



# پیش بینی روند تغییرات صید ماهی تون زرد باله (*Thunnus albacares* Bonnaterre, 1788) در آب‌های جنوبی کشور براساس مدل‌های آریما (ARIMA) و شبکه عصبی (NN)

سید احمدرضا هاشمی<sup>۱\*</sup>، مسطوره دوستدار<sup>۲</sup>

۱. مرکز تحقیقات شیلاتی آب‌های دور، موسسه تحقیقات علوم شیلاتی کشور، سازمان تحقیقات، آموزش و ترویج کشاورزی، چابهار، ایران

۲. موسسه تحقیقات علوم شیلاتی کشور، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران.

تاریخ پذیرش: ۱۴۰۲/۰۶/۲۵

تاریخ دریافت: ۱۴۰۲/۰۳/۱۴

## چکیده

هدف از این مطالعه، توسعه مدل‌های مختلف پیش‌بینی آریما بوده و تلاش شده میزان صید ماهی تون باله زرد (گیدر) در آب‌های جنوبی کشور با حداقل خطاهای احتمالی را پیش‌بینی نماید. میانگین صید ( $Y_i \pm S.D$ ) و لگاریتم صید ( $\text{Log} Y_i \pm S.D$ ) برای سال‌های ۱۳۷۶ تا ۱۴۰۰ به ترتیب  $35378 \pm 13744$  تن (۹۵٪ حدود اطمینان ۴۹۱۲۹-۲۱۶۳۴ تن) و  $4/51 \pm 0/18$  تن (۹۵٪ حدود اطمینان ۴/۶۹-۴/۳۳ تن) بود. براساس آزمون من‌کندال، میانگین صید به صورت معنی‌داری طی دوره یاد شده (بیش از دو دهه گذشته) افزایش یافته است ( $P < 0/05$ ,  $Z = 3/80$ ). مدل‌ها پیش‌بینی ترکیبی مختلف آریما (ARIMA, (p, d, q)) براساس شاخص AIC امتحان شد و آریما مدل (۰ و ۰ و ۱) بهترین تناسب را با روند تغییرات ماهی تون زرد باله یا گیدر در آب‌های جنوب کشور داشت ( $AIC = -24$ ). نتایج و خطای مدل‌های شبکه عصبی (NN) نشان می‌دهد که شبکه‌های عصبی پیش‌خور (FFNN) نسبت به سایر مدل‌ها عملکرد بهتری داشته و مقادیر صید ماهی گیدر را با خطای کمتری شبیه‌سازی و پیش‌بینی می‌کند ( $0/02$  MAE= و  $0/03$  RMSE). همچنین با توجه به نتایج مدل‌های سری زمانی آریما و شبکه عصبی می‌توان نتیجه گرفت که شبکه‌های عصبی پیش‌خور با دقت بالاتری نسبت به مدل‌های سری زمانی میزان صید ماهی گیدر را شبیه‌سازی می‌کنند و بازگو کننده آینده صید ماهی گیدر باشند. به نظر می‌رسد پیش‌بینی روند صید آریما می‌تواند ابزار مهم مدیران و برنامه‌ریزان شیلاتی برای مدیریت بهتر و پایدار در ذخایر آریما بوده و بایستی بیشتر به آن توجه داشت.

واژگان کلیدی: ماهی گیدر، دریای عمان، مدل آریما، مدل شبکه عصبی



# **Prediction of yellowfin tuna (*Thunnus albacares* Bonnaterre, 1788) catch trend in the southern waters of the country based on ARIMA and neural network (NN) models**

**Seyed Ahmad Reza Hashemi<sup>1\*</sup>, Mastoureh Doustdar<sup>2</sup>**

1. *Offshore Fisheries Research Center, Iranian Fisheries Science Research Institute, Agricultural Research, Education and Extension Organization, Chabahar, Iran*

2. *Iranian Fisheries Science Research Institute, Agricultural Research, Education and Extension Organization, Tehran, Iran*

**Received: 04-Jun-2023**

**Accepted: 16-Sep-2023**

## **Abstract**

The aim of this study is to develop different models of aquatic forecasting and try to predict yellowfin tuna catch in the southern waters of the country with minimum possible errors. The average catch ( $Y_i \pm S. D$ ) and logarithm of catch ( $\text{Log}Y_i \pm S. D$ ) for the years 1997 to 2021 were  $35,378 \pm 13,744$  tons (95% confidence interval 21,634 - 49,129 tons) and  $4.51 \pm 0.18$  tons (95% CI The confidence interval was 4.33-4.69 tons), respectively. According to the Mann-Kendall test, the average catch has increased significantly during the mentioned period (over the last two decades) ( $Z = 3.80, P < 0.05$ ). Different ARIMA combined prediction models (ARIMA, (p, d, q)) were tested based on the AIC index, and the ARIMA model (1, 0, 0) had the best fit with the change trend of yellowfin tuna in the southern waters of the country (AIC = -24). The predict of yellowfin tuna catch results in the neural network (NN) models was show that feed forward neural networks (FFNN) have better performance than other models and with less error (MAE=0.02 and RMSE=0.03). Also, according to the results of ARIMA time series and neural network models, it can be concluded that feed forward neural networks simulate catch this species fish with higher accuracy than time series models. It seems, forecasting the trend of aquatic catch can be an important tool for fisheries managers and planners for better and sustainable management of aquatic resources and should be given more attention.

**Key words:** Yellowfin tuna, Oman Sea, ARIMA models, Neural Network (NN)

## ۱. مقدمه

نیاز بشر به تأمین غذا و تمایل به افزایش مصرف محصولات آبی موجب افزایش فعالیت‌های صید و صیادی و تولیدات آبی‌پروری شده است و این روند رو به رشد به دلیل افزایش جمعیت جهان، همچنان ادامه خواهد داشت. در سال ۱۹۸۹، پس از چند دهه رشد مستمر، صید جهانی به سقف تولید خود رسید و در سال بعد روند نزولی در پیش گرفت. این افزایش صید تا مرز حدود ۱۰۰ میلیون تن نیز پیش رفته و در سال‌های اخیر متوسط تولید جهانی رقمی کمتر بوده است (FAO, 2018). میزان صید جهانی در سال ۲۰۲۰ حدود ۹۰ میلیون تن بوده که ۸۷ درصد آن در آب‌های دریایی (۷۹ میلیون تن) و ۱۳ درصد در آب‌های داخلی (۱۱ میلیون تن) قرار داشته است (FAO, 2022).

