

ارزیابی کارایی شبکه عصبی مصنوعی در پیش‌بینی شاخص‌های کیفی (DO و BOD) آب رودخانه دره مرادبیک همدان

احسان علیائی¹، حسین بانژاد^{2*}، محمدتقی صمدی³، علیرضا رحمانی⁴ و محمدحسین ساقی⁵

تاریخ دریافت: 89/2/13 تاریخ پذیرش: 89/5/6

1-2- دانشجوی کارشناسی ارشد و استادیار، گروه مهندسی آب، دانشگاه بوعلی سینا، همدان

3-4- استادیار و دانشیار، گروه مهندسی بهداشت محیط، دانشگاه بوعلی سینا، همدان

5- دانشجوی سابق کارشناسی ارشد، گروه مهندسی بهداشت محیط، دانشگاه علوم پزشکی همدان

* مسئول مکاتبه E-mail: hossein_banejad@yahoo.com

چکیده

یکی از عوامل مهم توسعه در هر منطقه فراهم بودن منابع آب مناسب می‌باشد. در این راستا علاوه بر کمیت، توجه به وضع کیفی آن نیز از اهمیت شایانی برخوردار است. هدف از این تحقیق کاربرد مدل شبکه عصبی پرسپترون چند لایه در مدل‌سازی شاخص‌های کیفی آب رودخانه‌ها است. در این مطالعه از اطلاعات و داده‌های شامل 10 متغیر کیفی ماهانه آب رودخانه دره مراد بیک همدان در طول یک سال و در شش ایستگاه برای مدل‌سازی اکسیژن مورد نیاز بیولوژیکی (BOD) و اکسیژن محلول (DO) بعنوان شاخص‌های مؤثر بر کیفیت آب استفاده شد. کارایی مدل شبکه‌های عصبی توسط معیارهای آماری ضریب همبستگی (R)، ریشه مربع میانگین خطا (RMSE) و میانگین قدرمطلق خطا (MAE) مورد ارزیابی قرار گرفت. با ساختار شبکه بهینه برای مدل‌سازی BOD و DO ضریب همبستگی به ترتیب 0/986 و 0/969 و ریشه مربعات خطا به ترتیب 8/42 و 0/84 بدست آمدند. نتایج برآمده از این مطالعه نشان دهنده کارایی مناسب شبکه عصبی پرسپترون چند لایه بعنوان تکنیکی برتر برای شبیه‌سازی تغییرات شاخص‌های BOD و DO می‌باشد.

واژه‌های کلیدی: رودخانه مراد بیک، شاخص‌های کیفیت آب، شبکه عصبی مصنوعی، BOD، DO

Performance Evaluation of Artificial Neural Networks for Predicting Rivers

Water Quality Indices (BOD and DO) in Hamadan Morad Beik River

E Olyaie¹, H Banejad^{2*}, MT Samadi³, AR Rahmani⁴ and MH Saghi⁵

Received: 03 May 2010 Accepted: 28 July 2010

^{1,2}MSc Student, and Assist. Prof., Water Engin. Dept., Bu Ali Sina Univ. of Hamadan, Iran.

^{3,4} Assist. and Assoc. Prof., Environ. Health Engin. Dept., BuAli Sina Univ. of Hamadan, Iran.

⁵Former Msc Student, Environ. Health Engin. Dept. ., BuAli Sina Hamadan Univ. of Medical Science, Iran.

*Corresponding author: E-mail: hossein_banejad@yahoo.com

Abstract

One of the important factor for development in each region is the availability of appropriate water resources. In addition to water quantity quality is also of great importance. The aim of this study is to medel the qualitative indices (BOD, DO) of river water using multi-layer perceptron neural network. In this paper, the information and data from Morad Beik river of hamadan including 10 monthly parameters of water quality in a one-year period and at six stations were used to predict biological exygen demand (BOD) and dissolved oxygen (DO), as indices affecting water quality. Efficiency of the neural network model was evaluated by some statistical criteria including correlation coefficient (R), root mean square error (RMSE) and mean absolute error (MAE). In the optimum structure of neural network the correlations coefficient for BOD and DO were 0.986 and 0.969, and root mean square errors were 8.42 and 0.84 respectively. The results indicated the ability of multi-layers perceptron neural network as a suitable technique for simulating changes in BOD and DO indices.

Keywords: BOD, DO, Multi layer perceptron neural networks, Morad Beik river, Water quality indices

مدل‌سازی پارامترهای کیفی آب یکی از مؤلفه‌هایی است که در برنامه‌ریزی‌های مدیریتی باید به‌دقت مورد لحاظ قرار گیرد. شاخص‌های آلودگی زیست محیطی در یک سیستم آبی مانند رودخانه با در نظر گرفتن شرایط اکسیژن مورد نیاز بیولوژیکی¹ (BOD) و کاهش سطح اکسیژن محلول² (DO) قابل ارزیابی است. BOD

مقدمه

امروزه نقش منابع آب و مشخصاً سیستم‌های رودخانه‌ای به عنوان شریان‌های حیاتی هر منطقه یکی از مهم‌ترین پایه‌های توسعه پایدار بشمار می‌روند. این درحالی است که علاوه بر مسئله کمیت و آورد، کیفیت آب رودخانه‌ها نیز از پارامترهای حائز اهمیت است. یکی از مهم‌ترین عوامل تهدید کننده این منابع خدادادی تخلیه بی‌رویه پساب‌ها است. لذا کنترل آلودگی با تخمین و

