



یازدهمین کنگره ملی مهندسی مکانیک بیوسیستم و مکانیزاسیون ایران



پیش‌بینی میزان اکسیژن محلول آب در استخرهای پرورش ماهی با مدل‌های هوش مصنوعی

سیدمحمدجواد افزلی^۱، محمدجواد شیخداودی^۲، سیدرضا سیدمرتضایی^۳، آذرخش عزیزی^۴

^۱ محقق مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی خوزستان، مؤسسه تحقیقات فنی و مهندسی کشاورزی، اهواز، ایران؛ آدرس پست الکترونیکی: moja_afzali@yahoo.com

^۲ استاد گروه مهندسی بیوسیستم، دانشکده کشاورزی دانشگاه شهید چمران، اهواز، ایران؛ آدرس پست الکترونیکی: javad1950@yahoo.com

^۳ دانشیار بخش بهداشت و بیماری‌های آبزیان، مؤسسه تحقیقات علوم شیلاتی، کرج، ایران؛ آدرس پست الکترونیکی: rmortezaei@yahoo.com

^۴ عضو هیأت علمی مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی خوزستان، مؤسسه تحقیقات فنی و مهندسی کشاورزی، اهواز، ایران آدرس پست الکترونیکی: a.azizy@yahoo.com

چکیده

در پرورش آبزیان پیش‌بینی میزان اکسیژن محلول آب تأثیر زیادی در کاهش مصرف انرژی و همچنین کاهش نیروی کاری دارد. این تحقیق با هدف ایجاد مدلی مناسب برای تخمین میزان اکسیژن محلول آب استخرهای پرورش ماهی انجام گردید. پارامترهای ورودی pH و دمای آب و دما و رطوبت هوا و سرعت باد بودند. در طول دوره پرورش ماهی تمامی پارامترهای ورودی و خروجی اندازه‌گیری شدند و با سه مدل بررسی شدند. مدل اول شبکه عصبی مصنوعی بود و نتایج نشان داد تابع انتقال logsig-purelin با ۱۷ نرون در لایه پنهان با میزان ۰/۷۰ بیشترین ضریب تبیین را داشت. مدل دوم ادغام مدل شبکه عصبی با الگوریتم ژنتیک بود و نتایج نشان داد در بهترین حالت این مدل قادر است با ضریب تبیین ۰/۴۱ میزان اکسیژن محلول آب را پیش‌بینی نماید. در مدل سوم از شبکه فازی-عصبی (ANFIS) استفاده گردید. نتایج نشان داد که این شبکه در وضعیت خوشه‌بندی کاهشی قادر است با ضریب تبیین ۰/۸۸ اکسیژن محلول آب را تخمین بزند. بنابراین شبکه فازی-عصبی مناسب‌ترین روش برای ارزیابی میزان اکسیژن محلول استخرهای پرورش ماهی در منطقه مورد مطالعه بود.

کلمات کلیدی: اکسیژن محلول، شبکه عصبی، الگوریتم ژنتیک، شبکه فازی-عصبی تطبیقی



Prediction of water dissolved oxygen rate at fish growing pools by different artificial intelligence-based models

Seied Mohammad Javad Afzali¹, Mohammad Javad Sheikhdavodi², Seied Reza Seiedmortezaie³, Azaraksh Azizi⁴

¹ Researcher of Engineering Research Department, Khuzestan Agricultural and Natural Resources Research and Education Center, AREEO, Ahvaz, Iran. Email: moja_afzali@yahoo.com

² Professor of Department of Biosystem Engineering, Shahid Chamran University, Ahvaz, Iran. Email: javad1950@yahoo.com

³ Associate Professor of Iranian Fisheries Science Research Institute, karaj, Iran. Email: rmortezaei@yahoo.com

⁴ Faculty member of Engineering Research Department, Khuzestan Agricultural and Natural Resources Research and Education Center, AREEO, Ahvaz, Iran. Email: a.azizi@yahoo.com

ABSTRACT

In aquaculture Dissolved Oxygen (DO) rate prediction has a large effect on reduction energy consumption and worker costs. The aim of this research was to create a suitable model to estimate DO rate at growing pools. Input parameters were pH and temperatures of water, moisture and temperature of air and wind speed. Along growing period total of parameters were measured and with three models were estimated. The first one was Artificial Neural Network (ANN). The results showed that the maximum R² was achieved by logsig-purelin transfer function with 17 neuron at hidden layer with 0.70. Second one was an aggregated ANN-AG model and its result showed that the maximum of R² was 0.41 and finally, Third one was Adaptive Neuro Fuzzy Inference System (ANFIS) model and the results showed that at condition of 3 Membership function per layer with gaussian type and constant output could estimate DO with R=0.87 accuracy. Therefore ANN was the best method for evaluation of DO at growing pools for the region under study.

Keywords: Dissolved Oxygen, Neural Network, Genetic Algorithm, Adaptive Neuro Fuzzy Inference System

۱- مقدمه

متداولترین شاخص برای تعیین وضعیت کیفی آب استخرها، غلظت اکسیژن محلول است. کاهش اکسیژن محلول در استخرها، سبب بالا رفتن سطح دی اکسیدکربن و آمونیاک می شود و هر دو مورد به عنوان مواد سمی برای ماهی هستند و افزایش آنها به طور هم زمان، قدرت دفاعی ماهی ها را در مقابل بیماری ها به شدت کاهش می دهد (Mwegoha et al., 2010). ورود اکسیژن به آب از طریق پدیده انتشار از سطح آب به لایه های پایین و همچنین فتوسنتز زی شناوران گیاهی (فیتوپلانکتون ها) انجام می شود. از آنجا که محدوده پرورش ماهی گرمایی در استان خوزستان از فروردین تا اسفند است در فصل تابستان، دمای بالا سبب افزایش تنفس و کاهش اکسیژن محلول می شود؛ بنابراین در فصل تابستان و به خصوص در شب (به دلیل عدم فتوسنتز زی شناوران و کاهش اکسیژن در اثر تنفس)، ماهی ها به دلیل کاهش اکسیژن دچار کاهش رشد می شوند. برای کیورماهیان، مقدار اکسیژن محلول آب در طی دوره پرورش نباید کمتر از ۳ پی پی ام باشد؛ اگر چه این حداقل مقدار اکسیژن محلول در آب، فقط برای زنده ماندن ماهی است، ولی برای رشد ماهی مناسب نیست. حداقل مقدار اکسیژن محلول مورد نیاز کیورماهیان برای رشد ۵ پی پی ام است (Peighan & Abdollahmashaie, 2008). برای جبران کاهش اکسیژن محلول در آب از هوادهای مصنوعی به وسیله هوادهای استفاده می شود. در وضعیت موجود، روشن کردن هوادهای به صورت دستی و پس از تاریکی هوا انجام می شود و در اوایل صبح، آنها نیز خاموش می شوند. همچنین بسیاری از پرورش دهندگان به دلیل هزینه بالای مصرف انرژی در هوادهای از خرید آن صرف نظر می کنند یا در مواقع بسیار اضطراری آنها را روشن می کنند. در صورتی که هوادهای به یک سامانه پیش بینی میزان اکسیژن مجهز شوند هم می توان در هزینه انرژی صرفه جویی کرد و هم هزینه کارگری به میزان زیادی کاهش و عملکرد ماهی نیز افزایش می یابد. بدین منظور نیاز به تهیه یک مدل برای پیش بینی میزان اکسیژن محلول استخر ضرورت می یابد. نکته ای که باید در تهیه این مدل به



