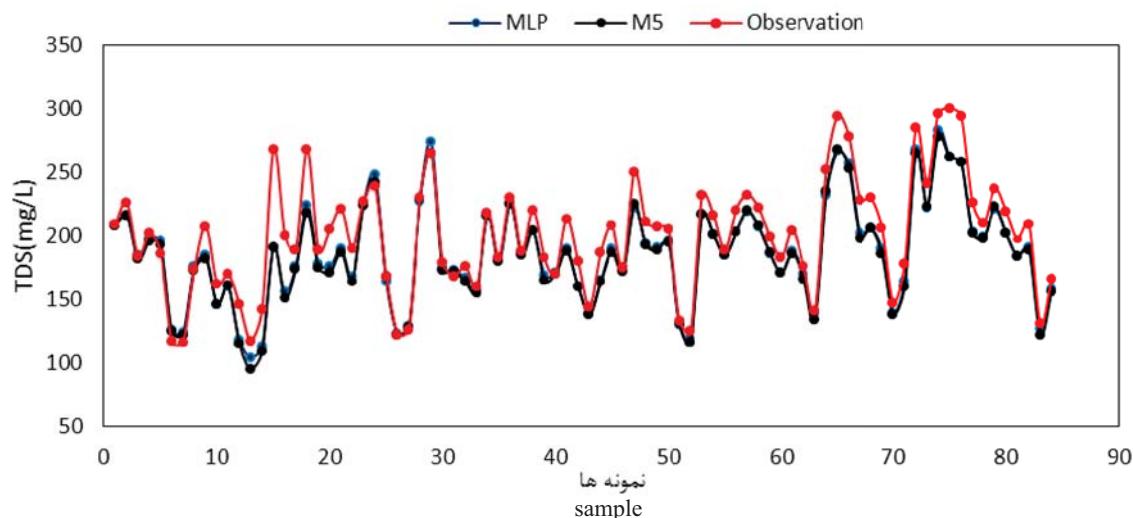
شکل ۴- مقادیر محاسباتی و مشاهداتی کل جامدات محلول برای سناریو ششم (ایستگاه لیقوان)

Fig 4. Estimation and observation magnitudes of total dissolved solids for 6th scenario (Lighvan station)

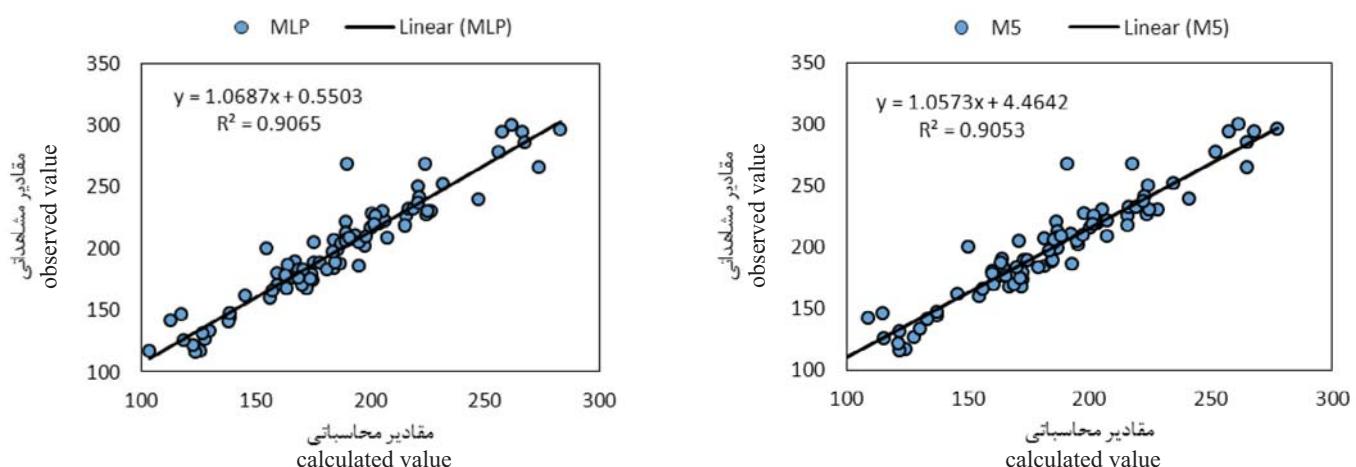


شکل ۵- مقادیر محاسباتی و مشاهداتی کل جامدات محلول برای سناریو ششم در مدل‌های M₅ و MLP (ایستگاه لیقوان)