¹ Biological oxygen demand

² Dissolved oxygen

فرایندهای هیدرولوژیکی متفاوت است که دسترسی به آنها همواره محتاج صرف زمان و هزینه بوده است. با گسترش روزافزون روش‌های رایانه‌ای از جمله هوش مصنوعی¹، استفاده از مدل شبکه‌های عصبی مصنوعی² که با الهام گرفتن از ساختار مغز بشر عمل می‌نماید، بطور گسترده‌ای در مطالعات مربوط به پیش‌بینی پارامترهای مختلف منابع آب مورد استفاده قرار گرفته و محققان بر دقت بالای این روش در مقایسه با روابط تجربی و رگرسیونی تاکید نموده‌اند (کو و همکاران 2004 و کو و همکاران 2007). برعکس بسیاری از مدل‌های پایه آماری کیفیت آب، که با فرض رابطه خطی بین مقادیر واقعی و مقادیر پیش‌بینی شده عمل می‌نمایند، شبکه‌های عصبی مصنوعی قادر به ترسیم رابطه غیر خطی نشات گرفته از خصوصیات و ماهیت واقعی اکوسیستم‌ها هستند (می و سیواکومار 2009). بطوریکه طی دهه‌های اخیر شبکه‌های عصبی مصنوعی به شکل گسترده‌ای مورد توجه محققان علوم مختلف از جمله مهندسی آب قرار گرفته است. رویکرد شبکه‌های عصبی دارای چندین مزیت نسبت به روش‌های مرسوم یا مدل‌های نیمه تجربی است. از جمله اینکه بیشتر این روش‌ها نیازمند پارامترهای ورودی زیادی می‌باشند. درحالیکه شبکه‌های عصبی با حداقل پارامترهای اندازه‌گیری شده، با دقت قابل قبولی تغییرات پارامتر مورد نظر را پیش‌بینی می‌نمایند (بوورز و شدرو 2000). از جمله تحقیقات انجام شده در زمینه کاربرد شبکه عصبی مصنوعی در مسائل مربوط به کیفیت آب می‌توان به کار هور و همکاران (2008) در استفاده از شبکه عصبی در برآورد پارامترهای مؤثر بر آلودگی آب در کانال تولی³ واقع در هند اشاره کرد. نجاج و همکاران (2009)

بیانگر مواد زیستی قابل تجزیه موجود در آب بوده و جزو اولین پارامترهای مورد نیاز برای ارزیابی کیفیت هر سیستم آبی به شمار می‌رود. روش‌های متداولی که برای تعیین BOD مورد استفاده قرار می‌گیرد، اغلب روش‌هایی بسیار مشکل و البته همراه با خطاهای اندازه‌گیری است. مبنای این روش‌ها، تعیین فاکتورهای پیچیده مانند اکسیژن مورد نیاز برای تنفس میکروارگانیسم‌ها در یک نمونه و اکسیداسیون آمونیاک است (کونوار و همکاران 2009). وجود ذرات سمی در نمونه از طریق تاثیری که ممکن است بر فعالیت‌های میکروبی بگذارد، منجر به کاهش BOD می‌شود. از طرفی شرایط آزمایشگاهی برای تعیین BOD متفاوت از شرایط طبیعی سیستم‌های آبی است. بنابراین تفسیر و تعمیم نتایج BOD نیز همراه با نوسان‌های شدیدی خواهد بود و طبیعتاً تخمین این مقادیر نیز تا حدودی غیرقابل اطمینان است. از آنجائیکه BOD با اکسیژن محلول در آب (DO) رابطه عکس دارد، مقادیر بالای BOD بیانگر شرایط فقدان اکسیژن محلول در آب خواهد بود. اکسیژن محلول در آب یکی از شاخص‌های مهم در مسائل بهداشت محیط می‌باشد. بعلاوه به منظور تعیین BOD، آگاهی از غلظت اکسیژن محلول در آب امری ضروری است. بهمین دلیل هر دو شاخص BOD و DO عمدتاً بصورت موازی و یکپارچه تعیین می‌شوند. در این راستا ضرورت اتخاذ برخی روش‌های غیر مستقیم برای پیش‌بینی این متغیرها برای ارزیابی کیفیت آب بیش از پیش نمایان می‌شود (کونوار و همکاران 2009). در سال‌های اخیر، مدل‌های بسیار زیادی از جمله QUAL2E، WASP و HEC-5Q در زمینه مدیریت بهتر برای حفظ کیفیت آب و پیش‌بینی شاخص‌های کیفی آب‌های سطحی گسترش یافته است (چن و همکاران 2003 و کورونک و همکاران 2005). اکثر این روش‌ها، نیازمند داشتن اطلاعات وسیعی از

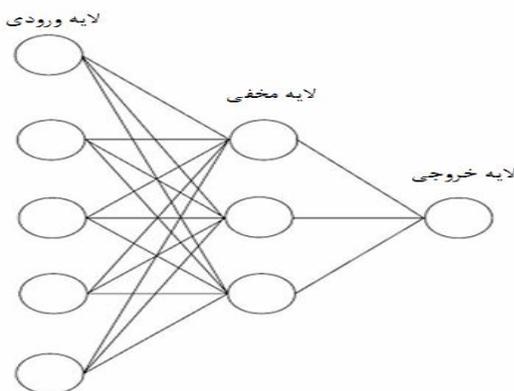
¹Artificial neural networks

²Artificial intelligence

³Tolly river

تعیین می‌کند که شبکه از چند نرون⁶ یا عنصر پردازشگر⁷ تشکیل یافته، چگونه در شبکه آرایش گرفته و به چه شکل به یکدیگر متصل شده‌اند. یکی از انواع شبکه‌های عصبی که در این تحقیق مورد استفاده قرار گرفته است، شبکه‌های عصبی پرسپترون چند لایه⁸ (MLP) است که از کاربرد روزافزونی بهره‌مند است. در یک مدل پرسپترون، یک نرون (Node) عامل تولید پالس بوده که هنگام دریافت آن دسته از ورودی‌هایی که قبلاً وزن دار شده و به حد آستانه رسیده‌اند، به نرون‌های مجاور انتقال می‌یابد.