یازدهمین کنگره ملی مهندسی مکانیک بیوسیستم و مکانیزاسیون ایران



انجمن مهندسی ماشین‌های کشاورزی و مکانیزاسیون ایران



BuAli Sina University

آن توجه کرد، این است که این مدل باید بتواند با حداقل متغیرها عمل کند تا هزینه تجهیز کردن دستگاه زیاد نشود و خرید آن برای پرورش‌دهندگان توجیه‌پذیر باشد. با توجه به اینکه سنسور اندازه‌گیری مستقیم اکسیژن محلول گران است (هر عدد پنج میلیون تومان استعلام یافته در سال ۱۳۹۵)، به نظر می‌رسد بهتر است از پارامترهایی که می‌توانند بر این شاخص مؤثر باشند، استفاده و میزان تقریبی اکسیژن محلول را پیش‌بینی کرد.

مدل‌های تخمین‌زننده کیفیت آب مانند مدل‌های QUA2K و WASP بسیار پیچیده و نیازمند به اطلاعات ورودی فراوان هستند (Nurani & Salehi, 2008; Kuo et al., 2004). همچنین محاسبه این ورودی‌ها، زمان‌بر و هزینه‌بر و طراحی مدل، پیچیده است. در سال‌های اخیر کاربرد شبکه عصبی برای پیش‌بینی متغیرهای کیفیت آب توسعه یافته است. شبکه عصبی مصنوعی از جمله روش‌های مورد استفاده در حل مسائل مهندسی است که می‌تواند در پیش‌بینی و مدل‌سازی این فرایندها به کار رود. از این روش برخلاف روش‌های آماری، بدون نیاز به یافتن قوانین ریاضی حاکم بر پارامترهای ورودی و خروجی، برای پیش‌بینی خروجی به ویژه در فرایندهای پیچیده و رفتارهای غیرخطی و سامانه‌های تصمیم‌ساز مشابه انسان استفاده می‌شود (Witten & Frank, 2000; Plumb et al., 2005). با توجه به اهمیت اکسیژن محلول آب استخر و تأثیر آن بر تولید نهایی ماهی در سال‌های اخیر، پژوهش‌هایی در زمینه پیش‌بینی میزان اکسیژن محلول آب انجام شده است که غالب آنها بر پایه سامانه‌های عصبی و فازی بوده‌اند.

در یک پژوهش با کمک سه مدل شبکه عصبی پرسپترون چندلایه^۱، تابع پایه شعاعی^۲ و سامانه استنتاج فازی-عصبی تطبیقی^۳ (ANFIS) میزان اکسیژن محلول، نیاز بیوشیمیایی اکسیژن^۴ و میزان نیاز اکسیژن شیمیایی^۵ در رودخانه کارون تخمین زده شد (Emamgholizadeh et al., 2014). ورودی‌های مدل شامل میزان شوری آب، میزان pH، کلسیم، منیزیم، سدیم، کدورت، فسفات، نترات و نیتریت بودند. نتایج نشان داد که میزان ضریب همبستگی سه روش برای تعیین میزان اکسیژن محلول در آب به ترتیب ۰/۸۶، ۰/۷۶ و ۰/۸۳ است و مؤثرترین ورودی مدل، میزان فسفات می‌باشد. در پژوهشی دیگر در سنگاپور برای تخمین هفتگی میزان اکسیژن محلول در آب دریا از دو شبکه عصبی پرسپترون چندلایه با قابلیت پس‌انتشار خطا^۶ و شبکه عصبی رگرسیون^۷ تعمیم‌یافته استفاده شد (Palani et al., 2009). ورودی‌های مدل شامل دما، شوری، pH، عمق سچی^۸ و کلروفیل آ بودند. در سه محل اندازه‌گیری شده هر دو مدل با ضریب همبستگی بالایی قادر به پیش‌بینی میزان اکسیژن هفتگی بودند؛ ولی شبکه عصبی رگرسیون تعمیم‌یافته نتایج بهتری داشت.

در یک پژوهش دیگر، میزان اکسیژن محلول در آب رودخانه سورما با استفاده از شبکه عصبی پیش‌خور^۹ و تابع پایه شعاعی تخمین زده شد (Masrur Ahmad, 2017). متغیرهای ورودی در این پژوهش، در دو حالت تک متغیره (نیاز بیوشیمیایی اکسیژن) و دومتغیره (نیاز بیوشیمیایی و شیمیایی اکسیژن) بررسی شد. نتایج نشان داد تفاوت بین دو شبکه عصبی در هر دو حالت تک‌متغیره و دومتغیره مشابه بود (ضریب همبستگی به ترتیب ۰/۷۹ و ۰/۸۸ شد)؛ ولی تعداد نوروهای لایه‌های پنهان در حالت شبکه عصبی پیش‌خور و تابع پایه شعاعی به ترتیب ۲۰ و ۳۰ (در حالت تک و دو متغیره) و ۶۵ و ۵۵ (در حالت تک و دومتغیره) بود.