در سال‌های اخیر نشانه‌های بارزی از برداشت بی‌رویه و غیرمنطقی از ذخایر عمده ماهیان و سایر آبزیان، شامل خسارت‌های جدی به اکوسیستم‌های آبی و زیان‌های اقتصادی موازی با فعالیت‌های شیلاتی به چشم می‌خورد. بیش از ۷۵ درصد منابع ماهیگیری اصلی جهان یا در بالاترین سطوح قابل برداشت خود و یا در حال کاهش (نیازمند اقدامات مدیریتی فوری) بوده و حدود ۲۵ درصد مابقی هنوز در حال توسعه هستند (Pauly and Zeller, 2015). بیش از ۳۴ درصد ذخایر جهان دچار صید بی‌رویه بوده (حدود یک سوم از ذخایر دریاها در وضعیت ناپایدار زیستی) و براساس اهداف ۱۷ گانه توسعه پایدار سازمان ملل و طبق هدف چهاردهم آن (استفاده پایدار از منابع دریایی و اقیانوسی یا اقتصاد آبی) بایستی تا سال ۲۰۳۰ به نقطه بدون صید بی‌رویه در دریاها رسیده باشیم (Sturesson et al., 2018).

به نظر می‌رسد وضعیت ماهیگیری در خلیج فارس و دریای عمان جدای از وضعیت جهانی نبوده و منابع ماهیگیری در حال رشد، بهره‌برداری شدید و بیش از حد بهره‌برداری شده به ترتیب برای مناطق خلیج فارس ۳، ۵۳ و ۴۱ درصد و برای دریای عمان ۵۳، ۴۲ و ۳ درصد گزارش شده است (Pauly and Zeller, 2015).

تون ماهی زرد باله، گونه‌ای اپی‌پلاژیک مهاجر مناطق گرمسیر و نیمه‌گرمسیر که در تمامی اقیانوس‌ها (آرام، اطلس و هند) مشاهده می‌شود. در اعماق تا ۲۵۰ متر حضور داشته (معمولاً تا اعماق ۱۰۰ متر) و بالغین به اعماق بالاتر و نواحی دورتر از ساحل تمایل دارند (برعکس نابالغین). حرارت ترجیحی آن‌ها بین ۳۱-۱۵ درجه سانتی‌گراد بوده و حداکثر طول ۲۳۹ سانتی‌متر (معمولاً حدود ۱۵۰ سانتی‌متر)، حداکثر وزن ۲۰۰ کیلوگرم و حداکثر سن ۹ سال برای این گونه گزارش شده است (Collette and Nauen, 1983; Froese and Pauly, 2018).

خلیج فارس و دریای عمان با شرایط اکولوژیک منحصر به فرد میزبان تنوع گونه‌ای وسیعی از آبزیان است که شرایط تهیه معیشت، اشتغال و فعالیت‌های اقتصادی وسیعی را برای ساحل‌نشینان فراهم کرده است. آنچه مهم است وجود این دو اکوسیستم بزرگ با شرایط اکولوژیک ویژه از جمله تنوع زیستی بالا در طول سواحل جنوبی ایران برکات عظیمی را برای ساحل‌نشینان و البته کل جمعیت ایران فراهم کرده است (Taghavimotlagh, 2010, Taghavimotlagh, 2018).

ماهگیری به عنوان یکی از زیر بخش‌های کشاورزی در ایجاد اشتغال، معیشت و فعالیت‌های اقتصادی، نقش مهمی را در توسعه اقتصادی-اجتماعی کشورهای زیادی به خصوص کشورهای دارای سواحل آبی دریایی ایفا کرده است. در ایران با بیش از ۱۲۰ هزار نفر صیاد که شغل اصلی آن‌ها صیادی است؛ ماهیگیری نقش مهمی را در ایجاد اشتغال در مناطق ساحلی و همچنین زمینه‌های ایجاد فعالیت‌های اقتصادی گسترده‌ای را برای عملیات پس از صید فراهم کرده است. حفظ و پایداری اشتغال ایجاد شده در این بخش و پایداری اقتصادی آن‌ها ضرورتی اجتناب‌ناپذیر است، که تنها با مدیریت علمی بر مبنای جمع‌آوری آمار و اطلاعات، تجزیه و تحلیل آن‌ها و ارائه راه‌کارهای علمی برای مدیریت پایدار این منابع و اجرای دقیق آن‌ها امکان‌پذیر است (Taghavimotlagh, 2010, Taghavimotlagh, 2018).

امروزه اهمیت پیش‌بینی و مدل‌های مختلف آن در علوم مختلف بر کسی پوشیده نیست و توسط روش‌های مختلفی از جمله مدل‌های آریمای و شبکه عصبی انجام می‌گردد. مدل‌های آریمای یا مدل‌های یکپارچه خود همبستگی و میانگین متحرک<sup>۱</sup> (ARIMA) عملکرد خوبی را در رابطه با تغییرات و پیش‌بینی توضیح می‌دهند (Tsitsika et al., 2007). اساس این مدل‌ها بر پایه زنجیره مارکوف در زنجیره سری زمانی بنا شده است و زمانی یک سری زمانی از زنجیره مارکوف تبعیت می‌کند که هر داده ثبت شده سری زمانی، زمان بعد و یا زمان قبل از خود مرتبط باشد. این مدل‌ها بر روی مقادیر گذشته خود رگرسیون‌گیری را اعمال کرده و مقادیر آینده را پیش‌بینی می‌نمایند (Azadtalaitepe et al., 2015).

شبکه‌های عصبی را میتوان با اغماض زیاد، مدل‌های الکترونیکی از ساختار عصبی مغز انسان (نورون‌های عصبی که شامل سه قسمت بدنه، اکسون و دندریت) نامید و مکانیسم فراگیری و آموزش آن‌ها مانند مغز انسان بر تجربه استوار است. شبکه‌های عصبی شبیه‌سازی شده، فقط قادرند تا بخش کوچکی از خصوصیات و ویژگی‌های شبکه‌های عصبی زیستی را شبیه‌سازی کنند (Tiumentsev and Egorchev, 2019). ساختار شبکه عصبی شامل تعداد زیادی پرسپترون (ساده‌ترین و قدیمی‌ترین مدل از نورون محسوب شده و تعدادی ورودی را دریافت، آن‌ها را تجمیع و تابع فعال‌سازی را روی آن‌ها اعمال می‌کند) با تابع عملکردی بوده و هر پرسپترون به واسطه ضریب وزنی خود، خروجی تمام پرسپترون‌های قبلی را تجمیع کرده و از طریق تابع عملکردی به لایه بعدی انتقال می‌دهد (Skaar, 2020).