شبکه عصبی پرسپترون با یک لایه ورودی آغاز می‌شوند و شار اطلاعات را به سمت لایه خروجی هدایت می‌نمایند. میان این دو لایه نیز ممکن است چندین لایه مخفی وجود داشته باشد. لازم به ذکر است تعداد این لایه‌ها و همچنین تعداد گره‌ها در هر لایه مخفی معمولاً به روش آزمون و خطا تعیین می‌گردد. شکل شماره 1 نمونه‌ای از شبکه عصبی سه لایه می‌باشد.



شکل 1- نمونه‌ای از مدل شبکه عصبی با ساختار سه لایه

نقطه آغاز نظریه شبکه عصبی مصنوعی را باید سال 1943 دانست، که مدل ریاضی نرون ارائه شد. به تبع آن اولین شبکه عصبی پرسپترون بنا نهاده شد. در سال

نیز توانایی شبکه‌های عصبی را در پیش‌بینی شاخص‌های کیفی آب رودخانه جوهر¹ مالزی و توانایی برآورد مقدار EC و TDS و کدورت در این حوضه را مورد تاکید قرار دادند. همچنین هویگون و لینگ (2008) در تحقیقی در کشور چین، کیفیت آب رودخانه دونگ چانگ² را توسط شبکه‌های عصبی مصنوعی و منطق فازی مورد ارزیابی قرار دادند. کونوار و همکاران (2009) نیز شبکه‌های عصبی پرسپترون را در مدل سازی پارامترهای کیفی BOD و DO رودخانه گوتمی³ هند بکار گرفته و بر کارایی مناسب آن تاکید نمودند.

هدف اصلی تحقیق حاضر، بنا گذاری یک ساختار شبکه عصبی پرسپترون چند لایه برای مدل سازی شاخص‌های کیفی آب (DO و BOD) رودخانه دره مرادبیک همدان و تشریح کاربرد آن برای داده‌های پیچیده کیفیت آب است. لذا در این مطالعه امکان آموزش شبکه عصبی برای مدلسازی پارامترهای مستقل (DO و BOD) با استفاده از پارامترهای وابسته (پارامترهای کیفی) مورد ارزیابی قرار گرفت.

مواد و روش‌ها

مدل شبکه عصبی پرسپترون

طی چند دهه اخیر، تلاش‌های قابل ملاحظه‌ای برای مدل کردن یک نرون طبیعی که قادر به توصیف خصوصیات یک سیستم بیولوژیک باشد و شبکه‌های عصبی زیستی را همانند سازی کند، صورت گرفته است. شبکه‌های مدل شده با نام الگوهای⁴ شبکه عصبی شناخته شده و گسترش یافتند. مشخصات اساسی شبکه عصبی را می‌توان توسط ساختار⁵ آنها و خصوصیات عملیاتی و دینامیکی آن شناسایی کرد. ساختار شبکه

¹Johor river

²Dongchang river

³Gotmi river

⁴Paradigms

⁵Architecture

⁶Neuron

⁷Processing elements

⁸Multi-layer perceptron

الگوریتم انشار به عقب، مقدار ثابت یک در نظر گرفته می‌شود. مقادیر مطلوب ورودی و خروجی نیز باید محدوده (0 و 1) نرمال سازی شوند. همچنین میانگین مجذور خطا مابین داده‌های خروجی شبکه $t_{p,k}$ و خروجی‌های مطلوب $x_{3,k}$ بصورت زیر تعریف می‌شود:

$$E_p = \frac{1}{2} \sum_{k=1}^n (t_{p,k} - x_{3,k})^2 \quad [4]$$

وزنه‌ها (w) و مقادیر آستانه (θ) بوسیله انتقال خطا از لایه خروجی به لایه مخفی و از لایه مخفی به لایه ورودی بصورت روابط زیر تعدیل می‌شوند:

$$d_{3,k} = kx_{3,k}(1-x_{3,k})(t_{p,k} - x_{3,k}) : k = 1, n_3 \quad [5]$$

$$d_{2,k} = kx_{3,k}(1-x_{3,k}) \sum_{k=1}^n d_{3,k} w_{3,i,k} : j = 1, n_2 - 1; k = 1, n_3 \quad [6]$$

$$w_{3,j,k}^{(M+1)} = w_{3,j,k}^{(M)} + hd_{3,k}x_{2,j} + a(w_{3,j,k}^{(M)} - w_{3,j,k}^{(M+1)}) \quad [7]$$

$$w_{2,j,k}^{(M+1)} = w_{2,j,k}^{(M)} + hd_{2,k}x_{2,j} + a(w_{2,j,k}^{(M)} - w_{2,j,k}^{(M+1)}) \quad [8]$$

که در آن η سرعت آموزش و α ضریب اینرسی می‌باشد. همچنین $w^{(M)}$ نشانگر این است که وزنه‌ها M بار کالیبره شده‌اند. دلیل استفاده از ضریب اینرسی نیز پرهیز از مشکلات ناشی از بوجود آمدن مینیمم موضعی و تسریع در همگرایی است.

در این تحقیق داده‌ها برای آموزش و آزمون (صحت یابی) به دو دسته تقسیم شده‌اند، بطوریکه 70 درصد داده‌ها برای بعنوان داده‌های آموزش و 30 درصد داده‌ها بعنوان داده‌های صحت یابی در نظر گرفته شده‌اند.

