



## مدلسازی دمای بیشینه و کمینه استخر پرورش ماهیان گرمابی با استفاده از روش‌های یادگیری ماشین

ابراهیم اسعدی اسکویی<sup>۱</sup>، بهزاد دهقان جیردهی<sup>۲</sup>، سید محمد تقی سدیدی شال<sup>۳</sup>، مرتضی پاکدامن<sup>۴\*</sup>، فرحناز کیان ارثی<sup>۴</sup>

تاریخ دریافت: ۱۴۰۲/۰۵/۱۸

تاریخ پذیرش: ۱۴۰۲/۱۰/۱۷

### چکیده

ماهی‌ها حیواناتی خونسرد هستند و متابولیسم، رشد و تغذیه آنها با دمای آب ارتباط تنگاتنگی دارد. تغییرات دمایی باعث بروز تنش در ماهی‌ها و بعضاً شیوع بیماری‌ها به هنگام گذر از آستانه‌های تحمل آنها می‌شود. با توجه به اهمیت موضوع، در این پژوهش به کمک داده‌های مشاهداتی روزانه ایستگاه هواشناسی کشاورزی رشت در استان گیلان، مربوط به بازه زمانی خرداد ۱۳۹۶ تا آبان ماه سال ۱۳۹۸، متغیرهای دمای بیشینه و کمینه استخر پرورش ماهیان گرمابی با استفاده از چند روش یادگیری ماشین مدلسازی شد. برای این منظور، روش‌های شبکه عصبی مصنوعی، تقویت گرادیان و جنگل تصادفی، برای مدلسازی دمای بیشینه و کمینه استخرهای یک مجموعه پرورش ماهی مورد استفاده قرار گرفتند. نتایج به دست آمده از ارزیابی عملکرد این رهیافت‌ها با داده‌های اندازه‌گیری شده، نشان داد برای مدلسازی دمای کمینه، شبکه عصبی (با ریشه میانگین مربعات ۱/۹۳ و همبستگی ۰/۹۲) و برای مدلسازی دمای بیشینه، مدل جنگل تصادفی (با ریشه میانگین مربعات ۱/۶۱ و همبستگی ۰/۹۵) دارای دقت بیشتری هستند. در صورت تدقیق بیشتر، با کاربست مدل‌های پیشنهادی می‌توان با استفاده از داده‌های روزانه پیش‌بینی هواشناسی، به عنوان ورودی، دمای بیشینه و کمینه را برای استخر پرورش ماهیان پیش‌بینی نمود و در صورت لزوم اقدامات مدیریتی مقتضی را با توجه به شرایط دمایی پیش‌بینی شده انجام داد.

**واژه‌های کلیدی:** ماهی گرمابی، یادگیری ماشین، پیش‌بینی، شبکه عصبی، جنگل تصادفی، روش تقویتی گرادیان

### مقدمه

اکسیژن محلول در آب گرم بحرانی‌تر از آب سرد می‌باشد. بر اساس نتایج Mohammad et al., (2018) دمای آب بر متابولیسم ماهی نازک تأثیر معنی‌داری داشته و کاهش دما موجب کاهش میزان متابولیسم استاندارد و افزایش دما موجب افزایش میزان آن در ماهی نازک گردید. چنین روندی در تأیید تأثیر دمای محیط بر متابولیسم موجودات خونسرد است. برای هر گونه ماهی، حد بالا و پایین، و همچنین یک محدوده بهینه برای رشد وجود دارد. دمای مناسب برای رشد ماهی را، دمای محیطی استاندارد می‌نامند. در صورتیکه دمای آب، خارج از

دما یکی از پارامترهای مهم در رشد و پرورش ماهیان است. در واقع می‌توان گفت دما، اولین عامل مؤثر در پرورش و یا نگهداری آبزیان می‌باشد. اثر دمای آب، در فرایند فیزیولوژیک از قبیل میزان تنفس، بازده تغذیه و جذب مواد غذایی، رشد، رفتار و تولید مثل مؤثر است. افزایش دمای تا ۱۰ درجه عموماً باعث دو یا سه برابر شدن واکنش‌های بیوشیمیایی و فیزیولوژی می‌گردد، به همین دلیل، نیاز

<sup>۳</sup> رئیس گروه مطالعات و تحقیقات هواشناسی استان گیلان  
<sup>۴</sup> عضو پژوهشکده آبی‌پروری آب‌های جنوب کشور، مؤسسه تحقیقات علوم شیلاتی کشور، سازمان تحقیقات، آموزش و ترویج کشاورزی، اهواز، ایران

<sup>۱</sup> عضو هیات علمی پژوهشگاه هواشناسی و علوم جو، پژوهشکده اقلیم‌شناسی مشهد، مشهد، ایران

(پاکدامن.م@gmail.com)

<sup>۲</sup> کارشناس مرکز تحقیقات هواشناسی کشاورزی گیلان

نحوه ارجاع مقاله:

دمای آب، کاهش اشتهای، بی حالی و بی تفاوتی است که به نوبه خود سبب کاهش میزان متابولیسم معمول در آنها می‌شود. علاوه بر این، تأثیر دما بر تحرک ماهی و همچنین میزان فعالیت آنزیم‌ها و ماهیچه‌های قلبی نیز کاملاً مشخص شده است (Tuckey et al, 2012). کاهش فعالیت خود بخودی ماهی همگام با کاهش دما نیز گزارش شده است (Castonguay and Cyr, 1998). بروز چنین رفتاری موجب می‌گردد ماهی انرژی کمتری را صرف نماید و به دنبال آن نیازهای متابولیکی آن کاهش پیدا خواهد کرد (Farrell, 2011). در جانداران خونسرد پاسخ‌های متابولیکی که به عنوان میزان مصرف اکسیژن شناخته می‌شوند همبستگی خطی یا نمایی را با دما نشان می‌دهند و علت آن تأثیر مستقیم دما بر واکنش‌های کینتیکی آنزیم‌های درگیر است (Guderley, 2004). لذا همسو با تغییرات دمایی میزان فعالیت آنزیم‌های درگیر، بدن‌بال آن میزان مصرف اکسیژن تغییر خواهد کرد. Zarafshani and Amirian (2018) به بررسی آسیب‌پذیری آبی‌پروران نسبت به مخاطرات آب‌وهوایی پرداختند و نشان دادند کم آبی، گرم‌تر شدن هوا و گرد و غبار مهمترین تغییرات آب‌وهوایی مؤثر بر پرورش آبزیان هستند. Mousavi Deh Mordi et al., (2018) تأثیر تغییرات اقلیمی روی شیلات و آبی‌پروری و راهکارهای سازش با آن را بررسی کردند و نشان دادند تغییرات اقلیمی که بر روی آبی‌پروری تأثیر می‌گذارد شامل گرمایش جهانی، نفوذ آب شور، افزایش سطح آب دریا، کاهش تولیدات اقیانوسی، تغییر در الگوهای گردش، تغییرات در مونسون و وقوع رویدادهای شدید آب و هوایی، استرس آب، تغییرات در رژیم‌های هیدرولوژیکی آب‌های داخلی، افزایش بیماری‌ها، اثرات اجتماعی بر مزرعه‌داران و پرورش دهندگان، تأثیر بر تنوع زیستی و تأثیر بر تأمین خوراک آبزیان پرورشی می‌باشد. با توجه به مطالب فوق، مدلسازی دمای آب با دقت قابل قبول می‌تواند در نگهداری بهینه ماهیان و در نتیجه افزایش کارایی استخرهای پرورش ماهی مؤثر باشد. روش‌های متعددی برای مدلسازی دمای آب استخر وجود دارد که در این بین روش‌های یادگیری ماشین به دلیل توانایی بالا در مواجهه با حجم انبوه داده‌های با ساختار غیرخطی، از اهمیت بسزایی برخوردار هستند. لذا از این روش‌ها به صورت گسترده در مدلسازی پارامترهای مختلف آب و هوایی استفاده

محدوده بهینه باشد در ماهی ایجاد فشار می‌نماید، که این تنش بر تغذیه، رشد و تولید مثل تأثیرگذار است. دما به عنوان یکی از پارامترهای فیزیکی آب نقش مهمی در حیات آبزیان دارد (Brett and Groves., 1979; Beitinger and Lutterschmidt., 2011). دمای آب‌های جاری معمولاً بر حسب فصل و در طول شبانه‌روز و همچنین بین مناطق مختلف به علت نوع اقلیم، ارتفاع، وسعت پوشش گیاهی حاشیه رودخانه و میزان ورودی آب‌های زیرزمینی تغییر می‌کند (Welch, 1999). در کنار عوامل طبیعی مذکور، آلودگی‌های حرارتی نیز در برهم زدن رژیم حرارتی اکوسیستم‌های آبی نقش قابل ملاحظه‌ای دارند (Nordell, 2003). آلودگی حرارتی به هرگونه تخلیه آب گرم حاصل از فعالیت‌های مختلف از جمله نیروگاه‌های تولید برق، نیروگاه‌های هسته‌ای و غیره به رودخانه‌ها، دریاچه‌ها یا سواحل که منجر به تغییرات نامناسب دمای آب گردد، اطلاق می‌شود (Moore, 1958). به هر حال، باتوجه به تعداد نیروگاه‌های فعال در کشور و میزان فعالیت آن‌ها، وجود چنین آلودگی‌هایی دور از ذهن نیست. تغییرات طولانی‌مدت (حتی کوتاه‌مدت) در دمای محیط موجب می‌گردد تا جانداران خونسرد پاسخ‌های متفاوتی جهت مقابله با تغییرات دمایی از خود نشان دهند. اغلب ماهیان به عنوان موجوداتی خونسرد نمی‌توانند دمای بدن خود را متفاوت از دمای محیط اطراف حفظ نمایند و بنابراین تغییر در دمای آب می‌تواند تأثیر قابل توجهی بر آنها داشته باشد و حتی در پراکنش و فراوانی آنها نیز تأثیرگذار باشد (Beitinger and Bennett, 2000; Rastogi, 2007; Sarma et al 2010). علاوه بر این، دمای آب در تعیین محدوده بالا و پایین متابولیکی آبزیان نقش مهمی را ایفا می‌کند (Kieffer et al, 2014). در نتیجه هرگونه تغییر در دمای آب بر رفتار، مهاجرت، فرایندهای متابولیکی، تولید مثل، رشد و سرانجام بقای آبزیان تأثیرگذار است (Fry, 1971). دمای آب اثرات قابل توجهی بر فرایندهایی مانند میزان متابولیسم دارد اما میزان این تأثیر بین گونه‌های مختلف متفاوت است. علاوه بر این، تأثیر تغییرات دمایی بر متابولیسم ماهی باتوجه به ایجاد سازگاری یا بروز ناگهانی آن بسیار متفاوت خواهد بود (Kieffer and Wakefield, 2009). از جمله بارزترین پاسخ موجودات خونسرد نسبت به کاهش

انفرادی، تعداد زیادی از این روش‌ها را بر مجموعه داده (و یا زیرمجموعه‌هایی از داده‌ها) اعمال کرده و نتیجه نهایی، از هم‌افزایی نتایج جزئی به دست می‌آید. لذا یکی از پارامترهای مهم و قابل تنظیم در این الگوریتم‌ها، تعیین تعداد الگوریتم‌های پایه مورد استفاده در آنهاست. در این بخش، دو روش گروهی روش تقویتی گرادیان و جنگل تصادفی و نیز روش پایه انفرادی شبکه عصبی پرسپترون چند لایه معرفی می‌شوند. در این الگوریتم نیز تعداد لایه‌های شبکه، تعداد نرون‌های هر لایه مخفی، و نیز نوع تابع فعالیت شبکه و الگوریتم آموزش شبکه عصبی از جمله مهمترین پارامترهای قابل تنظیم برای شبکه عصبی هستند. شایان ذکر است که انتخاب این الگوریتم‌ها از میان انبوه روش‌های یادگیری ماشین به دلیل توانایی بالای آنها در تقریب پارامترهای هواشناسی است که در پیشینه نیز ذکر گردید. در این مقاله از زبان برنامه نویسی پایتون و کتابخانه scikit-learn برای پیاده‌سازی الگوریتم‌های یادگیری، تنظیم پارامترهای آنها و نیز تقسیم داده‌ها به داده آزمون و آموزش استفاده گردید. همچنین این کتابخانه برای نرم‌ساز داده‌ها نیز توابع آماده دارد که در این مقاله مورد استفاده قرار گرفتند.