مطالعات مختلفی بر روی ویژگی‌های زیستی گونه تون ماهی زردباله در نقاط مختلف جهان صورت گرفته است (John and Reddy, 1989; Chantawong, 1998; Kaymaram et al., 2000, 2014; Tantivala, 2000; Somvanshi et al., 2003; Prathibha et al., 2012; Ramalingam et al., 2012; Nurdin et al., 2016;

## ۲. مواد و روش

داده‌های صید تخلیه شده به سواحل در استان‌های جنوبی کشور برای بیش از دو دهه گذشته (براساس تن) از سازمان شیلات ایران (سال ۱۳۷۶ تا ۱۴۰۰) جمع‌آوری شد (Iran Fisheries Organization (IFO), 2022) (شکل ۱). داده‌های صید ماهی گیدر از سال ۱۳۷۶ تا ۱۳۹۷ به‌عنوان الگوی یادگیری مدل و داده صید از سال ۱۳۹۸ الی ۱۴۰۰ به‌عنوان داده پیشگویی مدل‌های پیش‌بینی استفاده شد و سپس خطای مدل محاسبه گردید.

**روش‌های پیش‌بینی آریمای:** با توجه به فرضیه‌های اساسی در مدل‌سازی سری‌های زمانی یعنی نرمال بودن و ایستایی، قبل از مدل‌سازی باید از نرمال و ایستا بودن سری داده‌ها اطمینان حاصل کرد. مدل‌های یکپارچه خود همبستگی و میانگین متحرک عملکرد خوبی را در رابطه با تغییرات و پیش‌بینی آن‌ها نشان می‌دهند (Tsitsika et al., 2007). تابع خود همبستگی<sup>۲</sup> (ACF) و عملکرد تابع خود

<sup>۱</sup>Autoregressive integrated moving average (ARIMA)

<sup>۲</sup>Autocorrelation functions (ACF)

مورد استفاده در خلاصه‌سازی مدل ARIMA عبارتند از پارامتر خودهمبستگی (p)، پارامتر تفاوت (d) و پارامتر میانگین متحرک (q) می‌باشد (Tsitsika et al., 2007).

همبستگی جزئی<sup>۱</sup> (PACF) تخمین زده شد که منجر به شناسایی و ساخت مدل‌های ARIMA شد. ARIMA براساس داده‌ها اجرا شد و بهترین مدل با استفاده از آزمون ضریب آکائیکه انتخاب شد (Lawer, 2016). سه پارامتر



شکل ۱. موقعیت مناطق جمع‌آوری داده‌های صید تخلیه شده به ساحل ماهی‌گیر در آب‌های جنوبی کشور

پایه تابع شعاعی<sup>۶</sup> بوده و شبکه عصبی پایه تابع شعاعی شبکه ساده است و شباهت بین داده‌ها را براساس فاصله می‌سنجد) و شبکه پیش‌خور<sup>۷</sup> ساده یا شبکه کنترل (شبکه‌های عصبی ساده با یک لایه پنهان و الگوریتم فعال‌سازی از لایه ورودی به خروجی، بدون داشتن ارتباط بین نرون‌ها در یک لایه پنهان، بدون داشتن حلقه رو به عقب و الگوی یادگیری پیش انتشار خطا<sup>۸</sup>) است (Chen et al., 2020; Martinez et al., 2022). تفاوت هر کدام از این مدل‌های شبکه عصبی نحوه یادگیری، الگوریتم پیش‌بینی و محاسبه خروجی آن‌ها می‌باشد. در این مدل، مؤلفه‌های ورودی به‌عنوان فاکتور و لایه خروجی به‌عنوان مؤلف وابسته مشاهده شد. در پیش‌بینی سری‌های زمانی،

روش‌های پیش‌بینی شبکه عصبی<sup>۲</sup>: ساختار شبکه عصبی مصنوعی تعیین می‌کند که شبکه از چند نرون یا عنصر پردازشگر تشکیل شده و چگونه در ساختار شبکه قرار گرفته و به یکدیگر متصل می‌شوند (Tiumentsev and Egorchev, 2019). انواع شبکه عصبی که در این تحقیق استفاده شده است شامل شبکه عصبی مدل یادگیری عمیق<sup>۳</sup> (یادگیری شبیه به فرآیندی یادگیری انسان و شبکه عصبی با لایه‌های پنهان زیاد همراه با الگوی یادگیری طبقه‌بندی) (Pawlus and Devine, 2020)، پرسپترون چند لایه<sup>۴</sup> (شبکه پیچیده‌ای بوده و هر نورون در هر لایه، به تمامی نورون‌های لایه قبل متصل است)، رگرسیون تعمیم یافته<sup>۵</sup> (شکل تغییر یافته شبکه عصبی

<sup>1</sup> (PACF) Partial autocorrelation functions

<sup>2</sup> Neural Network(NN)

<sup>3</sup> Extreme Learning Machine (ELM)

<sup>4</sup> Multilayer Perceptron (MLP)

<sup>5</sup> Generalized regression neural networks(GRNN)

<sup>6</sup> Radial Basis Function(RBF)

<sup>7</sup> Feed-forward neural network (nnfor)

<sup>8</sup> Back Propagation (BP)

ترسیم و آنالیز نمودارهای صید (2023.03.1-446) Rstudio و R (4.3.0) همچنین پکیج‌های (بسته‌های) ggplot2، Car، forecast و Cardata برای ترسیم مدل‌های آریما و شبکه‌های عصبی استفاده شد (R Development Core Team, 2022).