Fig 5. Estimation and observation magnitudes of total dissolved solids for 6th scenario in MLP and M5 models
(Lighvan station)



شکل ۶- مقادیر محاسباتی و مشاهداتی کل جامدات محلول برای سناریو پنج (ایستگاه هروی)
Fig 6. Estimation and observation magnitudes of total dissolved solids for 5th scenario (Hervi station)



شکل ۷- مقادیر محاسباتی و مشاهداتی کل جامدات محلول برای سناریو پنج در مدل های M5 و MLP (ایستگاه هروی)
Fig 7. Estimation and observation magnitudes of total dissolved solids for 5th scenario in MLP and M5 models (Hervi station)

موقع سناریوهای رده پایین بهتر خواهد بود. شکل های (۲) تا (۵) مقادیر برآورده شده را در مقابل مقادیر مشاهده شده برای کل جامدات محلول برای سناریو پنج و شش در ایستگاه لیقوان نشان می دهد. همان طور که مشخص است در سناریو پنج و شش ضریب تبیین یا R در مدل M5 بیشتر از مدل MLP می باشد. بنابراین این نشان دهنده برتری مدل M5 در پیش بینی کل جامدات محلول در مقابل مدل MLP می باشد. بر عکس نتایج دیامتوپولا و همکاران [۸] در رودخانه اکسیوس (در شمال یونان که)، آنها بیان کردند که شبکه عصبی مصنوعی برای پیش بینی پارامترهای کیفیت بسیار مناسب بوده و هم چنین یک ابزار کارا برای برآورد مقادیر اندازه گیری نشده یا مفقوده می باشد. هم چنین اسد الله فردی [۴] بیان کردند کارایی و عملکرد روش RNN در پیش بینی پارامتر TDS در تلخه رود بهتر از MLP بوده است. در حالت کلی نتایج

(۰/۹۶) با مقادیر مشاهداتی و برآورده را دارد اما مقادیر ریشه دوم میانگین مربعات خطای میانگین مطلق خطای و میانگین اریب خطای در سناریو شش در بخش آزمون کمتر از سناریو پنج بوده است. با توجه به اینکه معیارهای ارزیابی در این دو سناریو نزدیک به هم هستند اما در بخش آموزش مدل، سناریو پنج مقادیر خطای کمتری را نشان داده است. بنابراین سناریوهای پنج به عنوان بهترین سناریو معرفی می گردد. همچنین لازم به ذکر است هر چه تعداد پارامتر ورودی یا مورد نیاز برای پیش بینی کمتر باشد با توجه هزینه های نمونه برداری و یا در دسترس بودن داده ها و ... بهتر می باشد. لذا اگر بخواهیم با کمترین پارامتر ورودی به نتیجه مطلوبی برسیم در این