1986 نیز الگوریتم کالیبراسیون یا آموزش مدل‌های پرسپترون چند لایه (MLP) پیشنهاد گردید. از آن به بعد مدل بعنوان مدلی سودمند و کاربردی مورد توجه وسیع محققین علوم مختلف قرار گرفته است (علیائی و همکاران 1387). در تحقیق حاضر، یک مدل پرسپترون سه لایه برای مدل‌سازی شاخص‌های کیفی آب در رودخانه دره مرادبیک همدان بکار گرفته شده است. یک مدل پرسپترون ترکیبی از واحد‌های n_1 (یک لایه ورودی)، واحد‌های n_2 (یک لایه مخفی) و واحد‌های n_3 (یک لایه خروجی) است. بر مبنای شکل شماره 2 خروجی‌ها ($x_{3,k}; k=1, n_3$) بصورت زیر محاسبه می‌شوند (کونوار و همکاران 2009):

$$x_{2,j} = f\left(\sum_{i=0}^{n_1-1} w_{2,i,j}x_{1,i}\right); j = 1, n_2-1 \quad [1]$$

$$x_{3,j} = f\left(\sum_{i=0}^{n_2-1} w_{3,i,j}x_{2,i}\right); j = 1, n_3 \quad [2]$$

زمانی که $X_{1,0}=0$ باشد، همواره یک مقدار ثابت برای محاسبه خروجی لایه مخفی مورد استفاده قرار می‌گیرد. $x_{1,i} (i = 1, n_1 - 1)$ ورودی‌های لایه مخفی $x_{2,j} (j = 1, n_2 - 1)$ خروجی‌های لایه خروجی می‌باشند. همچنین $w_{2,i,j} (i=1, n_1-1; j=1, n_2-1)$ وزنه‌های لایه ورودی و مخفی هستند که در محاسبه خروجی لایه مخفی استفاده می‌شوند. $w_{3,j,k} (i=1, n_2-1; k=1, n_3)$ نیز وزنه‌های مخفی و خروجی می‌باشند که برای محاسبه خروجی لایه خروجی مورد استفاده قرار می‌گیرند. یک نمونه از توابع انتقال غیر خطی $f(y)$ که در این تحقیق مورد استفاده قرار گرفته است، تابع سیگموئید است که بصورت زیر تعریف می‌شود:

$$f(y) = \frac{1}{1 + e^{-ky}} \quad [3]$$

در رابطه فوق k پارامتر تعیین کننده واکنش $f(y)$ است. در این تحلیل‌ها، پارامتر k بخاطر عدم سازگاری آن با

معیارهای ارزیابی مدل

به منظور سنجش عملکرد هر یک از مدل‌های شبکه‌ی انتخاب شده، سه شاخص معیاری متفاوت شامل ضریب همبستگی (R)، ریشه‌ی مربع میانگین خطا (RMSE) و میانگین قدرمطلق خطا (MAE) مورد استفاده قرار گرفت. که به ترتیب از روابط زیر (علیائی و همکاران 1387) قابل محاسبه هستند:

$$R = \frac{N \sum_{i=1}^N O_i y_{p,i} - \left(\sum_{i=1}^N O_i \right) \left(\sum_{i=1}^N y_{p,i} \right)}{\sqrt{\left[N \sum_{i=1}^N O_i^2 - \left(\sum_{i=1}^N O_i \right)^2 \right] \times \left[N \sum_{i=1}^N y_{p,i}^2 - \left(\sum_{i=1}^N y_{p,i} \right)^2 \right]}} \quad [9]$$

$$RMSE = \sqrt{\sum_{i=1}^N \frac{(y_{p,i} - O_i)^2}{N}} \quad [10]$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_{p,i} - O_i| \quad [11]$$

در این روابط O_i و $y_{p,i}$ به ترتیب مقادیر محاسبه شده توسط مدل و مقادیر اندازه‌گیری شده متغیرها است. همچنین N بیانگر تعداد مشاهدات است. طبیعتاً کم بودن میزان خطا (RMSE و MAE) و بالا بودن ضریب R بیانگر دقت قابل قبول مدل و ملاک برتری آن خواهد بود.

اطلاعات ورودی

به منظور مدل‌سازی شاخص‌های کیفی BOD و DO در این تحقیق از اطلاعات و داده‌های شامل 10 متغیر ماهانه کیفی آب در رودخانه دره مراد بیک همدان در طول یک سال و در شش ایستگاه استفاده شد. این متغیرها شامل اسیدیته آب، هدایت الکتریکی¹، کل

جامدات²، کل جامدات معلق³، کل جامدات محلول⁴، کدورت⁵، نیترات، فسفات، سدیم و آمونیاک است. نمونه‌برداری از ایستگاه‌های مشخص شده در طی 12 ماه سال 88-1387 و بصورت ماهیانه (اواسط هر ماه) انجام گرفت. اندازه‌گیری پارامترهای فوق در آزمایشگاه دانشگاه علوم پزشکی همدان انجام گردیده است.

شایان ذکر است شاخص‌های BOD و DO بعنوان آرایه‌های وابسته و متغیرهای دیگر بعنوان مجموعه آرایه‌های مستقلند. شاخص اکسیژن محلول با استفاده از دستگاه DO متر پرتابل و BOD نمونه‌ها با استفاده از دستگاه انکوباتور BOD قرائت گردید. جدول 1 مشخصات آماری متغیرهای کیفی آب رودخانه دره مراد بیک همدان را نشان می‌دهد. به منظور تعیین مقادیر بهینه تعداد لایه‌های مخفی و توابع انتقال در شبکه عصبی، مدل‌های متفاوت شبکه مورد ارزیابی و بررسی قرار گرفت. انتخاب یک مقدار مناسب برای تعداد گره‌های لایه مخفی یکی از جنبه‌های مهم در طراحی یک شبکه عصبی بشمار می‌رود. همانگونه که قبلاً ذکر شد، غالباً تعیین این مقادیر بر اساس آزمون و خطا انجام می‌گیرد، هرچند روابطی برای تخمین تعداد گره در لایه مخفی پیشنهاد شده است. یکی از معروفترین این روابط، (کونوار و همکاران 2009) محدوده این مقادیر را بین $2n^{1/2}+m$ و $2n+1$ تخمین زده است. که در آن n تعداد گره‌های ورودی و m تعداد گره‌های خروجی است. بر این اساس نهایتاً دو مدل برای محاسبه BOD و DO آب رودخانه طراحی شد. ساختار بهترین مدل برای اکسیژن مورد نیاز بیولوژیکی و اکسیژن محلول در آب در جدول 2 آمده است. شبکه عصبی منتخب برای مدل‌سازی DO، یک شبکه عصبی پرسپترون سه لایه مرکب از یک لایه ورودی با 10

² Total solids³Total suspended solids⁴Total dissolved solids⁵Turbidity¹Electrical conductivity

انتشار به عقب بوده و تابع انتقال نیز تابع غیر خطی سیگموئید است. به منظور سنجش دقت این مدل مقادیر R ، $RMSE$ و MAE برای مراحل آموزش و صحت‌یابی محاسبه و در جدول 2 درج گردیده است. تمامی محاسبات مربوط به ANN در این تحقیق توسط نرم‌افزار Qnet 2000 انجام شده است.