### ۳. نتایج

میانگین صید ( $Y_i \pm S.D$ ) و لگاریتم صید ( $\text{Log}Y_i \pm S.D$ ) برای سال‌های ۱۳۷۶ تا ۱۴۰۰ به ترتیب  $35378 \pm 13744$  تن (۹۵٪ حدود اطمینان  $49129 - 41634$  تن) و  $4/51 \pm 0/18$  تن (۹۵٪ حدود اطمینان  $4/69 - 4/33$  تن) بود. براساس آزمون من‌کندال که عموماً برای داده‌های سری زمانی (نرمال نشده) استفاده شده است، میانگین صید به صورت معنی‌داری طی دوره یاد شده (بیش از دو دهه گذشته) افزایش یافته است ( $Z = 3/80$ ،  $P < 0/05$ ) (شکل ۲). با توجه به اینکه داده‌های صید نرمال نبوده، از لگاریتم برای نرمال کردن داده‌ها و کاهش خطای مدل استفاده شد و نمودار توزیع نرمال لگاریتم صید (خروجی شاپیرو-ویلک) در شکل ۲ ارائه شده است افزایش یافته است ( $P < 0/05$ ،  $W = 0/92$ ).

با توجه به نرمال نبودن داده‌های صید این گونه، در محاسبات از لگاریتم صید استفاده شد و مقدار تابع خود همبستگی (ACF) و عملکرد تابع خود همبستگی جزئی (PACF) آورده شده است. مدل‌های مختلف پیش‌بینی ترکیبی آریما ((ARIMA, (p, d, q) که ترکیبی از خود همبستگی و میانگین متحرک است، براساس شاخص AIC با کمترین مقادیر و خطا امتحان شد و آریما مدل (۰ و ۰ و ۱) بهترین تناسب را با روند تغییرات ماهی گیدر در آب‌های جنوب کشور داشت (جدول ۱ و شکل ۳).

ورودی‌های شبکه عصبی مصنوعی، مشاهدات با وقفه سری زمانی است و خروجی شبکه، مقادیر آتی آن‌ها می‌باشد. در واقع اگر مشاهدات گذشته به صورت سری باشد، آنگاه شبکه عصبی مصنوعی تابع زیر را تقریب و طرح‌ریزی می‌کند که در آن  $y$ : مشاهده زمان  $t$ ام است و  $x_i$ : ورودی مدل،  $y_i$ : خروجی مدل و  $f(n)$ : تابع عملکردی و فعال است (Benzer and Benzer, 2019).

$$y_{t+1} = f(y_t, y_{t-1}, \dots, y_{t-n})$$

$$y_i = f(n) = f\left(\sum_{i=1}^p wix_i + b\right)$$

**بهترین پیش‌بینی مدل:** برای شناسایی بهترین مدل مقادیر میانگین خطا مطلق<sup>۱</sup> (MAE) و جذرمیانگین انحراف مربع<sup>۲</sup> (RMSD) مورد استفاده قرار می‌گیرند (Karmaker et al., 2017).

$$MAE = 1/n \sum \frac{|Dt - Ft|}{Dt}$$

$$RMSE = \sqrt{\sum (Dt - Ft)^2 / n}$$

$Dt$ : عدد واقعی برای دوره زمانی  $t$ ،  $Ft$ : عدد پیش‌بینی برای مدت زمان  $t$ ،  $n$ : تعداد تعداد دوره‌های زمانی مشخص شده، و  $e_t$ : خطای پیش‌بینی مساوی با  $(Dt - Ft)$  است. معیار اطلاعات آکائیکه<sup>۳</sup> به شرح زیر محاسبه شد ( $m$ : تعداد پارامترهای تخمینی است):

$$AIC = -2 \ln(\text{maximum likelihood}) + 2m$$

برای بررسی شرایط توزیع داده‌ها از آزمون‌های شاپیرو-ویلک<sup>۴</sup> و کولموگروف-اسمیرنوف<sup>۵</sup> و نیز برای بررسی داده‌های سری زمانی (نرمال نشده) از آزمون من‌کندال<sup>۶</sup> استفاده گردید. در تجزیه و تحلیل داده‌های حاصل از برنامه اکسل نسخه ۲۰۱۶، نرم‌افزارهای مینی‌تب نسخه ۱۶ برای

<sup>1</sup> Mean absolute Error (MAE)

<sup>2</sup> Root Mean square deviation (RMSD)

<sup>3</sup> Akaike Information Criterion (AIC)



<sup>4</sup> Shapiro- Wilk

<sup>5</sup> Smirnov-Kolmogorov-

<sup>6</sup> Mann-Kendall

لایه ( $MAE = 0/08$  و  $RMSE = 0/12$ ) هم بیانگر روند کاهشی این گونه هستند ولی میزان خطای آن‌ها نسبت به شبکه عصبی پیش‌خور بالاتر است. شبکه عصبی رگرسیون تعمیم‌یافته ( $MAE = 0/09$  و  $RMSE = 0/12$ ) هم بیانگر روند افزایشی صید ماهی گیدر در آب‌های جنوبی بوده ولی میزان خطای آن‌ها نسبت به شبکه عصبی پیش‌خور بالاتر است.


خروجی شبکه‌های عصبی مختلف و خطای مدل‌ها در شکل ۴ و جدول ۲ نشان داده شده است. نتایج نشان داد که شبکه عصبی پیش‌خور دارای خطای کمتری نسبت به بقیه مدل‌های شبکه عصبی بوده ( $MAE = 0/02$  و  $RMSE = 0/03$ ) و بیانگر روند کاهشی صید این گونه در آب‌های جنوبی کشور است. شبکه‌های عصبی یادگیری عمیق ( $MAE=0/18$  و  $RMSE=0/18$ )، پرسپترون چند