### الف- روش تقویتی گرادیان

روش تقویتی گرادیان یک روش یادگیری ماشین است که برای حل مسائل رگرسیون و طبقه‌بندی استفاده می‌شود. این مدل ترکیبی از یک سری مدل‌های ضعیف است که به صورت تناوبی برای ایجاد یک مدل نهایی قوی ساخته شده است. به طوری که یک مدل پیش‌بینی را در قالب مجموعه‌ای از مدل‌های پیش‌بینی گروهی ضعیف ارائه می‌دهد که معمولاً درخت‌های تصمیم هستند (Piryonesi, 2020; Hastie, 2009). ایده روش تقویتی گرادیان از مشاهدات Breiman (2001) مبنی بر اینکه تقویت<sup>۱</sup> را می‌توان به عنوان یک الگوریتم بهینه‌سازی بر روی یک تابع هزینه مناسب تفسیر کرد، سرچشمه گرفته است (Breiman, 1997). پس از آن الگوریتم‌های تقویتی گرادیان مختلفی متعاقباً توسط Friedman (1999)، همزمان با دیدگاه کلی‌تر روش تقویتی گرادیان تابعی توسط Mason et al., (1999) توسعه داده

می‌شود. به عنوان مثال Pakdaman et al., (2022) از روش‌های گروهی چند مدلی یادگیری ماشین، در پیش‌بینی ماهانه بارش ایران، به عنوان یک مسأله رگرسیونی استفاده نمودند. طبق نتایج این مقاله، شبکه عصبی و جنگل تصادفی در مقایسه با درخت تصمیم و ماشین بردار پشتیبان، نتایج بهتری را فراهم نمودند. همچنین Pakdaman et al., (2022) از روش‌های یادگیری ماشین برای پیش‌بینی پدیده رعد و برق به عنوان یک مسأله طبقه‌بندی استفاده نمودند. طبق نتایج این پژوهش، درخت تصمیم در مقایسه با شبکه عصبی عملکرد بهتری داشته است. علاوه بر استفاده از روش‌های یادگیری ماشین در پیش‌بینی پارامترهای هواشناسی، از این الگوریتم‌ها در بخش‌های مختلف هواشناسی کشاورزی نیز استفاده می‌شود. به عنوان مثال Momenpour et al., (2023) در تخمین عملکرد محصول نخود با استفاده از شاخص‌های اقلیمی-کشاورزی در کرمانشاه، از روش‌های یادگیری ماشین استفاده نمودند. (Afzali et al., 2018) از روش‌های یادگیری ماشین برای پیش‌بینی میزان اکسیژن محلول در آب استخرهای ماهی استفاده نمودند. در این پژوهش سه روش مختلف شبکه عصبی مصنوعی، ترکیب شبکه عصبی با الگوریتم ژنتیک و سیستم عصبی-فازی مورد آزمایش قرار گرفت و مدل سیستم عصبی-فازی بهترین تخمین را ارائه کرد. (Pakdaman et al., 2022) از روش‌های یادگیری ماشین برای پیش‌بینی ماهانه بارش در جنوب غرب آسیا استفاده نمودند. با توجه به بررسی مطالعات پیشین در این مقاله سه روش تقویتی گرادیان، شبکه عصبی مصنوعی و جنگل تصادفی برای مدلسازی دمای استخر پرورش ماهی مورد ارزیابی قرار می‌گیرد.

### مواد و روش‌ها

در این بخش روش‌های یادگیری ماشین مورد استفاده در این مقاله به اختصار شرح داده می‌شود. روش‌های یادگیری ماشین را در یک نوع دسته‌بندی می‌توان به روش‌های انفرادی پایه و روش‌های گروهی تقسیم‌بندی نمود (Breiman, 2001). در روش‌های گروهی، به جای استفاده از تنها یک روش پایه

<sup>1</sup> Boosting

پیاده‌سازی الگوریتم جنگل تصادفی از تابع scikit-learn RandomForestRegressor که در کتابخانه موجود است، استفاده گردید.

### ج- شبکه عصبی مصنوعی

از مدل‌های متفاوت شبکه عصبی برای پیش‌بینی پارامترهای مختلف جوی و اقلیمی به صورت گسترده استفاده می‌شود. این امر می‌تواند دلایل بسیار زیادی داشته باشد. از جمله این دلایل می‌توان به توانایی بالای شبکه‌های عصبی در مواجهه با داده‌های با حجم بالا، قدرت تعمیم فوق‌العاده و توانایی یادگیری آنها اشاره نمود. یکی از مهمترین مدل‌های شبکه عصبی مورد استفاده، شبکه‌های عصبی پرسپترون چندلایه (MLP)<sup>۳</sup> هستند. ثابت شده است که شبکه‌های عصبی پرسپترون چندلایه توانایی تخمین توابع پیوسته با دقت دلخواه را دارند. در شبکه عصبی تعداد زیادی پارامتر و وزن وجود دارد که همگی قابل تنظیم هستند. برای یافتن مقادیر بهینه پارامترهای مجهول شبکه عصبی، معمولاً از یک روش بهینه‌سازی ریاضی استفاده می‌شود. فرآیند یافتن مقادیر بهینه وزن‌های شبکه عصبی، برای برازش شبکه به داده‌ها را آموزش شبکه عصبی می‌نامند. فرآیند یادگیری شبکه عصبی یکی از مراحل مهم در حل مسأله به کمک این ابزار قدرتمند است. هر گره از شبکه عصبی یک نرون مصنوعی است. رابطه ریاضی نرون مطابق معادله ۱ تعریف می‌شود.