اگرچه مدل‌های ارائه‌شده دارای ضریب همبستگی بالایی بودند، تعداد ورودی‌ها زیاد و اندازه‌گیری آنها دشوار بوده و در عمل کنترل روشن و خاموش کردن هوا در زمان مشخص، مناسب نبودند. همچنین در خصوص تخمین میزان اکسیژن محلول آب در استخرهای پرورش ماهی‌های گرمابی پژوهش‌های چندانی انجام نشده است. این پژوهش با هدف تعیین مناسب‌ترین مدل پیش‌بینی میزان اکسیژن محلول آب استخرهای پرورش ماهی‌های گرمابی انجام شد.

۲- مواد و روش‌ها

محل اجرای آزمایش، پژوهشکده آبی‌پروری جنوب واقع در شهر اهواز و استان خوزستان با مختصات جغرافیایی "۴۴/۲۷' ۲۵° ۳۱ شمالی و "۴۸ ۴۹' ۱۷/۳۸" شرقی بود (شکل ۱).

- 1 Multi Layer Perceptron
- 2 Radial Basis Function (RBF)
- 3 Adaptive Neuro Fuzzy Inference System
- 4 Biochemical Oxygen Demand (BOD)
- 5 Chemical Oxygen Demand (COD)
- 6 Multi Layer Back Propagation (MLBP)
- 7 Generalized Regression Neural Networks (GRNN)
- 8 Secchi depth
- 9 Feed Forward Neural Network (FFNN)



یازدهمین کنگره ملی مهندسی مکانیک بیوسیستم و مکانیزاسیون ایران



انجمن مهندسی ماشین‌های کشاورزی و مکانیزاسیون ایران



BuAli Sina University

در این پژوهش تعداد دفعات نمونه‌گیری در این پژوهش ۲۹۳۴ مورد بود که در طول دوره پرورش ماهی (از تاریخ ۹۵/۴/۳۱ لغایت ۹۵/۸/۳۱) به صورت هفتگی و در طول شبانه‌روز به طور ساعتی برداشت شدند. فاصله نمونه‌گیری داده‌ها از هواده ۵۰ متر بود و مقادیر پارامترها از عمق ۷۵ سانتیمتری آب استخر قرائت می‌شدند. عمق آب نیز در حدود ۲ متر حفظ شد.



Figure 1. Schematic view of research location
شکل ۱- نمایشی از محل اجرای پژوهش

۱-۲- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی، از جمله روش‌های محاسباتی است که به کمک فرآیند یادگیری و با استفاده از پردازشگرهایی به نام نورون، تلاش می‌کند با شناخت روابط ذاتی بین داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد (شکل ۲). هر شبکه عصبی از سه لایه ورودی، پنهان و خروجی تشکیل شده است. در هر لایه، تعدادی نورون وجود دارند. لایه یا لایه‌های پنهان، اطلاعات دریافت شده از لایه ورودی را پردازش می‌کنند و در اختیار لایه خروجی قرار می‌دهند. تابع انتقال، بیان‌کننده پاسخ هر نورون به سیگنال ورودی آن نورون است. از توابع انتقال مختلفی در سامانه‌های عصبی مصنوعی استفاده می‌شود. در این پژوهش، از سه تابع فعال‌سازی تانژانت سیگموئید، لگاریتم سیگموئید و خطی استفاده شد. هر سامانه با دریافت مثال‌هایی آموزش می‌بیند. آموزش فرآیندی است که در نهایت منجر به یادگیری می‌شود. یادگیری سامانه، تا زمانی انجام می‌شود که وزن‌های ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف بین مقادیر پیش‌بینی شده و اندازه‌گیری شده در حد پذیرفتنی باشد. برای آموزش سامانه‌های عصبی، الگوریتم‌های آموزشی متفاوتی مانند الگوریتم مومنتوم، لونیبرگ-مارکوات (LM) و گرادیان نزولی (CG) وجود دارد. در این پژوهش از الگوریتم لونیبرگ-مارکوات به دلیل همگرایی سریع‌تر در آموزش سامانه‌های با اندازه متوسط استفاده شد (Golabi et al., 2013).




Figure 2. Artificial Neural Network used in this research

شکل ۲. مدل شبکه عصبی مورد استفاده در پژوهش



یازدهمین کنگره ملی مهندسی مکانیک بیوسیستم و مکانیزاسیون ایران



انجمن مهندسی ماشین‌های کشاورزی و مکانیزاسیون ایران



Buali Sina University

برای انتخاب صحیح و یکنواخت داده‌ها از روش Kennard and Stone (1969) استفاده شد. در این روش دو داده ابتدایی، داده‌هایی هستند که بیشترین فاصله را از یکدیگر دارند. برای انتخاب نقطه سوم، فاصله هر نقطه را تا هر کدام از این نقاط انتخاب‌شده قبلی اندازه‌گیری و حداقل آنها را حساب می‌کنیم. حداکثر مقدار حاصل‌شده سبب انتخاب آن نقطه می‌شود. در صورت مساوی بودن دو مقدار به‌عنوان مقدار حداکثر، نقطه‌ای انتخابی می‌شود که رتبه (ایندکس) کمتری داشته باشد.

پارامترهای ورودی در این پژوهش، شامل دمای آب، pH آب، دمای هوا، سرعت باد و رطوبت هوا بودند. این پارامترها با توجه به پژوهش‌های گذشته و سهولت اندازه‌گیری انتخاب شدند. در یک پژوهش از شاخص‌های دمای هوا، میزان بارش، سرعت باد، رطوبت هوا، تابش خورشید و دمای خاک برای ارزیابی میزان اکسیژن محلول در دریاچه استفاده شد (Xu & Xu, 2016). در پژوهش دیگر، برای پیش‌بینی میزان اکسیژن محلول از شاخص‌های دمای آب، تابش خورشید، سرعت باد، بارش و رطوبت هوا استفاده شد (huihui et al., 2016).

شاخص رطوبت هوا، ممکن است به‌دلیل پوشش سطح آب با مولکول‌های آب و کاهش سطح تماس مولکول‌های هوا با سطح آب استخر بر کاهش مقدار اکسیژن آب مؤثر باشد. همچنین افزایش سرعت باد با ایجاد موج و افزایش سطح تماس آب و هوا می‌تواند سبب افزایش میزان اکسیژن محلول آب شود.

در جدول ۱، نام، مقدار بیشینه و کمینه، میانگین و انحراف معیار هر یک از نوروں‌های ورودی و نوروں خروجی (میزان اکسیژن محلول) آورده شده است.