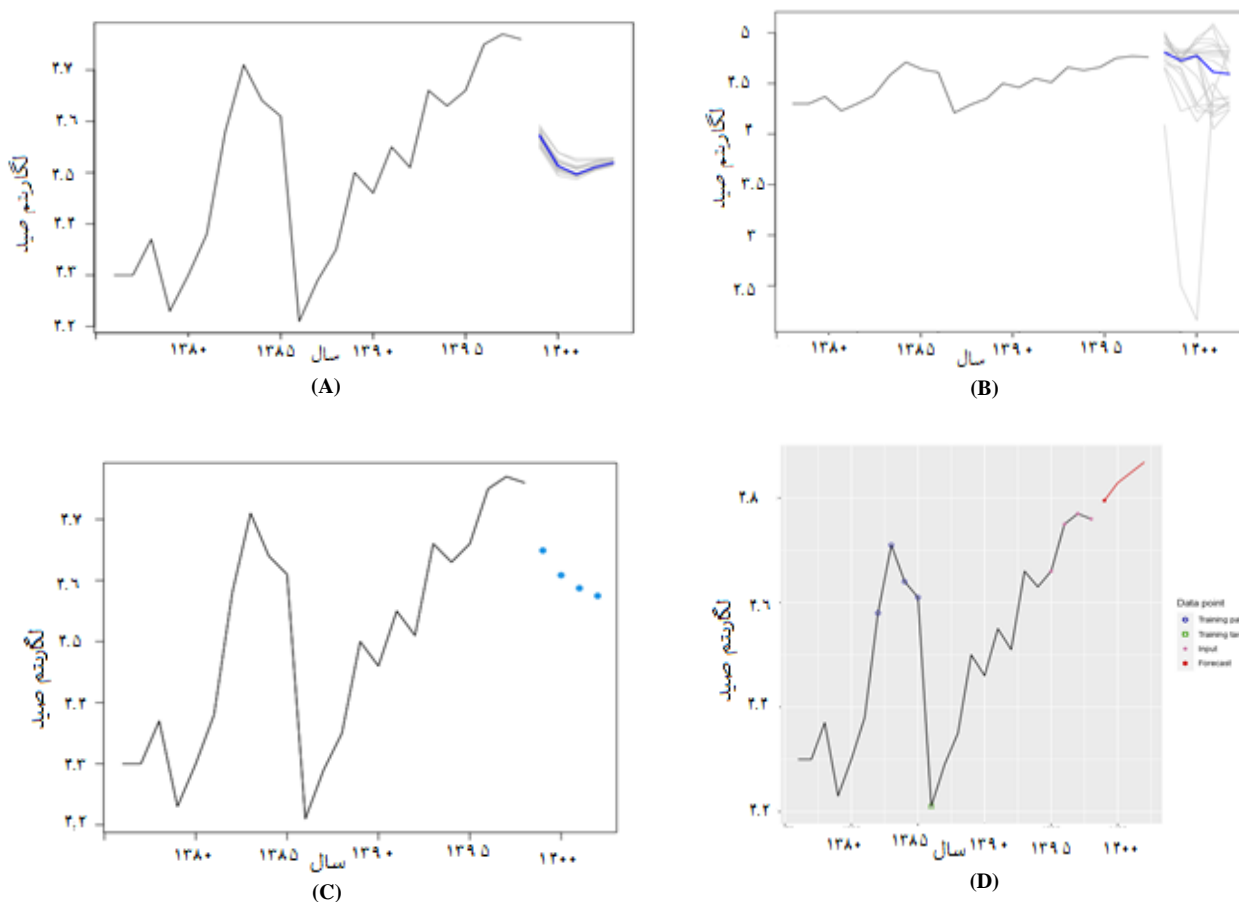
شکل ۲- روند تغییرات لگاریتم صید (Log catch) سالانه (A) و توزیع نرمال لگاریتم صید (B) ماهی گیدر در آب‌های جنوبی کشور

جدول ۱. مدل‌های مختلف پیش‌بینی ترکیبی اریما داده‌های صید تخلیه شده به ساحل ماهی گیدر در آب‌های جنوبی کشور

| AIC | P-Value    | (Ljung-Box) Chi-Square | B (coefficient)± Standard error |                 | Method          |
|-----|------------|------------------------|---------------------------------|-----------------|-----------------|
|     |            |                        | MA1                             | AR1             |                 |
| -۲۴ | $P > 0/05$ | ۷/۴                    | -                               | $0/75 \pm 0/14$ | ARIMA (1, 0, 0) |
| -۱۸ | $P > 0/05$ | ۱۰/۳                   | $0/52 \pm 0/13$                 | -               | ARIMA (0, 0, 1) |
| -۲۳ | $P > 0/05$ | ۱۰/۳                   | $0/12 \pm 0/08$                 | $0/70 \pm 0/1$  | ARIMA (1, 0, 1) |
| -۲۳ | $P > 0/05$ | ۱۰/۱                   | $-0/01 \pm 0/02$                | -               | ARIMA (0, 1, 1) |
| -۲۳ | $P > 0/05$ | ۱۰/۱                   | $-0/6 \pm 0/3$                  | $-0/85 \pm 0/2$ | ARIMA (1, 1, 1) |



شکل ۳. بهترین مدل پیش‌بینی ترکیبی (آریمما) داده‌های صید تخلیه شده به ساحل ماهی‌گیر در آب‌های جنوبی کشور



شکل ۴. مدل‌های پیش‌بینی شبکه عصبی یادگیری عمیق (A)، پرسپترون چند لایه (B)، شبکه پیش‌خور ساده (C) و رگرسیون تعمیم‌یافته (D) داده‌های صید تخلیه شده به ساحل ماهی‌گیر در آب‌های جنوبی کشور



جدول ۲. مقایسه خطای مدل‌های مختلف پیش‌بینی ترکیبی مدل آریمای و شبکه عصبی داده‌های صید تخلیه شده به ساحل ماهی‌گیر در آب‌های جنوبی کشور

| RMSE | MAE  | مقادیر واقعی لگاریتم صید |      |      | پیش‌بینی لگاریتم صید |      |      |      | Method                      |
|------|------|--------------------------|------|------|----------------------|------|------|------|-----------------------------|
|      |      | ۱۴۰۰                     | ۱۳۹۹ | ۱۳۹۸ | ۱۴۰۱                 | ۱۴۰۰ | ۱۳۹۹ | ۱۳۹۸ |                             |
| ۰/۱۸ | ۰/۱۸ | ۴/۶۵                     | ۴/۶۸ | ۴/۷۶ | ۴/۵۰                 | ۴/۴۹ | ۴/۵۰ | ۴/۵۵ | ELM neural network          |
| ۰/۱۲ | ۰/۰۸ | ۴/۶۵                     | ۴/۶۸ | ۴/۷۶ | ۴/۷۰                 | ۴/۶۹ | ۴/۸۹ | ۴/۷۶ | MLP neural network          |
| ۰/۰۳ | ۰/۰۲ | ۴/۶۵                     | ۴/۶۸ | ۴/۷۶ | ۴/۶۲                 | ۴/۶۴ | ۴/۷۶ | ۴/۷۱ | feed-forward neural network |
| ۰/۱۲ | ۰/۰۹ | ۴/۶۵                     | ۴/۶۸ | ۴/۷۶ | ۴/۸۵                 | ۴/۸۶ | ۴/۷۹ | ۴/۷۶ | tsfgmn neural networks      |
| ۰/۰۶ | ۰/۰۴ | ۴/۶۵                     | ۴/۶۸ | ۴/۷۶ | ۴/۷۶                 | ۴/۷۶ | ۴/۷۶ | ۴/۷۶ | ARIMA (1, 0, 0)             |

است (Iran Fisheries Organization (IFO), 2022). با در نظر گرفتن روند صید و واکنش‌های احتمالی جمعیت به این افزایش، نیاز به اطلاعات به‌روز شده در خصوص ذخایر این گونه و نیز پیش‌بینی روند آن بیش از پیش احساس می‌گردد.