$$y = \sigma\left(\sum_i w_i x_i + b\right) \quad (1)$$

که در آن  $w_i$  وزن ورودی  $x_i$ ،  $b$  اربیبی و  $\sigma$  نیز تابع فعالیت یا تابع محرک نرون است. عموماً این تابع به صورت تابع زیگموئید انتخاب می‌شود. برای پیاده‌سازی الگوریتم شبکه عصبی از تابع MLPRegressor که در کتابخانه scikit-learn موجود است استفاده گردید.

### داده‌های مورد استفاده

موقعیت ایستگاه هواشناسی کشاورزی رشت در استان گیلان و استخر پرورش ماهی گرمابی در شکل ۱ نشان داده شده است. داده‌های این مسأله شامل داده‌های هواشناسی

شدند (Friedman, 1999; Mason, 1999). در این دو پژوهش، دیدگاه الگوریتم‌های تقویتی به عنوان الگوریتم‌های کاهش گرادیان تابعی تکراری معرفی شدند. به این معنا که الگوریتم‌ها با انتخاب مکرر یک تابع در جهت منفی گرادیان، یک تابع هزینه را در فضای تابعی بهینه می‌کنند. دیدگاه تقویتی گرادیان تابعی به توسعه الگوریتم‌های تقویتی در بسیاری از حوزه‌های یادگیری ماشین و آمار، فراتر از رگرسیون و طبقه‌بندی منجر شده است. برای پیاده‌سازی الگوریتم تقویت گرادیان از تابع GradientBoostingRegressor که در کتابخانه scikit-learn موجود است استفاده گردید.

### ب- روش جنگل تصادفی

جنگل‌های تصادفی (RF)<sup>۱</sup> که برای اولین بار توسط Breiman, (2001) پیشنهاد شدند به طور گسترده برای رگرسیون متغیرهای مختلف جغرافیایی استفاده می‌شوند. RF یک روش گروهی یادگیری ماشین است که از چندین درخت تصمیم تشکیل شده و می‌تواند نرخ بالایی از دقت ایجاد کند و عملکرد آن در پیش‌بینی داده‌های جدید با تجمیع نتایج تمام درختان تعیین می‌شود (Hengl et al., 2018). تصادفی‌سازی در RF به دو جنبه انتخاب تصادفی نمونه‌های متغیرهای پیش‌بینی‌کننده، به عنوان ویژگی‌های انشعاب در هر گره درخت، منجر می‌شود (Merghadi et al., 2020; Yoo et al., 2018). جنگل تصادفی از مراحل اصلی بگینگ<sup>۲</sup> تبعیت کرده و برای ساخت طبقه‌بندی پایه از الگوریتم درخت تصمیم استفاده می‌کند. علاوه بر اینکه در بگینگ از نمونه‌گیری بوت‌استرپ و رأی‌دهی به اکثریت استفاده می‌شود، جنگل تصادفی از انتخاب فضای ویژگی تصادفی در ساخت مجموعه یادگیری برای بالا بردن تنوع طبقه‌بند پایه استفاده می‌کند. تصادفی بودن RF سبب می‌شود که در برابر مشکل بیش‌برازش مقاوم باشد. جنگل تصادفی که در برخورد با ناهمگنی در محیط‌های جغرافیایی بسیار امیدوارکننده و انعطاف‌پذیر است، برای پیش‌بینی متغیرهای مکانی و زمانی بسیار کاربرد دارد (Hengl et al., 2018; Yoo et al., 2018).

<sup>3</sup> Multi-Layer Perceptron (MLP)

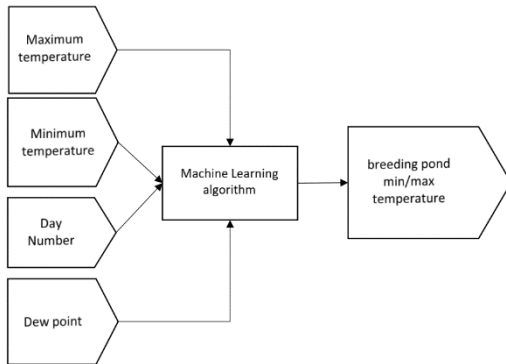
<sup>1</sup> Random Forest (RF)

<sup>2</sup> Bagging: Bootstrap Aggregating

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - X_i)^2}{n}} \quad (3)$$

$$R = \frac{\sum_{i=1}^n (X_i - \bar{X})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (O_i - \bar{O})^2}} \quad (4)$$

که در آن  $O_i$  و  $X_i$  به ترتیب مشاهدات و مقادیر مدل هستند و  $\bar{O}$  و  $\bar{X}$  نیز به ترتیب مبین میانگین مشاهدات و میانگین مدل هستند.



شکل ۲- شمای کلی مدلسازی سه روش یادگیری ماشین


Figure 2- General framework of three machine learning algorithms

## نتایج و بحث

همانطور که بیان شد، برای پیاده‌سازی الگوریتم‌های یادگیری ماشین از بسته نرم‌افزاری scikit-learn (Pedregosa et al., 2011) در زبان برنامه‌نویسی پایتون استفاده گردید. این بسته شامل الگوریتم‌های متعدد یادگیری ماشین است. پس از اعمال سه روش یادگیری ماشین، شبکه عصبی، جنگل تصادفی و تقویت گرادیان بر روی داده‌های مسأله، نتایج ارزیابی عملکرد آنها برای هر دو دسته داده‌های آزمایش و آموزش در جداول ۱ و ۲ ذکر شده است. با توجه به جدول ۱ مشاهده می‌شود که نتایج مربوط به مدل شبکه عصبی پرسپترون چند لایه در مقایسه با دو روش دیگر برتری دارد. نتایج جدول ۱ مربوط به یک شبکه عصبی دو لایه با به ترتیب ۷ و ۱۱ نرون، تابع فعالیت ReLU با معادله ۵ و الگوریتم آموزش Adam است.

$$f(x) = \begin{cases} x & \text{if } x > 0 \\ 0 & \text{if } x \leq 0 \end{cases} \quad (5)$$

روزانه ایستگاه هواشناسی کشاورزی رشت در استان گیلان، مربوط به بازه زمانی خرداد ۱۳۹۶ تا آبان ماه سال ۱۳۹۸ بوده است.