-
- 1- Root Mean Square Error
 - 2- Mean Absolute Error
 - 3- Mean Bias Error

جدول ۴- معادله‌های حاصل از مدل M₅ برای پیش‌بینی TDS در دو ایستگاه آب‌سنگی

Table 4. M₅ equations for TDS prediction in two hydrometric stations

Scenario	معادله‌های ارائه شده در مدل M ₅ (ایستگاه هروی)
1	TDS= 59.09 * HCO ₃ ⁻ + 70.30
2	TDS= 51.57 * HCO ₃ ⁻ + 20.68 * Ca ²⁺ + 58.01
3	TDS= 49.93 * HCO ₃ ⁻ + 21.60 + Na ⁺ + 65.82
4	TDS= 37.73* HCO ₃ ⁻ + 28.18 * Ca ²⁺ + 26.20* Na ⁺ + 48.13
5	TDS= 8.77 * HCO ₃ ⁻ + 51.71* Ca ²⁺ + 46.91* Na ⁺ + 64.60 * Mg ²⁺ + 14.86
6	HCO ₃ ⁻ <= 1.85: TDS= 26.11* HCO ₃ ⁻ + 25.14 * Ca ²⁺ + 26.10 * Na ⁺ + 43.28 * SO ₄ ²⁻ + 50.72 (106\53.36%) HCO ₃ ⁻ > 1.85: TDS= 66.56 * HCO ₃ ⁻ + 2.61 * Ca ²⁺ + 1.81 * Na ⁺ + 55.05 * SO ₄ ²⁻ + 28.19 (90\49.04%)
Scenario	معادله‌های ارائه شده در مدل M ₅ (ایستگاه لیقوان)
1	TDS= 68.40 * HCO ₃ ⁻ + 53.72
2	HCO ₃ ⁻ <=1.85: HCO ₃ ⁻ <=1.35: TDS= 16.88 * HCO ₃ ⁻ + 54.69 * Ca ²⁺ + 51.82 (47\45.51%) HCO ₃ ⁻ <=1.85: HCO ₃ ⁻ >1.35: TDS= 12.65* HCO ₃ ⁻ + 29.04 * Ca ²⁺ + 109.14 (88\59.27) HCO ₃ ⁻ > 1.85: TDS= 53.79 * HCO ₃ ⁻ + 1.89 * Ca ²⁺ + 85.39
3	TDS= 58.05* HCO ₃ ⁻ + 22.34* Na ⁺ + 48.45 HCO ₃ ⁻ <=1.85: HCO ₃ ⁻ <=1.35: TDS= 11.93 * HCO ₃ ⁻ + 54.23 * Ca ²⁺ + 41.32 * Na ⁺ + 33.41 (47\33.46%)
4	HCO ₃ ⁻ <=1.85: HCO ₃ ⁻ >1.35: TDS= 8.98 * HCO ₃ ⁻ + 30.23 * Ca ²⁺ + 5.94 * Na ⁺ + 107.91 (88\59.27%) HCO ₃ ⁻ >1.85: Na ⁺ <=1.45: TDS= 48.91* HCO ₃ ⁻ + 4.89 * Ca ²⁺ + 6.83 * Na ⁺ + 75.93 (77\40.94%) HCO ₃ ⁻ >1.85: Na ⁺ >1.45: TDS= 56.83 * HCO ₃ ⁻ + 10.53 * Ca ²⁺ - 24.49 * Na ⁺ + 127.19 (24\42.84%)
5	TDS= 13.45* HCO ₃ ⁻ + 48.45 * Ca ²⁺ + 45.02 * Na ⁺ + 53.58 * Mg ²⁺ + 16.64
6	TDS= 54.95 * HCO ₃ ⁻ + 14.33 * Ca ²⁺ + 17.10 * Na ⁺ + 32.58 * SO ₄ ²⁻ + 28.96

با هم نداشته‌اند و از طرفی مقادیر خطای برآورده هم در بخش آموزش مدل‌ها برای سناریو پنج کمتر از بقیه بوده است، بنابراین سناریو ۵ بهترین سناریو ورودی جهت پیش‌بینی کل جامدات محلول انتخاب می‌شود. لازم به توضیح است که شبیه بودن نتایج در بسیاری بخش‌ها در دو ایستگاه مورد مطالعه مربوط به این است که ایستگاه لیقوان در بالادست حوزه بوده و ایستگاه هروی خروجی حوزه آبخیز لیقوان می‌باشد و تقریباً شرایط یکسانی را نشان داده‌اند. شکل‌های (۱) و (۷) مقادیر مشاهداتی و محاسباتی را برای سناریو پنج در هر دو مدل M₅ و MLP را نشان می‌دهد. در این ایستگاه بر عکس ایستگاه لیقوان، ضریب همبستگی بین مشاهداتی و محاسباتی و همچنین خطاهای برآورده در مدل MLP کمتر از M₅ می‌باشد. مدل M₅ بر عکس رگرسیون خطی که برای همه داده‌ها یک معادله خطی بر اساس ورودی‌ها و خروجی ارائه می‌دهد، محدوده داده‌ها را به زیر رده‌های همگن تقسیم نموده و برای هر یک از قسمت‌های

نشان داد که هر دو روش توانایی خوبی در پیش‌بینی پارامتر TDS تحت سناریوهای در نظر گرفته داشتند. هم چنین این شکل‌ها نشان می‌دهند که R سناریو شش در هر دو مدل استفاده شده بیشتر از سناریو شش می‌باشد. بنابراین با توجه به این سناریو پنج شامل پارامترهای ورودی HCO₃⁻, Na⁺, Ca²⁺, Mg²⁺ و تنها تفاوت با سناریو شش جایگزین شدن پارامتر SO₄²⁻ به جای منیزیم می‌باشد و از طرفی همبستگی بین پارامترهای ورودی و خروجی نشان داد که پارامتر Mg²⁺ همبستگی بیشتری از پارامتر SO₄²⁻ به خروجی مدل یا کل جامدات محلول داشت لذا می‌توان ذکر کرد که سناریو پنج بهترین سناریو ورودی برای پیش‌بینی پارامتر TDS می‌باشد. نتایج معیارهای ارزیابی خطای مدل‌ها برای سناریوهای مختلف در ایستگاه هروی همانند ایستگاه لیقوان نشان داد که بیشترین مقدار R (۰/۹۵) بر اساس دو مدل M₅ و MLP برای سناریو پنج بوده است. با توجه به این که بقیه معیارهای ارزیابی آن چنان تفاوتی