متغیر، یک لایه مخفی با 16 گره و یک لایه خروجی با یک متغیر خروجی است. در حالیکه تعداد گره‌های مخفی در مورد BOD متفاوت از شبکه قبلی و 20 گره انتخاب شده است. این مدل‌ها ابتدا با وارد کردن داده‌های مجموعه آموزش، آموزش دیده و سپس با ارائه داده‌های مجموعه آزمون مورد صحت‌سنجی قرار می‌گیرند. الگوریتم آموزشی برای هر دو مدل الگوریتم

جدول 1- مشخصات آماری متغیرهای کیفی آب رودخانه دره مراد بیگ همدان.

| انحراف استاندارد | میانگین | بیشینه | کمینه | واحد | پارامترهای کیفی آب |
|------------------|---------|--------|-------|-------------------------|----------------------------|
| 1/00 | 6/51 | 8/24 | 2/5 | - | اسیدیته |
| 304/63 | 387/77 | 1171 | 285 | میکروزیمنس بر سانتی متر | هدایت الکتریکی |
| 337/22 | 426/81 | 1690 | 60 | میلی گرم بر لیتر | بی کربنات |
| 259/02 | 234/41 | 1534 | 0/76 | میلی گرم بر لیتر | کل جامدات معلق |
| 143/14 | 186/40 | 578 | 9/5 | میلی گرم بر لیتر | کل جامدات محلول |
| 92/84 | 72/57 | 448 | 1/02 | NTU | کدورت |
| 18/43 | 26/04 | 73/25 | 0/41 | میلی گرم بر لیتر | نیترات |
| 13/93 | 10/30 | 54 | 0/1 | میلی گرم بر لیتر | فسفات |
| 30/08 | 33/34 | 140 | 2/25 | میلی گرم بر لیتر | سدیم |
| 7/80 | 8/83 | 39/5 | 0/06 | میلی گرم بر لیتر | آمونیاک |
| 42/96 | 48/48 | 150 | 0 | میلی گرم بر لیتر | اکسیژن مورد نیاز بیولوژیکی |
| 3/41 | 6/99 | 12/4 | 1 | میلی گرم بر لیتر | اکسیژن محلول |

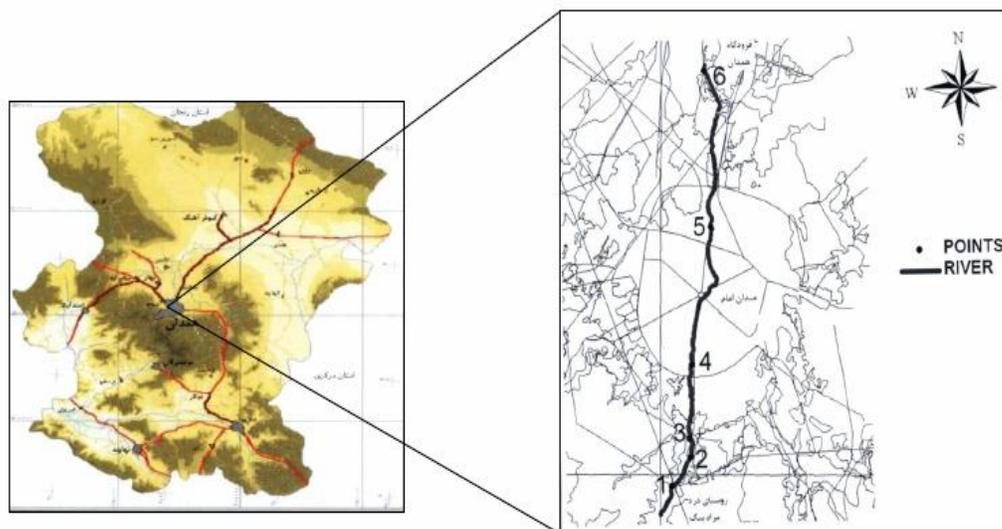
رود، از شیب آن کاسته می‌شود. این رودخانه از ارتفاعات الوند سرچشمه گرفته و پس از تامین آب شرب و کشاورزی روستای مرادبیک و سیلوار از حاشیه روستای دره مرادبیک عبور کرده و پس از تلاقی با جاده دره مراد بیک در سمت غرب این جاده از جنوب به طرف شمال امتداد می‌یابد. بر اساس گزارشات آب منطقه‌ای استان همدان مساحت حوضه آبریز این رودخانه 30 کیلومتر مربع بوده و میزان آبدهی آن متغیر می‌باشد. در طول مسیر این رودخانه آلاینده‌های مختلفی وارد آن می‌گردند که شامل آلاینده‌های حاصل از فعالیت‌های کشاورزی، فاضلاب‌های صنعتی و انسانی است. همچنین فقدان شبکه جمع‌آوری فاضلاب در شهر همدان نیز مزید بر علت می‌

منطقه مورد مطالعه

رودخانه مرادبیک در گستره دامنه شرقی سلسله جبال زاگرس شمالی و در میان رشته کوه الوند با ارتفاع حداکثر 3850 متر از سطح دریا در محدوده جنوبی همدان قرار گرفته است. این رودخانه، رودخانه مرکزی شهر همدان محسوب می‌شود. عرض جغرافیایی ایستگاه‌های مورد مطالعه در طول مسیر رودخانه دره مراد بیک از $34^{\circ} 44'$ تا $34^{\circ} 51'$ و طول جغرافیایی ایستگاه‌ها در حدود $48^{\circ} 30'$ بوده است. طول این رودخانه در محدوده ایستگاه‌های مورد مطالعه نیز 13949/87 متر است. این رودخانه دارای توپوگرافی با شیب نسبتاً زیاد بوده و هر چه به پایین دست پیش می‌

رودخانه را نشان می‌دهد.