شکل ۱- موقعیت ایستگاه هواشناسی کشاورزی رشت در

استان گیلان و استخر پرورش ماهیان گرمابی

Figure 1- Location of Rasht agrometeorology station (Guilan Province) and warm-water fish breeding ponds

متغیرهای ورودی الگوریتم‌ها شامل دمای بیشینه، دمای کمینه، شماره روز سال و میانگین دمای نقطه شبنم است و متغیرهای خروجی شامل دمای بیشینه و دمای کمینه استخر پرورش ماهی است که به صورت جداگانه مدلسازی شدند. دمای بیشینه و دمای کمینه استخر پرورش ماهی که با دامسج اندازه‌گیری می‌شود، برای حدود ۳۵۰ روز از بازه زمانی خرداد ۱۳۹۶ تا آبان ماه سال ۱۳۹۸ ثبت گردیده است. به منظور مدلسازی، دو مدل مختلف، یکی برای دمای بیشینه و دیگری برای دمای کمینه آموزش داده می‌شود. در این مقاله ۳۰ درصد داده‌ها برای آزمایش و ۷۰ درصد آنها برای آموزش الگوریتم‌ها مورد استفاده قرار گرفت. انتخاب داده‌های آموزش و آزمایش به صورت تصادفی انجام شد. برای ارزیابی عملکرد روش‌های پیشنهادی از سه شاخص ضریب همبستگی (Cor)<sup>۱</sup>، ریشه میانگین مربعات خطا (RMSE)<sup>۲</sup> و شاخص نش-ساتکلیف (NSE)<sup>۳</sup> به صورت معادله‌های ۲ تا ۵ استفاده می‌شود (Nash and Sutcliffe, 1970).

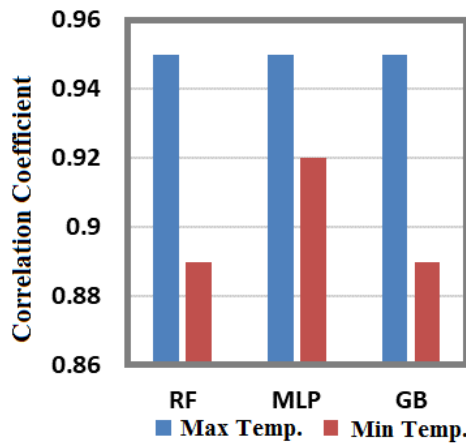
$$NSE = 1 - \frac{\sum_{i=1}^n (X_i - O_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (2)$$

<sup>1</sup> Correlation Coefficient (Cor)

<sup>2</sup> Root Mean Squared Error (RMSE)

<sup>3</sup> Nash-Sutcliffe efficiency (NSE)

آنها برای داده‌های آزمایش بهتر است. هرچند عملکرد هر الگوریتم برای هر متغیر در جداول ۱ و ۲ مشخص گردیده است، اما برای درک بهتر عملکرد الگوریتم‌ها و مقایسه آنها در مدل‌سازی دو متغیر دمای بیشینه و کمینه، شکل‌های ۲ تا ۴ ترسیم شده‌اند. مطابق شکل ۲، ملاحظه می‌شود که در مجموع، عملکرد الگوریتم‌ها برای ضریب همبستگی در مواجهه با داده‌های دمای بیشینه بسیار بهتر از مدل‌سازی دمای کمینه است. همچنین در صورتی که عملکرد سه الگوریتم برای مدل‌سازی دمای بیشینه و کمینه جداگانه بررسی شود مطابق شکل ۲، ضریب همبستگی برای دمای بیشینه برای سه الگوریتم تقریباً برابر است. این در حالی است که برای دمای کمینه ترتیب عملکرد بهتر به صورت شبکه عصبی، جنگل تصادفی و روش تقویتی گردید است.



شکل ۲- ضریب همبستگی برای الگوریتم‌های مختلف و برای دمای بیشینه و کمینه روی داده‌های آزمایش

Figure 2- Correlation Coefficient of maximum and minimum temperature for all algorithms and test data

مطابق شکل ۳، ملاحظه می‌شود که در مجموع، عملکرد الگوریتم‌ها برای ضریب نش-ساتکلیف در مواجهه با داده‌های دمای بیشینه بسیار بهتر از مدل‌سازی دمای کمینه است. همچنین در صورتی که عملکرد سه الگوریتم برای مدل‌سازی دمای بیشینه و کمینه جداگانه بررسی شود مطابق شکل ۳، ضریب نش-ساتکلیف برای دمای بیشینه برای سه الگوریتم به ترتیب عملکرد عبارت است از جنگل تصادفی، روش گردیدان تقویتی و شبکه عصبی. این در حالی است که برای دمای کمینه ترتیب عملکرد الگوریتم‌ها عبارت است از: شبکه عصبی، جنگل تصادفی و روش تقویتی گردیدان. مطابق شکل

جدول ۱- نتایج تخمین دمای کمینه برای داده‌های آموزش و آزمایش شامل ضریب همبستگی (Cor)، ضریب نش ساتکلیف (NSE) و ریشه میانگین مربعات خطا (RMSE)

Table 1-Results for minimum temperature estimation for test and train datasets including Correlation Coefficient (Cor), Nash-Sutcliffe efficiency (NSE) and Root Mean Squared Error (RMSE).