براساس نتایج به‌دست آمده، مدل ARIMA (1, 0, 0) بهترین مدل در مدل‌های ARIMA است و مطالعات زیادی در زمینه‌های مختلفی، توانایی پیش‌بینی مناسب این گونه مدل‌ها را بیان داشته‌اند (Tsitsika et al., 2007; Hashemi and Mirzaei, 2019). تجزیه و تحلیل سری زمانی از داده‌های ماهیگیری ابزار مهمی برای مدیریت و تصمیم‌گیری مدیریتی بوده است، زیرا روند و الگوهای کلی و فصلی را آشکار می‌سازد (Koutroumanidis et al., 2006). مدل‌های یکپارچه خود همبستگی و میانگین متحرک (ARIMA) در توصیف و پیش‌بینی دینامیک ماهیگیری گونه‌ها در گذشته موفق بوده است (Hashemi and Mirzaei, 2019; Koutroumanidis et al., 2006). مدل‌های ARIMA تنها از اطلاعات موجود در سری خود استفاده می‌کنند، بنابراین مدل‌های آریمای به‌عنوان توابع خطی از سری مقادیر گذشته و یا دوره‌های تصادفی قبلی (یا خطاها) ساخته می‌شوند (Box and Jenkins, 1976). در این‌گونه مطالعات، پیش‌بینی روش‌های خطی قادر به پیش‌بینی دقیق سری‌های زمانی روند تغییرات ماهیگیری نیستند، زیرا سری‌هایی اغلب ثبات ندارند (Shabri and

آریمای مدل (۰ و ۰ و ۱) که دارای خطای کمتری نسبت به بقیه مدل‌های آریمای بوده (AIC = -۲۴) و روند تغییرات صید ماهی‌گیر را کم و به نسبت ثابتی پیش‌بینی نموده است ولی دارای خطای بالاتری نسبت به شبکه عصبی پیش‌خور است (MAE = ۰/۰۴ و RMSE = ۰/۰۶). همچنین مقادیر پیش‌بینی لگاریتم صید برای سال ۱۴۰۱ نشان داده شده است (در جدول ۲ و شکل ۴). براساس نتایج، مدل شبکه عصبی رگرسیون تعمیم‌یافته پیش‌بینی افزایشی صید، مدل آریمای تغییرات کم و نسبتاً ثابت و مدل‌های شبکه عصبی پیش‌خور، یادگیری عمیق و پرسپترون چند لایه روند کاهشی از میزان صید ماهی‌گیر در آب‌های جنوبی کشور را پیش‌بینی می‌نمایند.

#### ۴. بحث و نتیجه‌گیری

تون ماهی زرد باله (گیردر) از جمله ماهیان سطح‌زی درشت و از با ارزش اقتصادی در جنوب کشور است که روند صید این گونه طی دو دهه گذشته روند افزایشی را نشان می‌دهد. در آب‌های جنوب کشور بیش از ۴۴ هزار تن ماهی از این گونه صید شده (سال ۱۴۰۰) که قسمت زیادی از صید تون ماهی زرد باله در آب‌های دور از ساحل است که در استان‌های جنوبی تخلیه شده (هرمزگان و سیستان و بلوچستان) و استان سیستان و بلوچستان در سال ۱۴۰۰ بیش از ۸۵ درصد صید این گونه را به‌خود اختصاص داده

شبکه‌های زیستی است (Azadtaitepe *et al.*, 2015). دلیل استفاده از شبکه‌های عصبی در شناخت الگو به‌خاطر توانایی آن‌ها در یادگیری و ذخیره دانش است. در حال حاضر شبکه‌های عصبی با توجه به توانایی بالای آن‌ها در پردازش اطلاعات و حل مسائل پیچیده، کاربرد فراوانی در شناخت الگو، خوشه‌بندی، مدل‌سازی، تخمین و شناسایی و پیش‌بینی سیستم‌ها دارند (Asgharieskouei, 2002).

Castellano-Mendez و همکاران (۲۰۰۴) بر این باورند که شبکه‌های عصبی مصنوعی توانایی بیشتری در پیش‌بینی‌های کوتاه‌مدت دارند چرا که نتایج مطالعه آن‌ها نشان داد که مدل سری زمانی در پیش‌بینی‌های ماهانه عملکرد بهتری دارند. مطالعات پیش‌بینی شبکه عصبی در حال حاضر جزء روش‌های پرطرفدار پیش‌بینی بوده و عمدتاً در دوره زمانی کوتاه پیش‌بینی صورت می‌گیرد زیرا با افزایش دوره زمانی میزان خطا و عدم قطعیت پیش‌بینی افزایش یافته و اعتمادپذیری آن را کاهش می‌دهد (Chen *et al.*, 2020). بنابراین انجام مطالعات بعدی در زمینه مقایسه کارایی شبکه‌های عصبی مصنوعی و سری زمانی در پیش‌بینی صید آبزیان در مقیاس‌های زمانی کوتاه پیشنهاد می‌گردد.

علی‌رغم عدم اطمینان و عدم قطعیت مربوط به داده‌های صید آبزیان گونه‌های مختلف، ما باید توجه بیشتری به تحلیل و بررسی این داده‌ها داشته باشیم و از آن‌ها در امر برنامه‌ریزی و مدیریت صیادی استفاده کنیم (Rosenberg *et al.*, 2005). مدیران شیلات و برنامه‌ریزان برای مدیریت بهتر و پایدار در دریای خلیج فارس و دریای عمان باید بر روندهای موجود تمرکز داشته باشند. تحقیقات بیشتری می‌تواند برای مقایسه قابلیت پیش‌بینی مدل با دیگر مدل‌های سری زمانی مانند SARIMA، PARIMA و غیره بررسی شود.