مدل پنج با پارامترهای ورودی Na^+ , SO_4^{2-} و Cl^- خطا کمتری بین مقادیر مشاهده‌ی و برآورده شده داشته است.

منابع

- 1- Abbasi Maedeh, P. Mehrdadi, N. Nabi Bidhendi, G.R. and Zare Abyaneh, H. 2013. Application of Artificial Neural Network to Predict Total Dissolved Solids Variations in Groundwater of Tehran Plain, Iran. International Journal of Environment and Sustainability. 1: 10-20.
- 2- Alberg, D. Last, M. and Kandel , A. 2012. Knowledge discovery in data streams with regression tree methods. WIREs Data Mining Knowl Discov. 2: 69-78.
- 3- American Public Health Association. 1992. Standard methods for the examination of water and wastewater, Washington DC.
- 4- Asadollahfardi, G. Taklify, A. and Ghanbari, A. 2011. Application of artificial neural network to predict TDS in Talkheh Rud River. J Irrig Drain Eng. 138(4): 363-370.
- 5- Azarmdel, H. Mostafazadeh, R. and Ghasemi A. 2010. Assessment of Water Quality Monitoring Stations in Gorgan-Roud River, Golestan Province. Iran – Watershed Management Science & Engineering. 4 (10): 57-61. (In Persian)
- 6- Bhattacharya, B. and Solomatine, D.P. 2006. Machine learning in sedimentation modelling. Neural Networks. 19: 208-214.
- 7- Demuth, H. and Beale, M. 2001. Neural network toolbox user's guide. 4: The Math Works, Inc., Natick, Massachusetts, USA.
- 8- Diamantopoulou, M.J. Antonopoulos, V.Z. and Papamichail, D.M. 2005. The use of a neural network technique for the prediction of water quality parameters of Axios River in Northern Greece. European Water Resources Association. 11(12) 55-62.
- 9- Khandelwal, M. and Singh, T.N. 2005. Prediction of mine water quality by physical parameters. Journal of Scientific & Industrial Research. 64: 564-570.
- 10- Kouchakzadeh, M. and Bahmani, A. 2005. Assessment of Artificial Neural Networks Revenue in Reducing Required Parameters for Estimation of Reference Evapotranspiration. Journal of Agricultural Sciences. 4: 87-97.
- 11- Najah, A. El-Shafie, A. Karim, O.A. and El-Shafie, A.H. 2013. Application of artificial neural networks for water quality prediction. Neural Comput & Applic. 22: 187-S201.
- 12- Quinlan, J.R. 1992. Learning with continuous classes. In proceedings AI, 92 (Adams & Sterling, Eds), , Singapore: World Scientific. 343-348.
- 13- Sattari, M.T. Nahrein, F. and Azimi, V. 2013. M5 Model

همگن یک معادله خطی ارائه می‌دهد. بنابراین مشخص است که بعد از طبقه داده‌ها بتوان معادله خطی را تولید کرد بهتر از رگرسیون خطی است که برای کل داده‌ها یک معادله خط ارائه می‌دهد. نتایج حاصل از کاربرد مدل M5 در پیش‌بینی TDS در منطقه مورد مطالعه منجر به ایجاد شش قانون "اگر-آنگاه" در هر ایستگاه شده است که در جدول (۴) آورده شده است. اعداد داخل پرانتز به ترتیب تعداد مواردی از داده‌ها را که در شرایط هر رابطه خطی صدق می‌کند و درصد خطا مربوط به هر رابطه خطی می‌باشد.