باشد. شکل 2 موقعیت جغرافیایی رودخانه مراد بیک همدان و ایستگاه‌های مورد مطالعه در طول مسیر



شکل 2- موقعیت ایستگاه‌های مورد مطالعه در طول مسیر رودخانه مراد بیک همدان

نتایج و بحث

جهت تعیین تعداد بهینه گره‌های لایه مخفی ایجاد و مورد آزمون قرار گرفت. جدول 2 جزئیات ساختار و عملکرد شبکه عصبی در شبیه‌سازی شاخص‌های فوق را نشان می‌دهد. با توجه به نتایج بدست آمده از ضرایب همبستگی می‌توان دریافت که اولاً عملکرد مدل استفاده شده در تخمین BOD بهتر از DO بوده است. بطوریکه ضریب همبستگی (R) در مورد مرحله صحت سنجی تخمین BOD برابر با 0/986 و در مورد DO برابر با 0/969 است. شکل‌های 4 و 6 نیز بیانگر همین نتیجه می‌باشند. این مساله در مورد مراحل آموزش شبکه نیز صادق می‌باشد. شکل‌های شماره 3 و 5 نیز نمایانگر نتایج فوق می‌باشند. ثانیاً میزان خطا در مراحل صحت سنجی هر دو پارامتر به مراتب کمتر از مقادیر خطا در بخش آموزش مدل بوده است. شکل‌های 3 و 4 مقایسه بین مقادیر اندازه گیری BOD و مقادیر پیش بینی شده توسط مدل در مراحل آموزش و صحت‌سنجی را ارائه می‌نماید. همچنین شکل‌های 5 و 6

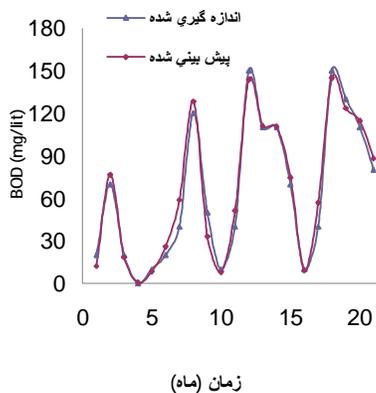
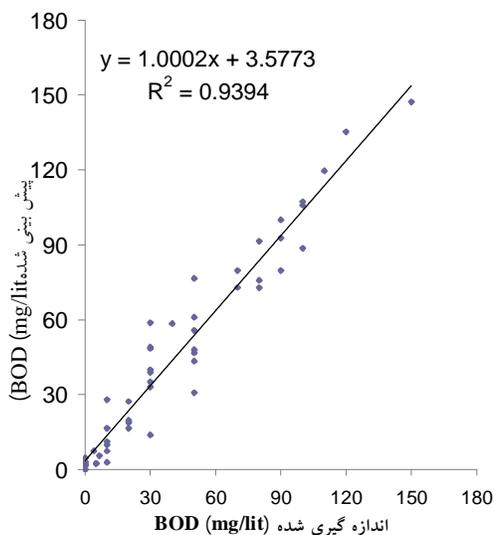
به منظور تخمین شاخص‌های BOD و DO از یک شبکه عصبی پرسپترون سه لایه برای پیش‌بینی هر شاخص بهره گرفته شد. به دلیل تفاوت در ماهیت این دو شاخص از دو مدل شبکه عصبی بصورت جداگانه استفاده شد. نتایج برآمده نیز نشان دهنده تفاوت در ساختار مدل به لحاظ تعداد گره در لایه مخفی بود. همانگونه که قبلاً ذکر شد، تعداد بهینه گره‌های لایه مخفی با تکرار و آزمون و خطا بدست آمد. لیکن در مورد هر دو شاخص، ده متغیر کیفی بعنوان ورودی-های شبکه لحاظ گردید. پارامترهای ورودی و تعیین ترکیب آن‌ها با توجه به اثرگذاری این پارامترها در تخمین شاخص‌های مورد نظر، مشخص شدند. چنانچه مطالعات کونوار و همکاران (2009) نشان داد، پارامترهای ورودی یاد شده و ترکیب همین پارامترها بخوبی قادر به تخمین شاخص‌های BOD و DO خواهد بود. در این راستا مدل‌های مختلف شبکه عصبی

در مدل‌سازی شاخص‌های کیفی رودخانه‌ها بوده است. همچنین نتایج مطالعه هور و همکاران (2008) در استفاده از این تکنیک در پیش‌بینی شاخص‌های کیفیت آب فاضلاب منطبق با نتایج بدست آمده از این تحقیق است.