شبکه پیش‌بینی‌کننده این پژوهش پس از آزمون و خطا و در نظر گرفتن کمترین میزان خطای حاصل‌شده با ۳ تا ۱۷ نوروں در لایه پنهان و با سه نوع تابع انتقال *tansig-purelin*، *logsig-purelin* و *tansig-tansig* با یکدیگر مقایسه شدند.

از ۷۰ درصد داده‌ها برای آموزش سامانه، ۱۵ درصد برای اعتبارسنجی و ۱۵ درصد برای سنجش سامانه عصبی استفاده شد. در همه آزمایش‌ها فقط از یک لایه پنهان استفاده شد تا نرم‌افزار با سرعت بالا قادر به تحلیل داده‌ها باشد.

با توجه به آنکه در شبکه عصبی ایجاد شده در هر مرحله جواب‌های متفاوت ارائه می‌شد، هر مرحله از آزمایش پنج بار تکرار شد و میانگین ضریب تبیین‌ها و خطاهای ارائه شده آنها، به‌عنوان ضریب تبیین و خطای مدل ارائه شد.



یازدهمین کنگره ملی مهندسی مکانیک بیوسیستم و مکانیزاسیون ایران



انجمن مهندسی ماشین‌های کشاورزی و مکانیزاسیون ایران



Bu Ali Sina University

جدول ۱- پارامترهای ورودی و خروجی مدل شبکه عصبی و مقادیر آماری آنها در طول دوره پرورش

Table 1. Inputs and output parameters of neural network and statistical rates during grawing

Neuron	Abbreviation symbol	Maximum rate	Minimum rate	average	Standard deviation
Water temperature (°C)	T _w	37.7	17.3	28.12	4.29
Water pH	pH	10.94	6.4	8.33	0.52
Air temperature (°C)	T _a	49	12	33.63	8.32
Wind speed (m/s)	S _w	10	1	3.63	1.92
Air moisture (%)	M _a	99	8	25.47	17.25
Dissolved oxygen (p.p.m.)	DO	17	1.8	8.25	2.72

۲-۲- تنظیم اوزان مدل شبکه عصبی مصنوعی با استفاده از الگوریتم ژنتیک

یک شبکه عصبی مصنوعی دقیق، کارآمد و با قابلیت تعمیم‌پذیری بالا، با انتخاب صحیح و مناسب متغیرهای ورودی (مانند اوزان اولیه)، تعداد لایه‌های پنهان، تعداد نورون لایه پنهان و انتخاب الگوریتم‌های مناسب آموزش سامانه حاصل می‌شود. در غیر این صورت ممکن است به نقطه بهینه با کمترین میزان خطا دست نیافت و به اصطلاح در نقاط مینیمم محلی گرفتار شد؛ لذا با انتخاب بهینه این متغیرها، می‌توان انتظار داشت شبکه عصبی نتایج دقیق و درستی را به‌عنوان خروجی ارائه دهد. در این پژوهش از الگوریتم ژنتیک برای تنظیم اوزان اتصالات سامانه استفاده شد. در الگوریتم ژنتیک، به‌جای آنکه از یک قطعه برای تخمین میزان خطا استفاده شود، از مجموعه‌ای از نقاط که جمعیت نامیده می‌شود، استفاده می‌شود. در هر مرحله، تمامی جمعیت که هر کدام شامل تعدادی کروموزوم هستند، به همراه درصدی از جمعیت که دچار تقاطع یا جهش شده‌اند، با استفاده از یک تابع تناسب ارزیابی و آنگاه تعدادی از بهترین جمعیت‌ها با استفاده از یک تابع احتمال انتخاب می‌شوند و جمعیت جدید را تشکیل می‌دهند.

۲-۳- عملگرهای تقاطع و جهش

برای تقاطع کروموزوم‌های منتخب والد و تولید کروموزوم‌های فرزند، از عملگر تقاطع یک نقطه‌ای، استفاده شد. از عملگر تقاطع برای تولید نسل در هر تکرار استفاده می‌شود و هدف اصلی از به‌کارگیری این عملگر، تولید نسلی با برازندگی بهتر است، مشروط بر این‌که هر یک از فرزندان مشخصه‌های والدین خود را به ارث ببرند. در عملگر تقاطع یک نقطه‌ای یک نقطه روی هر کروموزوم انتخاب می‌شود و فرزندان با ترکیب ژن‌های قبل و بعد نقطه تقاطع کروموزوم والدین منتخب حاصل می‌شوند. همان‌گونه که در شکل ۳ مشاهده می‌شود، پس از اعمال عملگر تقاطع تک نقطه‌ای دو کروموزوم والد تبدیل به دو کروموزوم فرزند می‌شوند. در انتخاب کروموزوم‌های والد از هر دو رویکرد چرخ رولت و انتخاب رقابتی استفاده شد و نتایج هر دو مقایسه شدند. در روش چرخ رولت انتخاب والد براساس شایستگی انجام می‌شود و والدهای برتر که دارای هزینه پایین‌تری هستند، از بین والدها انتخاب می‌شوند. در روش چرخ رولت ضربی به‌نام فشار انتخاب وجود دارد که وظیفه آن ایجاد فشار بیشتر برای انتخاب والدهای برتر است. در روش انتخاب رقابتی دسته‌های چندتایی از والدها انتخاب و از بین آنها برترین والد انتخاب می‌شود و این روند تا انتخاب تعداد والد تعیین شده برای تقاطع یا جهش ادامه می‌یابد. در این روش نیز اندازه انتخابی دسته‌ها از هر دسته می‌تواند در انتخاب والدها تأثیرگذار باشد. از عملگر تقاطع، برای بررسی گسترده‌تر فضای جواب مسأله از عملگر جهش نیز استفاده شد؛ به طوری که در آن یک محل از هر کروموزوم به‌صورت تصادفی انتخاب شده و مقدار ژن متناظر با احتمال ۰/۵ به میزان ۱۰ درصد افزایش (کاهش) یافت.

۲-۴- شرط توقف

تعداد کل تکرار الگوریتم ژنتیک برابر با در نظر گرفتن زمان پاسخ دستگاه رایانه ۲۰ در نظر گرفته شده است و اگر بعد از ۱۰ تکرار بهبودی در مقادیر برازندگی به وجود نمی‌آید، الگوریتم متوقف می‌شود.