بحث و نتیجه‌گیری

در این پژوهش مدل‌های M5 و MLP در برآورد میزان کل جامدات محلول در حوزه آبخیز لیقوان ارزیابی شدند. داده‌های انتخاب شده از دو ایستگاه آب‌سنجدی بصورت ماهانه طی دوره ۱۳۵۱-۱۳۵۰ تا ۱۳۸۹-۱۳۸۸ بوده است. برای ارزیابی مدل‌ها، داده‌ها به دو قسمت شامل آموزش ۷۰ درصد داده‌ها و تست ۳۰ درصد داده‌ها تقسیم شدند. پارامترهای ورودی در شش سناریو مختلف با توجه درجه همبستگی با خروجی ایجاد شدند. نتایج همبستگی نشان داد که پارامتر HCO_3^- بیشترین همبستگی را با مقادیر TDS در دو ایستگاه لیقوان و هروی داشته است. در صورتی که کمترین همبستگی را در بین ورودی‌های مدل‌ها، SO_4^{2-} داشته است. با توجه به معیارهای ارزیابی مدل‌ها، M5 و MLP توانایی خوبی در پیش‌بینی کل جامدات محلول داشته و هم چنین در بیشتر موارد نتایجی یکسانی را این دو روش نشان دادند. به عبارتی نتایج این پژوهش نشان داد که تقریباً کارایی مدل‌های M5 و MLP در پیش‌بینی مقداری کل جامدات محلول یکسان می‌باشدند. ستاری و همکاران [۱۳] بیان کردند که اختلاف نتایج پیش‌بینی تبخیر-تعرق بوسیله شبکه عصبی مصنوعی در مقایسه با M5 خیلی کم بوده است، اما روش M5 روابط ساده خطی، قابل فهم تر و کاربردی‌تری را ارائه می‌کند. در ایستگاه لیقوان که در بالا دست حوزه آبخیز قرار گرفته است، در بین سناریوهای مختلف بر اساس M5 و MLP، سناریو پنج و شش بیشترین ضریب همبستگی را بین مقادیر مشاهداتی و برآورده نشان دادند و با توجه به نزدیک بودن معیار ارزیابی‌ها این سناریوهای سناریوهای پنج و شش بهترین سناریوها معرفی گردیدند. در ایستگاه آب‌سنجدی هروی نتایج نشان داد سناریو پنج بهترین سناریو ورودی برای پیش‌بینی کل جامدات بوده است. نتایج ارزیابی مدل‌های M5 و MLP نشان داد که کارایی مدل M5 در پیش‌بینی کل جامدات محلول در ایستگاه لیقوان (عکس ایستگاه هروی) بهتر از MLP بوده است. بنابراین با توجه به معیارهای ارزیابی مدل‌ها تقریبی این دو روش نتایجی یکسانی را در پیش‌بینی کل جامدات محلول را داشتند. در حالت کلی سناریو ۵ با پارامترهای ورودی HCO_3^- , Na^+ , Ca^{2+} , Mg^{2+} , SO_4^{2-} در پیش‌بینی TDS بهترین نتیجه را نشان داد. عباسی مائده و همکاران [۱] دریافتند که با استفاده از پارامترهای کیفی می‌توان مقدار کل جامدات محلول را پیش‌بینی کرد. هم چنین نتایج آنها نشان داد که

- 17- Witten, I.H. and Frank, E. 2005. Data mining: practical machine learning tools and techniques with Java implementations. Morgan Kaufmann: San Francisco.
- 18- Ying, Z. Jun, N. Fui-yi, C. and Liang, G. 2007. Water quality forecast through application of BP neural network at Yuqiao reservoir. *Journal of Zhejiang University SCIENCE A*. 8(9): 1482-1487.
- 19- Zaman Zad Ghavidel, S. and Montaseri, M. 2014. Application of different data-driven methods for the prediction of total dissolved solids in the Zarinehroud basin. *Stoch Environ Res Risk Assess*. 28: 2101–2118.
- Trees and Neural Networks Based Prediction of Daily ET0 (Case Study: Bonab Station). *Iranian Journal of Irrigation and Drainage*. 1(7): 104-113. (In Persian)
- 14- Sattari, M.T. Pal, M. Apaylin, H. Ozturk, F. 2013. M5 Model Tree Application in Daily River Flow Forecasting in Sohu Stream, Turkey. *Water Resources*. 40: 223-242.
- 15- Verma, A. Wei, X. and Kusiak, A. 2013. Predicting the total suspended solids in wastewater: a data-mining approach. *Eng Appl Artif Intell*. 26(4): 1366–1372.
- 16- Wang, Y. Guo, S. Chen, H. and Zhou , Y. 2014. Comparative study of monthly inflow prediction methods for the Three Gorges Reservoir. *Stoch Environ Res Risk Assess*. 28(3): 555–570.