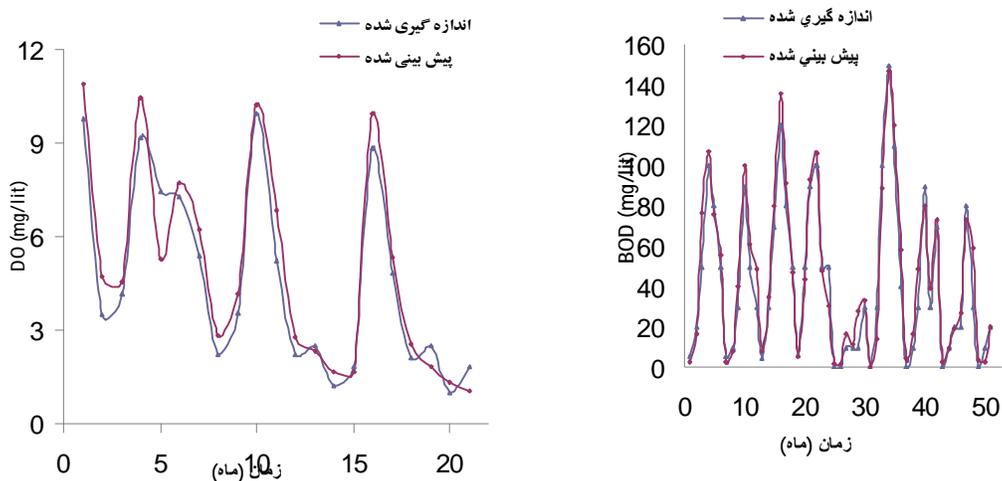
مقایسه بین مقادیر اندازه‌گیری شده DO و مقادیر پیش‌بینی شده توسط مدل در مراحل فوق را نشان می‌دهد. مقادیر ارائه شده توانایی محسوس قدرت مدل-سازی برای شبکه‌های عصبی مصنوعی را بیان می‌کند. نتایج مطالعات کونوار و همکاران (2009) نیز بیانگر برتری قابل توجه شبکه‌های عصبی پرسپترون چند لایه

جدول 2- نتایج حاصل از مدل‌های بهینه شبکه عصبی مصنوعی در شبیه‌سازی پارامترهای BOD و DO

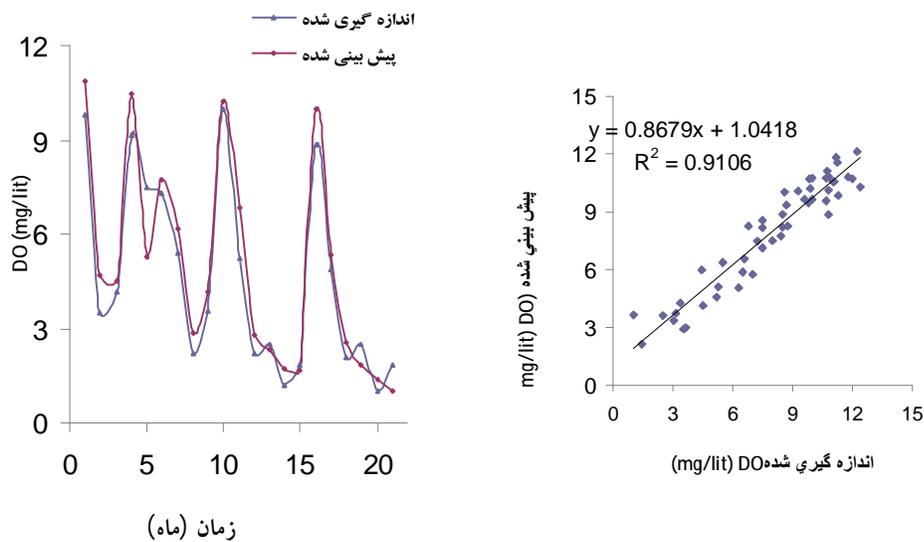
| DO | | BOD | | پارامترهای کیفی آب |
|---------------|-------|---------------|-------|-------------------------|
| 10-16-1 | | 10-20-1 | | ساختار نرونی شبکه عصبی |
| پس انتشار خطا | | پس انتشار خطا | | الگوریتم آموزش |
| سیگموئید | | سیگموئید | | تابع انتقال (محرک) |
| 0/01 | | 0/01 | | سرعت آموزش (η) |
| 10000 | | 10000 | | تعداد دور آموزش |
| صحت سنجی | آموزش | صحت سنجی | آموزش | مرحله |
| 0/84 | 1/02 | 8/42 | 9/01 | RMSE (میلی گرم بر لیتر) |
| 0/69 | 0/78 | 6/27 | 6/71 | MAE (میلی گرم بر لیتر) |
| 0/969 | 0/954 | 0/986 | 0/969 | R |



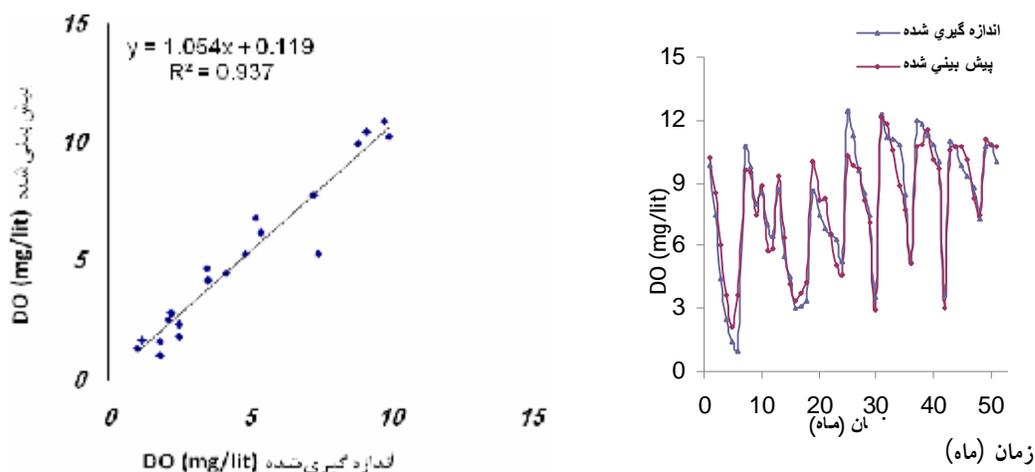
شکل 3- مقایسه نتایج حاصل از ANN با مقادیر مشاهداتی BOD در مرحله آموزش.



شکل 4- مقایسه نتایج حاصل از ANN با مقادیر مشاهداتی BOD در مرحله صحت سنجی.