1 Fitness
2 Roulette Wheel
3 Tournament Selection



یازدهمین کنگره ملی مهندسی مکانیک بیوسیستم و مکانیزاسیون ایران



انجمن مهندسی ماشین‌های کشاورزی و مکانیزاسیون ایران



BuAli Sina University

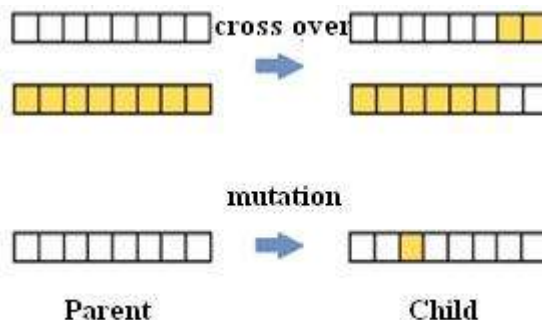


Figure 3. Methods of cross over and mutation and child generation

شکل ۳- نحوه تقاطع و جهش و تولید فرزند

۲-۵- سیستم استنتاج تطبیقی فازی - عصبی (ANFIS)

در سال‌های اخیر از ترکیب منطق فازی با سامانه‌های عصبی مصنوعی، سیستم‌های فازی-عصبی به وجود آمده‌اند. یک شبکه تطبیقی، یک ساختار پیشرو چندلایه است که رفتار کلی خروجی آن به وسیله مقدار یک مجموعه از پارامترهای قابل اصلاح تعیین می‌شود؛ به عبارت دیگر ساختار شبکه تطبیقی شامل یک مجموعه از گره‌های متصل به هم است که به طور مستقیم به هم مرتبط شده‌اند و در آن هر گره یک واحد پردازش محسوب می‌شود. این سیستم‌ها مشکل اصلی در طراحی سیستم‌های فازی (به دست آوردن قواعد اگر-آنگاه در سیستم فازی) را به وسیله استفاده مؤثر از قابلیت یادگیری شبکه عصبی مصنوعی برای تولید خودکار این قواعد و بهینه‌سازی پارامترها، حل کرده‌اند. ANFIS از متداول‌ترین سیستم‌های عصبی فازی است که یک سیستم فازی سوگنوا را در یک ساختار عصبی اجرا می‌کند (شکل ۴). این سیستم برای فرایند آموزش، از ترکیبی از روش‌های آموزش پس‌انتشار خطا و کمینه مربعات خطا استفاده می‌کند. در ANFIS لازم است که در لایه اول نوع تابع عضویت و تعداد آن مشخص شود. برای این منظور، در لایه اول دو روش تفکیک شبکه‌ای و تفکیک خوشه‌ای برای کلاسه‌بندی داده‌ها وجود دارد. انواع توابع موجود در این شبکه، شامل مثلثی^۱، گوسی^۲، گوسی نوع دو^۳ و زنگوله‌ای^۴ است. مدل فازی عصبی تطبیقی براساس تغییر در میزان مقادیر مرکز و دامنه توابع تعلق در تکرارهای مختلف برای رسیدن به شبکه مناسب براساس حداقل خطای موجود عمل می‌کند (Fausett, 1994 ; Ross, 1995). با توجه به اینکه تحلیل‌های سامانه ANFIS در سه حالت شبکه‌بندی^۵، خوشه‌بندی کاهشی^۶ و خوشه‌بندی C-means^۷ است، در هر حالت و با تغییر پارامترهای آن، ضریب تبیین محاسبه شد. در حالت شبکه‌بندی هر کدام از این ترکیبات ورودی با توابع عضویت مثلثی، گوسی نوع ۱، گوسی نوع ۲ و زنگوله‌ای ارزیابی شدند. تعداد توابع عضویت ۲ و ۳ و خروجی در دو حالت عدد ثابت و روش خطی در نظر گرفته شدند. در حالت خوشه‌بندی کاهشی شعاع تأثیر ۰/۲ در نظر گرفته شد. در حالت خوشه‌بندی C-means، تعداد خوشه‌ها از ۳ تا ۱۷ افزایش یافت و نتایج، بررسی شدند. همچنین برای گروه‌بندی داده‌های ورودی، از جداسازی خوشه‌ای استفاده شد. برای آموزش ANFIS در این پژوهش از عملگر اشتراک (AND) از روش حاصل ضرب (Prod)، عملگر اجتماع (OR) از روش حداکثر (Maximum) و برای روش غیرفازی‌سازی نیز از روش متوسط وزن‌دار استفاده شد.

1 Sugeno

2 Trimf

3 Gaussmf

4 Gauss2mf

5 Gbellmf

6 grid partitioning

7 subtractive clustering

8 Fuzzy C-means clustering

9 Weighted Average

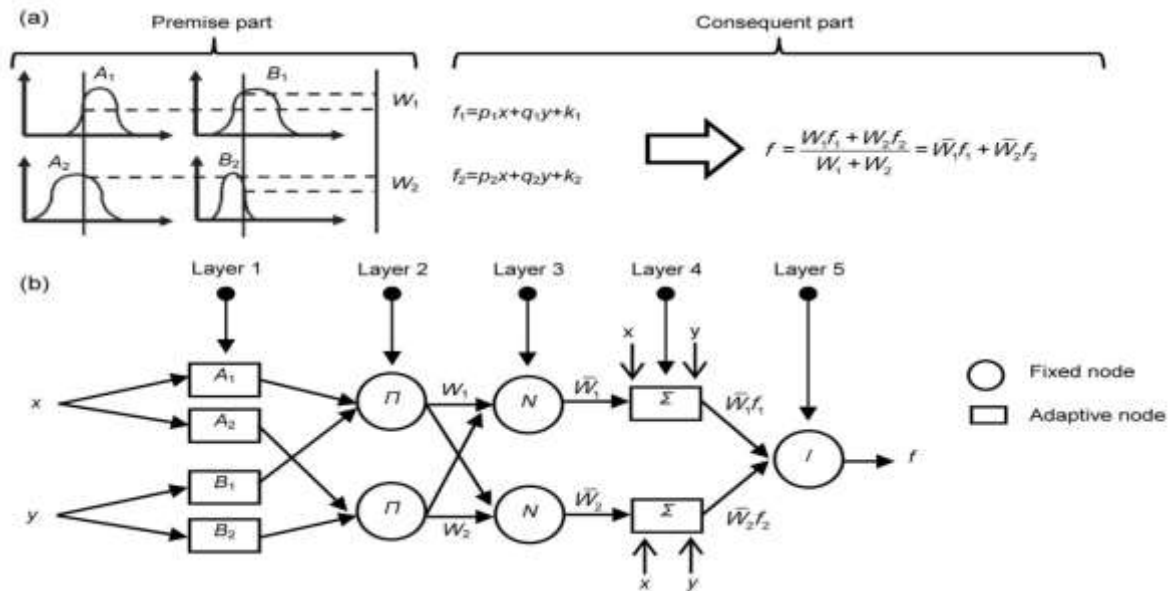


Figure 4. Sugeno-Type Fuzzy Inference system (down) and Typical ANFIS structure diagram (up)