Data	Method	RMSE(°C)	NSE	Cor
Test	RF	2.18	0.80	0.89
	MLP	1.93	0.84	0.92
	GB	2.20	0.79	0.89
Train	RF	1.95	0.94	0.95
	MLP	1.82	0.85	0.94
	GB	1.99	0.82	0.91

تعداد نرون‌ها به صورت آزمون و خطا روی تعداد مختلف نرون به دست آمد. از سوی دیگر با توجه به پیشینه مورد مطالعه ترکیب تابع فعالیتهای ReLU و الگوریتم Adam انتخاب گردید (Barbu, 2023). نتایج مربوط به مدل‌سازی دمای بیشینه نیز در جدول ۲ ارائه شده است.

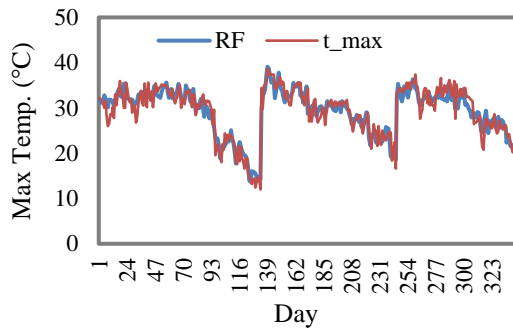
جدول ۲- نتایج تخمین دمای بیشینه برای داده‌های آموزش و آزمایش شامل ضریب همبستگی (Cor)، ضریب نش ساتکلیف (NSE) و ریشه میانگین مربعات خطا (RMSE)

Table 2-Results for maximum temperature estimation for test and train datasets including Correlation Coefficient (Cor), Nash-Sutcliffe efficiency (NSE) and Root Mean Squared Error (RMSE)

Data	Method	RMSE(°C)	NSE	Cor
Test	RF	1.61	0.91	0.95
	MLP	1.72	0.89	0.95
	GB	1.64	0.91	0.95
Train	RF	1.12	0.95	0.97
	MLP	1.51	0.93	0.96
	GB	1.49	0.94	0.96


با توجه به جدول ۲ ملاحظه می‌شود که بهترین عملکرد به جنگل تصادفی مربوط است. از آنجا که تعداد درخت تصمیم (الگوریتم پایه روش جنگل تصادفی) از جمله پارامترهای قابل تنظیم جنگل تصادفی است، با توجه به حجم داده‌ها، الگوریتم برای تعداد درخت تصمیم ۱۰، ۲۰، ۳۰، ۴۰ و ۵۰ جداگانه اجرا گردید که بهترین نتیجه (جدول ۲) برای تعداد درخت تصمیم ۲۰ به دست آمد. نکته حائز اهمیت در جداول ۱ و ۲ این است که از آنجا که داده‌های آموزش برای یادگیری مدل‌های یادگیری ماشین مورد استفاده قرار گرفتند، عملکرد هر سه الگوریتم برای هر دو متغیر دمای کمینه و بیشینه در جداول ۱ و ۲ و برای داده‌های آموزش، در مقایسه با عملکرد

مناسب‌تری دارد. شکل‌های ۵ و ۶ به منظور مقایسه دمای کمینه و بیشینه مشاهداتی با دمای تقریبی پیشنهادی توسط مدل بهینه ارائه شده‌اند. مطابق شکل ۵ ملاحظه می‌شود که مدل جنگل تصادفی تا حد قابل قبولی توانسته است دمای بیشینه (که در شکل ۵ با  $t_{max}$  نشان داده شده است) را تقریب بزند. همچنین با توجه به شکل ۶ نیز ملاحظه می‌گردد که مدل شبکه عصبی توانسته است با دقت مناسب دمای بیشینه را تخمین بزند. توجه شود که شکل‌های ۵ و ۶ برای کل داده‌های موجود ترسیم شده است.



شکل ۵- مقایسه دمای بیشینه مشاهداتی ( $t_{max}$ ) و مدل جنگل تصادفی (RF) برای کل داده‌های موجود.

Figure 5- Comparing observed maximum temperature ( $t_{max}$ ) and its corresponding estimation using RF.



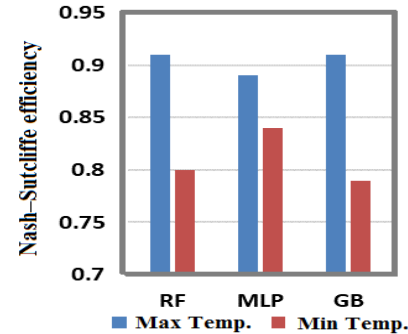
شکل ۶- مقایسه دمای کمینه مشاهداتی ( $tmin$ ) و مدل MLP برای کل داده‌های موجود

Figure 6- Comparing observed minimum temperature ( $tmin$ ) and its corresponding estimation using MLP.


### نتیجه‌گیری

نتایج این مطالعه نشان دادند که با استفاده از پیش‌بینی‌های موجود برای داده‌های ورودی مدل‌های پیشنهادی، می‌توان دمای کمینه و بیشینه استخر را با دقت مناسب مدلسازی نمود. البته با افزایش تعداد مشاهدات از

۴، ملاحظه می‌شود که در مجموع، مشابه دو شاخص دیگر، عملکرد الگوریتم‌ها برای ریشه میانگین مربعات خطا در مواجهه با داده‌های دمای بیشینه بسیار بهتر از مدلسازی دمای کمینه است.