شکل 5- مقایسه نتایج حاصل از ANN با مقادیر مشاهداتی DO در مرحله آموزش.



شکل 6- مقایسه نتایج حاصل از ANN با مقادیر مشاهداتی DO در مرحله صحت سنجی.

نتیجه‌گیری

در مطالعه انجام شده، دو مدل بر اساس رویکرد شبکه عصبی پرسپترون چند لایه برای مدل‌سازی غلظت اکسیژن مورد نیاز بیولوژیکی و اکسیژن محلول در آب در رودخانه دره مراد بیک همدان طراحی و مورد استفاده قرار گرفت. مدل‌های فوق بر اساس داده‌های اندازه‌گیری شده ماهانه متغیرهای کیفی و با استفاده از الگوریتم انتشار به عقب مورد آموزش قرار گرفته و سپس عمل صحت‌یابی اجرا شد. تحقیق حاضر نشان می‌دهد که شبکه‌های عصبی مصنوعی قادر به تخمین و مدل‌سازی شاخص‌های BOD و DO هستند که در شرایط معمول اندازه‌گیری آزمایشگاهی آنها کاری پرهزینه و زمان‌بر است. همچنین نتایج برآمده از این تحقیق نشان داد که کارایی مدل شبکه عصبی با پارامترهای ورودی مشابه به منظور تخمین شاخص BOD به مراتب دقیق‌تر از تخمین شاخص DO بود. لذا می‌توان ادعا کرد شبکه‌های عصبی مصنوعی می‌توانند بعنوان ابزاری توانمند برای محاسبه تغییرات کیفیت آب رودخانه‌ها مورد استفاده قرار گیرند و در اتخاذ تصمیمات مدیریتی در جهت حفظ و بهبود وضعیت کیفی آبهای سطحی کارگشا باشند. همچنین شبکه‌های عصبی

با توجه به نمودارهای فوق و معادلات رگرسیونی برازش داده شده می‌توان دریافت که عملکرد مدل استفاده شده در تخمین BOD دقیق‌تر از DO می‌باشد. شکل شماره 3 نمایانگر مقادیر اندازه‌گیری شده و پیش‌بینی شده BOD توسط شبکه عصبی در مرحله آموزش و شکل شماره 4 نشان‌گر مقادیر اندازه‌گیری شده و پیش‌بینی شده همین پارامتر توسط شبکه عصبی در مرحله صحت‌یابی می‌باشد. شبکه عصبی منتخب (10) گره در لایه ورودی، 20 گره در لایه مخفی و یک گره در لایه خروجی، بهترین نتیجه را در هر دو مرحله ارائه داد. ضریب همبستگی بالای 0/95 در مراحل آموزش و صحت‌یابی حاکی از عملکرد بالای مدل استفاده شده است. همچنین مقایسه بین مقادیر اندازه‌گیری شده و پیش‌بینی شده شاخص DO در مراحل آموزش و صحت‌یابی با استفاده از شبکه عصبی منتخب (10) گره در لایه ورودی، 16 گره در لایه مخفی و یک گره در لایه خروجی) به ترتیب در شکل‌های 5 و 6 آمده است. در مورد تخمین DO نیز ضریب همبستگی محاسبه شده بازای مراحل آموزش و صحت‌یابی مقدار بالای 0/95 را تبیین می‌نماید.

قادر به رقابت با سایر تکنیک‌های معمول در زمینه مدل-سازی بوده و به سبب سادگی از لحاظ عدم نیاز به دانش بالای مبانی ریاضی الگوریتم، می‌توانند جایگزینی مناسب برای روش‌های مرسوم اندازه‌گیری پارامترهای مورد نظر باشند. لازم به ذکر است در صورت افزایش دامنه داده، نتایج بهتری نیز حاصل می‌شود.

منابع مورد استفاده

علیائی ا، قربانی م ع و جباری خامنه ح، 1387. عملکرد حافظه اتورگرسیو و شبکه‌های عصبی مصنوعی در پیش بینی جریان روزانه رودخانه ليقوان. مجموعه مقالات سومین کنفرانس مدیریت منابع آب ایران (لوح فشرده). دانشکده مهندسی عمران دانشگاه تبریز.

Bowers JA and Shedrow CB, 2000. Predicting stream water quality using artificial neural networks. WSRC-MS-2000-00112.

Chen JC, Chang NB and ShiehWK, 2003. Assessing wastewater reclamation potential by neural network model. *Engin Appl Artif Intell* 166: 149-57.

Hore A, Dutta S, Datta S and Bhattacharjee C, 2008. Application of an artificial neural network in wastewater quality monitoring: prediction of water quality index. *International Journal of Nuclear Desalination (IJND)* 3: 160 - 74.

Huiqun M and Ling L, 2008. Water quality assessment using artificial neural network. pp.13-5. *International Conference on Computer Science and Software Engineering*. Washington, DC, USA.

Kunwar P, Singh AB, Amrita M and Gunja J, 2009. Artificial neural network modeling of the river water quality—A case study. *Ecol Model* 220:888-95.

Kuo Y, Liu C and Lin KH, 2004. Evaluation of the ability of an artificial neural network model to assess the variation of groundwater quality in an area of blackfoot disease in Taiwan. *Water Res* 38: 148-58.

Kuo J, Hsieh M, Lung W and She N, 2007. Using artificial neural network for reservoir eutrophication prediction. *Ecol Model* 200: 171-7.

Kurunc A, Yurekli K and Cevik O, 2005. Performance of two stochastic approaches for forecasting water quality and stream flow data from Yesilirmak River. *Turkey Environ Model Software*. 20: 1195-200.

May D and Sivakumar M, 2009. Prediction of urban storm water quality using artificial neural networks. *Environ Model Software*. 24: 296-302.

Najah A, Elshafie A, Karim O and Jaffar O, 2009. Prediction of Johor river water quality parameters using artificial neural networks. *Europ J Sci Res* 28: 422-35.