(Samsudin, 2015). معیار اطلاعات آکائیکه معیار و اطلاعات بیزین<sup>۱</sup> (BIC) از مهمترین شاخص‌های انتخاب مدل‌های پیش‌بینی می‌باشد و کمتر بودن این شاخص‌ها به معنی کمتر بودن خطای مدل بوده و در اکثر تحقیقات از برتری معیار اطلاعات بیزی جهت پیش‌بینی مدل صحبت شده است (Cook *et al.*, 2003; Panhwar *et al.*, 2010)، اگر چه در داده‌های کم و با نوسان (نویز) زیاد معیار اطلاعات آکائیکه، شاخص بهتر و مطمئن تری به نظر می‌رسد (Acquah, 2010).

این نتایج و خطای مدل‌ها نشان می‌دهد که شبکه‌های عصبی پیش‌خور ساده نسبت به سایر مدل‌ها عملکرد بهتری داشته و مقادیر صید ماهی‌گیر را با خطای کمتری شبیه‌سازی و پیش‌بینی می‌کند. همچنین با توجه نتایج و خطای مدل‌های سری زمانی آریمای و شبکه عصبی می‌توان نتیجه گرفت که شبکه‌های عصبی پیش‌خور با دقت بالاتری نسبت به مدل‌های سری زمانی میزان صید ماهی‌گیر را شبیه‌سازی می‌کنند، هرچند مدل‌های سری زمانی آریمای نیز دارای دقت قابل قبولی می‌باشند. برخی از مطالعات نشان می‌دهند که عملکرد مدل‌سازی سری زمانی و شبکه عصبی مصنوعی به حجم داده و مقیاس زمانی مورد مطالعه بستگی دارد و در حالت کلی به‌نظر می‌رسد عملکرد شبکه عصبی بهتر از مدل‌های آریمای باشد (Benzer and Benzer, 2019). شبکه‌های عصبی پیش‌خور از بهترین روش‌های مدل‌سازی شبکه عصبی بوده و در زمانی که حجم داده بالا باشد، بهتر از بقیه مدل‌های شبکه عصبی بوده و زمانی که حجم داده کم باشد، شبکه عصبی رگرسیون تعمیم‌یافته نسبت به بقیه روش‌ها خروجی بهتر با خطای کمتری خواهد داشت (Chen *et al.*, 2020). در حقیقت، هدف از ایجاد یک شبکه عصبی، بیش از آنکه شبیه‌سازی مغز انسان باشد، ایجاد مکانیسمی برای حل مسائل مهندسی با الهام از الگوی رفتاری

<sup>1</sup> Bayesian Information Criterion (BIC)

## ۵. منابع

## References

- Acquah, H.D., 2010. Comparison of Akaike information criterion (AIC) and Bayesian information criterion (BIC) in selection of an asymmetric price relationship. *Journal of Development and Agricultural Economics* 2(1), 001-006.
- Asgharieskoui, M., 2002. Application of neural network in time series forecasting. *Iranian Economic Research Quarterly* 12(1), 96-69. (In Persian)
- Azadtaitepe, N., Bahmanesh, J., Mantsari, M., Vardinjad, V., 2015. Comparison of time series and artificial neural network methods in forecasting reference evapotranspiration (case study: Urmia). *Irrigation Science and Engineering* 38(4), 85-76.
- Benzer, S., Benzer, R., 2019. Alternative growth models in fisheries: Artificial Neural Network. *Journal of Fisheries* 7(3), 719-725. DOI: 10.17017/j.fish.137.
- Box, G., Jenkins, G., 1976. *Time Series Analysis, Forecasting and Control*. Holden-Day, San Francisco, CA. 125 p.
- Castellano-Mendez, M., Gonzalez- Manteiga, W., Febrero- Bande, M., Prada-Sanchez, J. M., R. Lozano-Calderon., 2004. Modelling of monthly and daily behavior of the run off the Xallas River using Box-Jenkins and neural networks methods. *Journal of Hydrology* 296(1), 38-58. DOI: 10.1016/j.jhydrol.2004.03.011
- Chen, Y., Song, L., Liu, Y., Yang, L., Li, D., 2020. A Review of the Artificial Neural Network Models for Water Quality Prediction. *Applied Sciences* 10(5776), 2-49. DOI: 10.3390/app10175776.
- Cook, S., Holly, S., Turner, P., 2003. The Power of Tests for Non-linearity: the case of Granger-Lee Asymmetry. *Economics Letters* 62(2), 155-159.
- FAO., 2018. FAO Global Capture Production database updated to 2015 - Summary information.
- FAO., 2022. *The State of World Fisheries and Aquaculture 2022 - Meeting the sustainable development goals*. Rome. Licenses: CC BY-NC-SA 3.0 IGO. 227 p.
- Haruna, A., Mallawa, A., Musbir, M., Zainuddin, M., 2018. Population dynamic indicator of the Yellowfin tuna *Thunnus albacares* and its stock condition in the Banda Sea, Indonesia. *AACL Bioflux* 11(4), 1323-1333.
- Hashemi, S.A.R., Doustdar, M., Gholampour, A., Khanehzaei, M., 2020. Length-based fishery status of yellowfin tuna (*Thunnus albacares* Bonnatere, 1788) in the northern waters of the Oman Sea. *Iranian Journal of Fisheries Sciences* 19(6), 2790-2803. DOI: 10.22092/ijfs.2020.122747. (in Persian)
- Hashemi, S.A.R., Mirzaei, M., 2019. Prediction of catch changes of Largehead hairtail (*Trichiurus lepturus*) fish in the coastal waters of the south of the country (Persian Gulf and Oman Sea). *Journal of Aquatic Ecology* 9(2), 140-149. (In Persian)
- Iran Fisheries Organization(IFO), 2022. *Statistical Yearbook of Iran Fisheries Organization*. Iranian Fisheries Organization, Vice President of Planning and Management Development, Program and Budget Office. 65 p. (in Persian)
- John, M.E., Reddy, K.S.N., 1989. Some considerations on the population dynamics of yellowfin tuna, *Thunnus albacares* (Bonnatere) in Indian Seas. Studies on fish stock assessment in Indian waters. *Foreign Service Institute Special Publication* 2(1), 33-54.
- Karmaker, C.L., Halder, P.K., Sarker, E., 2017. A Study of Time Series Model for Predicting Jute Yarn Demand: Case Study. *Journal of Industrial Engineering* 2017(1), 1-8. DOI: 10.1155/2017/2061260.
- Kaschner, K., Kesner-Reyes, K., Garilao, C., Rius-Barile, J., Rees, T., Froese, R., 2016. AquaMaps: predicted range maps for aquatic species. World Wide Web electronic publication, www.aquamaps.org, Version 08/2016.