شکل ۴- معماری معمول سیستم استنتاج فازی سوگنو (پایین) و ساختار ANFIS معادل آن (بالا)

پس از آموزش سامانه‌های مختلف، معیارهای آماری خطای جذر میانگین مربعات (RMSE)، میانگین خطای مطلق (MAE) و ضریب تبیین (R²) برای ارزیابی و مقایسه عملکرد سامانه‌های عصبی مصنوعی و مدل ANFIS در تخمین میزان اکسیژن محلول آب، مورد استفاده قرار گرفت. روابط مربوط به هر یک از آماره‌ها در روابط (۱) تا (۳) ارائه شده است.

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

$$MAE = \frac{\sum_{i=1}^n |O_i - P_i|}{n} \quad (2)$$

$$R = \frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 (P_i - \bar{P})^2}} \quad (3)$$

در این روابط RMSE، MAE و R به ترتیب خطای جذر میانگین مربعات، میانگین خطای مطلق و ضریب همبستگی هستند. ضریب تبیین (R²) برابر با مجذور ضریب همبستگی است. O_i میزان خروجی واقعی، P_i میزان خروجی مدل و n تعداد کل داده‌هاست. داده‌ها با سه برنامه جداگانه در محیط MATLAB 2015 انجام و تحلیل خروجی‌ها توسط نرم‌افزار SPSS 16 استفاده شد و شکل‌ها در محیط Excell 2007 ترسیم شدند.

- 1 - Root Mean Square Error
- 2 - Mean Absolute Error
- 3 - Correlation Coefficient

۳- نتایج و بحث

نتایج نشان داد در شبکه عصبی استفاده شده تابع انتقال logsig-purelin در لایه پنهان با ۱۷ نورون با میزان ۰/۷۰، بیشترین ضریب تبیین را داشت و مقدار خطای جذر میانگین مربعات و میانگین خطای مطلق آن نیز به ترتیب ۱/۴۲ و ۱/۰۹ بود (شکل ۵).

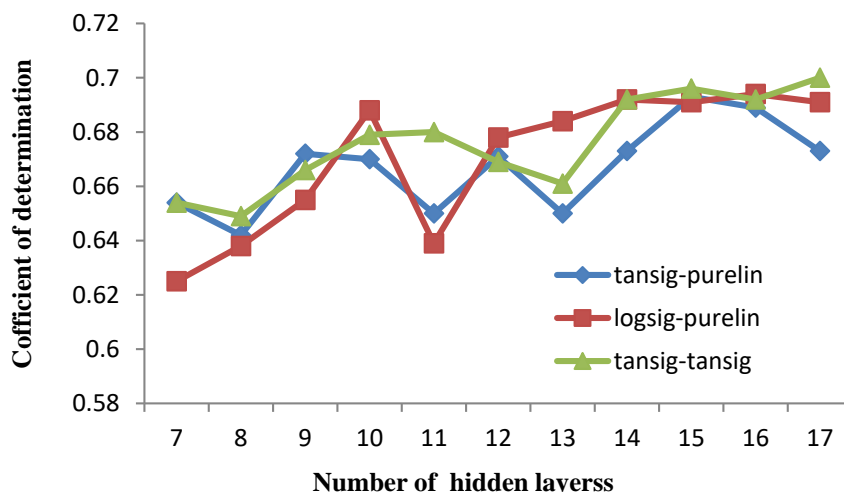


Figure 5. Coefficient of determination rate at different number of neurons in hidden layer and with different transfer functions

شکل ۵- میزان ضریب تبیین در تعداد نورون‌های مختلف در لایه پنهان و با توابع انتقال مختلف

در ادغام کردن الگوریتم ژنتیک با شبکه عصبی ابتدا بر طبق آزمون و خطا چند مقدار برای ضریب فشار در روش چرخ رولت و اندازه دسته در روش انتخاب رقابتی، آزمون شده و میزان ضریب تبیین محاسبه شد. نتایج تجزیه واریانس داده‌ها نشان داد تمامی مقادیر ضریب فشار و تعداد دسته انتخابی اثر یکسانی بر ضریب تبیین، MAE و RMSE داشتند؛ به همین خاطر از بین آنها مقداری انتخاب شد که بیشترین مقدار عددی ضریب تبیین را داشتند (جدول ۲).

جدول ۲- مقادیر ضریب تبیین در مقادیر مختلف ضرایب تنظیم در ادغام شبکه عصبی و الگوریتم ژنتیک

Table 2. R² rates in different rates of adjustment coefficient at combined ANN and GA

pressure index/ Batch size	7	9	11	13	15
Roulette Wheel method	0.250 ^b	0.302 ^b	0.411 ^a	0.400 ^a	0.334 ^{b*}
Tournament Selection method	0.310 ^b	0.377 ^a	0.371 ^a	0.394 ^a	0.394 ^a

* Different letters means statistical significant difference at $P < 0.05$

طبق نتایج به دست آمده روش انتخاب چرخ رولت و انتخاب دسته‌های یازده تایی به دلیل ایجاد ضریب تبیین بالاتر بین ورودی‌ها و خروجی انتخاب و در لایه‌های پنهان مختلف ارزیابی شد. نتایج نشان داد که بیشترین مقدار ضریب تبیین با قرار دادن هفده نورون در لایه پنهان با ضریب تبیین ۰/۳۹ به دست آمد (جدول ۳)؛ بنابراین ادغام کردن الگوریتم ژنتیک با شبکه عصبی نتایج مناسبی نسبت به فقط کاربرد شبکه عصبی دربر نداشت.