شکل ۳- ضریب نش-ساتکلیف برای الگوریتم‌های مختلف و برای دمای بیشینه و کمینه روی داده‌های آزمایش Figure 3- Nash-Sutcliffe efficiency of maximum and minimum temperature for all algorithms and test data



شکل ۴- مقدار RMSE برای الگوریتم‌های مختلف و برای دمای بیشینه و کمینه روی داده‌های آزمایش

Figure 4- RMSE of maximum and minimum temperature for all algorithms and test data

همچنین در صورتی که عملکرد سه الگوریتم برای مدلسازی دمای بیشینه و کمینه جداگانه بررسی شود مطابق شکل ۴، ریشه میانگین مربعات خطا برای دمای بیشینه به ترتیب عملکرد الگوریتم‌ها به این صورت است: جنگل تصادفی، گرادیان تقویتی و شبکه عصبی. این در حالی است که برای دمای کمینه ترتیب عملکرد به صورت شبکه عصبی، جنگل تصادفی و روش تقویتی گرادیان است. بنابراین می‌توان نتیجه گرفت که دقت تخمین دمای بیشینه از دقت تخمین دمای کمینه بیشتر است. برای دمای بیشینه می‌توان ادعا نمود جنگل تصادفی و روش تقویتی گرادیان عملکرد یکسانی دارند در حالی که برای تخمین دمای کمینه، شبکه عصبی پرسپترون چند لایه در مقایسه با سایر روش‌ها عملکرد

- Guderley, H. 2004. Locomotor performance and muscle metabolic capacities: impact of temperature and energetic status. *Comparative Biochemistry and Physiology Part B: Biochemistry and Molecular Biology*, 139 (3), 371-382.
- Hastie, T., Tibshirani, R., Friedman, J. H. 2009. 10. Boosting and Additive Trees. *The Elements of Statistical Learning* (2nd ed.), New York: Springer.
- Hengl, T., Nussbaum, M., Wright, M. N., Heuvelink, G. B. M., Gräler, B. 2018. Random forest as a generic framework for predictive modeling of spatial and spatio-temporal variables, *PeerJ*, 6, e5518,
- Kieffer, J. D., Penny, F. M., Papadopoulos, V. 2014. Temperature has a reduced effect on routine metabolic rates of juvenile shortnose sturgeon (*Acipenser brevirostrum*). *Fish Physiology and Biochemistry*, 40 (2), 551- 559.
- Kieffer, J., Wakefield, A. 2009. Oxygen consumption, ammonia excretion and protein use in response to thermal changes in juvenile Atlantic salmon *Salmo salar*. *Journal of Fish Biology*, 74 (3), 591-603.
- Mason, L., Baxter, J., Bartlett, P. L., Frean, Marcus, 1999. Boosting Algorithms as Gradient Descent, In S.A. Solla and T.K. Leen and K. Müller (ed.). *Advances in Neural Information Processing Systems 12*. MIT Press, 512-518.
- Merghadi, A., Yunus, A. P., Dou, J., Whiteley, J., ThaiPham, B., Bui, D. T., Avtar, R., and Abderrahmane, B. 2020. Machine learning methods for landslide susceptibility studies: A comparative overview of algorithm performance, *Earth-Science Reviews*, 207, 103-225.
- Mohammadi, M., Mahboobi Soofiani, N.A., Farhadian, O., Malekpouri, P. 2018. Effects of different thermal acclimations on metabolic rate of Brond-snout *Chondrostoma regium*. *Journal of Animal Research (Iranian Journal of Biology)*, 31(1), 109-121. (In Farsi)
- Momenpour, S. E., Bazgeer, S., Moghbel, M., Mohammadi, H., Hossaini, S. M., Abdollahi Kakroudi, A. 2023. Application of machine learning approach for Chickpea yield estimation based on Agroclimatological Indices (Case Study: Kermanshah region). *Journal of Agricultural Meteorology*, 10(2), 37-51. (In Farsi)
- Moore, E. W. 1958. Thermal pollution of streams. *Industrial and Engineering Chemistry*, 50 (4), 87A-88A.
- Mousavi Deh Mordi, L., Ebadi, H., Fadeami, Y., Negahban, M. and Rashedi, S. 2018. The impact of climate change on fisheries and aquaculture and solutions to compromise with it, the fourth national طریق برداشت دمای استخر در تعداد روزهای بیشتر از سال (که ممکن است مستلزم هزینه بیشتر باشد) می‌توان حجم داده‌های مورد استفاده را افزایش داد. با افزایش حجم داده‌ها می‌توان دقت مدل‌سازی را با آموزش مدل‌ها روی تعداد بیشتر داده متنوع بهبود بخشید.

## سپاسگزاری

نویسندگان مقاله بر خود لازم می‌دانند از هیات محترم تحریریه و نیز داوران گرامی برای بررسی مقاله تشکر و قدردانی نمایند.

## منابع

- Afzali, S. M. J., Sheikhdavodi, M. J., Seiedmortezaie, S. R. 2018. Comparison of different artificial intelligence-based models for prediction of dissolved oxygen rates at fish growing pools- Case Study: Ahvaz city. *Journal of Researches in Mechanics of Agricultural Machinery*, 7(1), 69-80. (In Farsi)
- Barbu, A. 2023. Training a Two-Layer ReLU Network Analytically. *Sensors*, 23(8), 40-72.
- Beitinger, T. L., and Bennett, W. A. 2000. Quantification of the role of acclimation temperature in temperature tolerance of fishes. *Environmental Biology of Fishes*. 58 (3), 277-288.
- Beitinger, T., and Lutterschmidt, W. 2011. Measures of thermal tolerance. *Encyclopedia of Fish Physiology: From Genome to Environment*. 3, 1695-1702.
- Breiman, L. 1997. *Arcing the Edge*, Technical Report 486. Statistics Department, University of California, Berkeley CA. 94720.
- Breiman, L. 2001. Random forests. *Machine Learning*, 45, 5-32.
- Brett, J., Groves, T. 1979. Physiological energetics. *Fish Physiology* (8), 279-352.
- Castonguay, M., Cyr, D. 1998. Effects on temperature on spontaneous and thyroxine-stimulated locomotor activity of Atlantic cod. *Journal of Fish Biology*, 53 (2), 303-313.
- Farrell, A.P. 2011. *Encyclopedia of fish physiology: from genome to environment*. Vol. 2,3. Academic Press,
- Friedman, J. H. 1999. Greedy Function Approximation: A Gradient Boosting Machine. *The Annals of Statistics*, 29(5), 1189-1232.
- Fry, F. 1971. The effect of environmental factors on the physiology of fish. *Fish Physiology*, 6, 1-98.