- Kaymaram, F., Emadi, H., Kiabi, B., 2000. 2nd IOTC proceedings, Victoria, 23-27 September, Seychelles, 283-285.
- Kaymaram, F., Hossini, A., Darvishi, M., 2014. Estimates of Length-Based Population Parameters of Yellowfin Tuna (*Thunnus albacares*) in the Oman Sea. *Turkish Journal of Fisheries and Aquatic Sciences* 14(1), 101-111. DOI: 10.4194/1303-2712-v14\_1\_12.
- Koutroumanidis, T., Iliadis, L., Sylaios, G., 2006. Time-series modeling of fishery landings using ARIMA models and Fuzzy Expected Intervals software. *Environmental Modelling and Software* 21(1), 1711-1721. DOI: 10.1016/j.envsoft.2005.09.001
- Lawer, E.A., 2016. Empirical Modeling of Annual Fishery Landings. *Natural Resources* 7(1), 193-204. DOI: 10.4236/nr.2016.74018
- Martinez, F., Charte, F., Frías, M., Martínez-Rodríguez, M., 2022. Strategies for time series forecasting with generalized regression neural networks. *Neurocomputing* 491(1), 509-521. DOI: 10.1016/j.neucom.2021.12.028
- Martinez, F., Frías, M., Perez, M.D., Rivera, A.J., 2022. Time Series Forecasting by Generalized Regression Neural Networks Trained with Multiple Series. *IEEE Access* 10(1), 1-8. DOI: 10.1109/ACCESS.2022.3140377
- Michael Pawlus, M., Devine, R., 2020. A practical guide to designing, building, and improving neural network models using R. Packt Publishing. 317 p.
- Nurdin, E., Sondita, M.F.A., Yusfiandayani, R., Baskoro, M.S., 2016. Growth and mortality parameters of yellowfin tuna (*Thunnus albacares*) in Palabuhanratu waters, west Java (eastern Indian Ocean). *AACL Bioflux* 9(3), 741-747.
- Panhwar, S., Liu, Q., Khan, F., 2010. Selecting the Best Growth Model for Fish Using Akaike Information Criterion (AIC) and Bayesian Information Criterion (BIC). *Journal of the Fisheries Society of Taiwan* 37(3), 183-190.
- Prathibha, R., Syda Rao, G., Rammohan, K., 2012. Age, growth and population structure of the yellowfin tuna *Thunnus albacares* (Bonnaterre, 1788) exploited along the east coast of India. *Indian Journal of Fisheries* 59(1), 1-6.
- R Development Core Team., 2022. R: A Language and Environment for Statistical Computing. Vienna: Foundation for Statistical Computing. <http://www.R-project.org>.
- Ramalingam, A.B., Kar, L., Govindaraj, K., Prasad, G.V.A., 2012. Study of the growth and population parameters of yellowfin tuna (*Thunnus albacares*) in the Andaman and Nicobar waters based on the length frequency data. Report of 14th IOTC proceedings. 24–29 October. Mauritius: 17 p.
- Riede, K., 2004. Global register of migratory species - from global to regional scales. Final Report of the R&D-Projekt 808 05 081. Federal Agency for Nature Conservation, Bonn, Germany. 329 p.
- Rodrigo Silvestre Martins, J.A., 2006. Cephalopods and fish attracted by night lights in coastal shallow-waters, off southern Brazil, with the description of squid and fish behavior. *Revista de Etologia* 4(1) 151-160.
- Rosenberg, A.A., Bolster, W.J., Alexander, K.E., Leavenworth, W.B., Cooper, A.B., McKenzie, M.G., 2005. The history of ocean resources: modeling cod biomass using historical records. *Frontiers in Ecology and the Environment* 3(2), 84-90. DOI: 10.1890/1540-9295(2005)003[0078:THOORM]2.0.CO;2
- Schultz, K., 2011. Ken Schultz's Field Guide to Saltwater Fish. New Jersey: John Wiley & Sons. 230 p.
- Shabri, A., Samsudin, R., 2015. Fishery Landing Forecasting Using Wavelet-Based Autoregressive Integrated Moving Average Models. Hindawi Publishing Corporation Mathematical Problems in Engineering, Volume 2015, Article ID 969450, 9. DOI: 10.1155/2015/969450
- Skaar, S., 2020. A Comprehensive Guide to Neural Network Modeling. Nova Science Pub Inc. 172 p.

- Somvanshi, V.S., Bhargava, A.K., Gulati, D.K., Varghese, S., Varghese, S.P., 2003. Growth parameters estimated for yellowfin tuna occurring in the Indian EEZ. 6th IOTC proceedings. Victoria, 3-12 June, Seychelles, 191-193.
- Sturesson, A., Weitz, N., Persson, A., 2018. SDG 14: Life Below Water. A Review of Research Needs. Technical annex to the Formas report Forskning för Agenda 2030: Översikt av forskningsbehov och vägar framåt. Stockholm Environment Institute, Stockholm.
- Taghavimotlagh, S.A., 2010. Population dynamics and biology of Largehead hairtail (*Trichiurus lepturus*) fish in the Iranian coasts of the Persian Gulf and the Sea of Oman. National Fisheries Science Research Institute, 87 p. (In Persian)
- Taghavimotlagh, S.A., 2018. Economic fishes of Persian Gulf and Sea of Oman and forecasting sustainable harvesting of their stocks. National Fisheries Science Research Institute. 668 p. (in Persian)
- Tantivala, C., 2000. Some biological study of yellowfin tuna (*Thunnus albacares*) and bigeye tuna (*Thunnus Obesus*) in the eastern Indian Ocean. 2nd IOTC proceedings. Victoria, 23-27 September, Seychelles, pp. 436-440.
- Tiumentsev, Y., Egorchev, M., 2019. Neural Network Modeling and Identification of Dynamical Systems. Academic Press. 324 p. DOI: 10.1016/C2017-0-02854-9.
- Tsitsika, E., Maravelias, C., Haralabous, J., 2007. Modeling and forecasting pelagic fish production using univariate and multivariate ARIMA models. *Fisheries Science* 73(1), 979-988. DOI: 10.1111/j.1444-2906.2007.01426.x