جدول ۳- نتایج ادغام شبکه عصبی و الگوریتم ژنتیک در مقادیر مختلف لایه پنهان

Table 3. Results of combined ANN and GA in different rates of hidden layer

Neuron numbers of hidden layer	9	11	13	15	17
R ²	0.376	0.385	0.392	0.384	0.394
MAE	0.207	0.206	0.205	0.206	0.202
RMSE	0.248	0.246	0.252	0.247	0.243



یازدهمین کنگره ملی مهندسی مکانیک بیوسیستم و مکانیزاسیون ایران



طبق نظر برخی پژوهشگران، روش‌های الحاقی به شبکه عصبی زمانی سبب بهبود ضریب تبیین می‌شوند که تعداد داده‌ها اندک باشند و توسعه این روش‌ها، برای کاهش تعداد نمونه‌برداری و کاهش تعداد متغیرهای ورودی و در نتیجه سهولت جمع‌آوری داده‌های ورودی است (Sadeghi et al. 2014). البته برخی دیگر از پژوهشگران نظر متفاوت و اعتقاد دارند که مدل مناسب بستگی به نوع داده‌ها دارد و باید مقایسه شوند تا مدل مناسب مشخص شود (Heddam, 2014).

ادغام شبکه عصبی با منطق فازی (ANFIS)، نتایج بهتری نسبت به شبکه عصبی در برداشت. در حالت شبکه‌بندی از بین حالات انتخابی تعداد دو تابع گوسی نوع دو با خروجی خطی با ضریب تبیین ۰/۸۵۹ به‌عنوان بهترین تخمین‌زننده انتخاب شد (جدول ۴). در حالت خوشه‌بندی C-means با در نظر گرفتن ۱۱ خوشه، بیشترین ضریب تبیین با میزان ۰/۸۲۳ به‌دست آمد. در حالت خوشه‌بندی کاهش میزان ضریب تبیین، خطای جذر میانگین مربعات و میانگین خطای مطلق به ترتیب ۰/۱۱۵، ۰/۰۸۶ و ۰/۰۸۶ بودند. در نتیجه بیشترین میزان ضریب تبیین در این مدل به‌دست آمد. این نتیجه با نتیجه به‌دست آمده با پژوهش‌های دیگران تأیید می‌شود (Heddam, 2014) که در آن یک شبکه عصبی و یک شبکه انفیس برای پیش‌بینی محلول مورد استفاده قرار گرفتند و میزان ضریب تبیین در شبکه عصبی، انفیس در حالت شبکه‌بندی و انفیس در حالت خوشه‌بندی کاهش به ترتیب ۰/۵۶، ۰/۷۴ و ۰/۷۶ به‌دست آمد. در ادامه برای تعیین میزان حساسیت پارامترهای ورودی شبکه عصبی - فازی با حذف هر کدام از ورودی‌ها، مدل به‌طور جداگانه اجرا شد. مهمترین پارامتر مؤثر بر مدل سرعت باد بود؛ زیرا با حذف آنها از مدل میزان ضریب تبیین کاهش بیشتری داشت و همچنین میزان خطاهای مدل MAE و RMSE افزایش بیشتری یافت (جدول ۵). در پژوهش مشخص شد که در روزهای بادی میزان انتقال اکسیژن در آب از ۰/۱ به ۰/۵ گرم بر مترمکعب در هر ساعت افزایش می‌یابد (Welch, 1968). در پژوهشی دیگر یک رابطه رگرسیونی بین سرعت باد و میزان انتقال استاندارد اکسیژن به صورت رابطه (۴) ارائه شد (Boyd & Coddington, 1992):

$$K_{La20} = 0.017x - 0.014 \quad R^2 = 0.882$$

(۴)

که در آن K_{La20} ضریب انتقال استاندارد اکسیژن (در ۲۰ درجه سلسیوس (h^{-1})) و x سرعت باد ($m.s^{-1}$) بود.

جدول ۴- مقادیر R^2 ، MAE و RMSE در اثر تغییر پارامترها در روش شبکه‌بندی

Table 4. The rates of R^2 , MAE and RMSE at different rates of indeces at grid partitioning method

Number of MF	MF type	Output type	R^2	MAE	RMSE
2	Gaussmf	constant	0.759	0.134	0.172
2	Gaussmf	linear	0.852	0.100	0.129
3	Gaussmf	constant	0.845	0.102	0.133
2	Trimf	constant	0.752	0.140	0.175
2	Trimf	linear	0.826	0.110	0.141
3	Trimf	constant	0.841	0.105	0.134
2	Gbellmf	constant	0.757	0.132	0.170
2	Gbellmf	linear	0.850	0.102	0.130
3	Gbellmf	constant	0.824	0.109	0.141
2	Gauss2mf	constant	.748	0.132	0.172
2	Gauss2mf	linear	0.859	0.098	0.125
3	Gauss2mf	constant	0.790	0.118	0.156

برای کاهش هزینه‌های تمام‌شده برای خودکار کردن هواده‌ها، مدل در حالت عدم اندازه‌گیری پارامترهای آب و با تکیه بر داده‌های هواشناسی ارزیابی شد و ضریب تبیین ۰/۸۷ به‌دست آمد (جدول ۵). در نتیجه در شرایط پرورش ماهی منطقه به‌دلیل آنکه تراکم ماهی استخرها پایین است،



یازدهمین کنگره ملی مهندسی مکانیک بیوسیستم و مکانیزاسیون ایران



شاخص‌های pH و دمای آب در محدوده مجاز خود هستند و تأثیر چندانی بر مدل نداشته و با لحاظ کردن سه شاخص هواشناسی منطقه می‌توان میزان اکسیژن محلول را پیش‌بینی کرد (جدول ۱). مدل انفیس ارائه شده دارای ضریب تبیین بالاتری نسبت پژوهش‌های گذشته بود (Palani et al., 2009; Masrur Ahmad, 2017; Emamgholizadeh et al., 2014).