- Performance Indicator on Flexible Pavement Deterioration Modeling. *Journal of Infrastructure Systems*, 27 (2), 04021005.
- Rastogi, S. 2007. *Essentials of animal physiology*. New Age International.
- Sarma, K., Pal, A., Ayyappan, S., Das, T., Manush, S., Debnath, D., Baruah, K. 2010. Acclimation of *Anabas testudineus* (Bloch) to three test temperatures influences thermal tolerance and oxygen consumption. *Fish Physiology and Biochemistry*, 36 (1), 85-90.
- Tuckey, N. P., Forgan, L. G., and Jerrett, A. R. 2012. Fillet colour correlates with biochemical status in Australasian snapper (*Pagrus auratus*) during storage in refrigerated seawater. *Aquaculture*, 356, 256-263.
- Welch, H. E. 1999. *Freshwater ecosystems: Revitalizing educational programs in limnology*. Wiley Online Library, 78(48), 552-557.
- Yoo, C., Im, J., Park, S., Quackenbush, L. J. 2018. Estimation of daily maximum and minimum air temperatures in urban landscapes using MODIS time series satellite data, *Journal of photogrammetry and remote sensing*, 137, 149-162.
- Zarafshani, K., Amirian, S. 2018. Determining Vulnerability of fish farmers towards Climate Change A case of Qasr e-shirin Township. *Rural Development Strategies*, 5(1), 33-50.
- conference on climate change and its impact on agriculture and Environment, Urmia. (In Farsi)
- Nash, J. E., Sutcliffe, J. V. 1970. River flow forecasting through conceptual models. part I-A discussion of principles. *Journal of hydrology*, 10(3), 282-290.
- Nordell, B. 2003. Thermal pollution causes global warming. *Global and planetary change*, 38 (3), 305-312.
- Pakdaman, M., Babaeian, I., Bouwer, L. M. 2022. Improved Monthly and Seasonal Multi-Model Ensemble Precipitation Forecasts in Southwest Asia Using Machine Learning Algorithms. *Water*, 14(17), 26-32.
- Pakdaman, M., Babaeian, I., Javanshiri, Z., & Falamarzi, Y. 2022. European multi model ensemble (EMME): A new approach for monthly forecast of precipitation. *Water Resources Management*, 36(2), 611-623.
- Pakdaman, M., Naghab, S. S., Khazanedari, L., Malbousi, S., Falamarzi, Y. 2020. Lightning prediction using an ensemble learning approach for northeast of Iran. *Journal of Atmospheric and Solar-Terrestrial Physics*, 209, 105417.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... and Duchesnay, E. (2011). *Scikit-learn: Machine learning in Python*. *The Journal of machine Learning research*, 12, 2825-2830.
- Piryonesi, S. Madeh; El-Diraby, Tamer E. 2021. Using Machine Learning to Examine Impact of Type of



## Prediction of maximum and minimum temperature of warm-water fish breeding pool using machine learning methods

E. Asadi Oskouei<sup>1</sup>, B. Dehghan Jirdehi<sup>2</sup>, M. T. Sadidi Shal<sup>3</sup>, M. Pakdaman<sup>1\*</sup>, Farahnaz Kianersi<sup>4</sup>

Received: 09/08/2023

Accepted: 07/01/2024

### Abstract

Fish are cold blooded animals and their metabolism, growth and feeding are strongly dependent on water temperature. Temperature changes in fish breeding pools cause stress and disease outbreaks occur especially above the tolerance thresholds. The aim of this study is predicting pool water temperature from observed air temperature using several machine learning approaches, namely artificial neural network, gradient boosting and random forest in Gilan province. Maximum and minimum air temperature data of Rasht Agrometeorological station for the period of June 2016 to November 2018 were collected and used for prediction of corresponding data of fish breeding pond. The obtained results showed that for prediction of the minimum temperature, the neural network model (with a root mean square of 1.93 and a correlation of 0.92) and for the pool water maximum temperature, the random forest model (with a root mean square of 1.61 and a correlation of 0.95) did a better job comparing to other two approaches. These selected models can be applied for prediction of water temperature using air Tmax and Tmin for improved management options under changing conditions.

**Keywords:** Artificial Neural Network, Boosting, Gradient, Machine Learning, Prediction, Random Forest, Warm-Water Fish



<sup>1</sup> Research Institute of Meteorological and Atmospheric Science (RIMAS), Climate Research Institute (CRI), Mashhad, Iran

(\*Corresponding Author Email Address: [pakdaman.m@gmail.com](mailto:pakdaman.m@gmail.com))

<sup>2</sup> Expert of Gilan Agricultural Meteorology Research Center

<sup>3</sup> Agricultural meteorological Research center of Guilan

<sup>4</sup> Aquaculture Research Center -South of Iran, Iranian Fisheries Science Research Institute (IFSRI)

نحوه ارجاع مقاله:

اسعدی اسکویی، ا.، دهقان جیردهی، ب.، سدیدی شال، م. ت.، پاکدامن، م.، کیان ارثی، ف. ۱۴۰۳. مدلسازی دمای بیشینه و کمینه استخر پرورش ماهیان گرمابی با استفاده از روش‌های یادگیری ماشین. نشریه هواشناسی کشاورزی، ۱۲(۱): ۶۴-۷۳. DOI: 10.22125/agmj.2024.410815.1157

Asadi Oskouei, E., Dehghan Jirdehi, B., Sadidi Shal, M. T., Pakdaman, M., Kianersi, F. 2024. Prediction of maximum and minimum temperature of warm-water fish breeding pool using machine learning methods. Journal of Agricultural Meteorology, 12(1): 64-73. DOI: 10.22125/agmj.2024.410815.1157