جدول ۵- میزان حساسیت به پارامترهای ورودی در سامانه انفیس برای تخمین میزان اکسیژن محلول آب استخر

Table 5. Sensitivity rate to input parameters at ANFIS for prediction of pool water dissolved oxygen

Deleted parameter	R ²	MAE	RMSE
pH	0.865	0.124	0.095
Water temperature	0.862	0.121	0.092
Air temperature	0.862	0.126	0.095
Wind speed	0.824	0.142	0.110
Air moisture	0.855	0.125	0.095
pH and Water temperature	0.872	0.105	0.102

با استفاده از نتایج مدل ارائه شده می‌توان از نظر مجهز کردن هواده برای اندازه‌گیری میزان اکسیژن محلول در آب به میزان زیادی صرفه‌جویی کرد و به جای خرید و نصب سنسورهای اکسیژن برای هر استخر (هزینه هر عدد ۵ میلیون تومان) با نصب کیت مجهز شده به نرم‌افزار انفیس هزینه را به مقدار زیادی کاهش داد تا بهره‌برداران برای خرید دستگاه هواده رغبت داشته باشند.
نکته دیگر آنکه مدل حاضر در منطقه اهواز جوابگو و برای مناطق دیگر ممکن است در نظر گرفتن همه شاخص‌ها ضروری باشد و برای کاربرد در مناطق دیگر نیاز به تنظیم مدل است.

۴- نتیجه‌گیری

در این پژوهش، برای پیش‌بینی میزان اکسیژن محلول در آب استخرهای پرورش ماهیان گرمابی از رویکرد سامانه‌های عصبی مصنوعی استفاده شد و با کاربرد الگوریتم ژنتیک، سعی شد که اوزان اتصالات شبکه عصبی بهینه شود و همچنین تأثیر فازی کردن ورودی‌ها با شبکه عصبی بررسی شد. نتایج کلی نشانگر برتری نسبی سامانه ANFIS بر دو روش دیگر بود و این روش با ورودی‌های pH و دمای آب، رطوبت و دمای هوا و سرعت باد با ضریب تبیین ۰/۸۸ قادر به تخمین میزان اکسیژن محلول در آب استخر است؛ بنابراین با مجهز کردن هواده‌های عمودی مورد استفاده به سیستم‌های راه‌انداز که از مدل به‌دست آمده ورودی‌ها را دریافت کنند، می‌توان مصرف انرژی استخرها و هزینه کارگری را به میزان زیادی کاهش داد و از تلفات ماهی‌ها در اثر روشن نکردن به‌موقع هواده‌ها جلوگیری کرد.

۵- تشکر و قدردانی

بدین‌وسیله از ریاست محترم پژوهشکده تحقیقات آبی‌پروری جنوب و همکاران بخش آبی‌پروری آن پژوهشکده به‌دلیل همکاری در اجرای این پژوهش کمال تشکر را دارم.

۶- مراجع

- Boyd, C. E., & Coddington, D. T. (1992). Relationship between wind speed and reaeration in small aquaculture ponds. *Aquacultural Engineering*, 11(2), 121-131.
- Emamgholizadeh, S., Kashi, H., & Marofpoor, I. (2014). Prediction of water quality parameters of Karoon River (Iran) by artificial intelligence-based models. *International Journal of Environmental Science and Technology*, 11, 645-656.
- Fausett, L. (1994). *Fundamentals of neural networks architectures algorithms and applications*. Prentice-Hall Inc. New Jersey. 476 p.
- Golabi, M. R., Akhondali, A. M., & Radmanesh, F. (2013). Comparison of the performance of different artificial neural network algorithms in seasonal rainfall modeling Case study; Selected stations in Khuzestan province. *Scientific Journals Management System*, 13(30), 151-169. (Persian).



یازدهمین کنگره ملی مهندسی مکانیک بیوسیستم و مکانیزاسیون ایران



- Heddam, H. (2014). Modeling hourly dissolved oxygen concentration (DO) using two different adaptive neuro-fuzzy inference systems (ANFIS): a comparative study. *Environmental Monitoring*, 186, 597-619.
- Huihui Y., Yingyi, C., Shahbazgul, H., & Daoliangi, L. (2016). Dissolved oxygen content prediction in crab culture using a hybrid intelligent method. *Scientific Reports* volume 6, Article number: 27292. doi: 10.1038/srep27292.
- Kennard, R. W., & Stone L. A. (1969). Computer aided design of experiment. *Technometrics*, 11(1), 137-147.
- Kuo, Y. M. Liu, C. W., & Lin, K. H. (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 Research*, 38(1), 148-58.
- Masrur Ahmad, A. A. (2017). Prediction of dissolved oxygen in Surma River by biochemical oxygen demand and chemical oxygen demand using the artificial neural networks (ANNs). *Journal of King Saud University: Engineering Sciences*, 29(2), 151-158.
- Mwegoha, W. J. S., Kaseva, M. E., & Sabal, S. M. M. (2010). Mathematical modeling of dissolved oxygen in fish ponds. *African Journal of Environmental Science and Technology*, 4(9), 625-638.
- Nurani, V., & Salehi, K. (2008). *Rainfall and runoff modeling by using adaptive neural network and comparison with neural networks and fuzzy inference methods*. the Fourth National Congress on Civil Engineering, Tehran University, Tehran, Iran (Persian).
- Palani, S., Liong, S. Y., Tkalich, P., & Jegathambal P. (2009). Development of a neural network model for dissolved oxygen in seawater. *Indian Journal of Geo-Marine Sciences*, 38(2), 151-159.
- Peighan, R., & M. Abdollahmashaie. (2008). *Management of warm water culturing fields*, Volume 2. Dariasar editin. 264 p. (Persian).
- Plumb, A. P. Rowe, R. C. York, P., & Brown, M. (2005). Optimization of the predictive ability of artificial neural network (ANN) models: A comparison of three ANN programs and four classes of training algorithm. *European Journal of Pharmaceutical Sciences*, 25, 395-405.
- Ross, T. J. (1995). *Fuzzy logic with engineering application*. McGraw Hill Inc. USA. 585 p.
- Sadeghi, H. Sohrabi Vafa, h., & Nouri, F. 2014. Applications of Neural Network Based on Genetic Algorithm for Long Term Energy Demand Forecasting. *Applied Theories of Economics journal*, 2, 29-52 (Persian).
- Welch, H. E. (1968). *Use of modified diurnal curves for the measurement of metabolism in standing water*. *Limnol. Oceanogr.*, 13, 679-687.
- Witten, I. H., & Frank, E. (2000). *Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations*. San Diego, Cal: Academic Press.
- Xu, Z., & Xu, Y. J. (2016). A Deterministic model for predicting hourly dissolved oxygen change: development and application to a shallow eutrophic Lake. *Molecular Diversity Preservation International, Water*, 8(41), 1-15.