



University of Hormozgan



The effect of weighting predictor variables on the performance of habitat suitability index (HSI) models (case study: Caspian Kutum, *Rutilus frisii*)

Fateh Moëzzi¹, Soheil Eagderi¹✉

1. Department of Fisheries, Faculty of Natural Resources, University of Tehran, Karaj, Iran.

Article Info

Article type:
Research Article

Article history:

Received: 20 September 2024
Accepted: 24 November 2024
ePublished: 25 January 2025

✉ **Corresponding Author:**
Soheil.eagderi@ut.ac.ir

Keywords:

Caspian Kutum,
Habitat suitability index (HSI),
Modeling,
Support vector machine
(SVM),
Weighting.

ABSTRACT

This study investigates the effect of weighting predictors on the performance of habitat suitability index (HSI) models using arithmetic mean (AMM) and geometric mean (GMM) methods. The case study focused on the catch data of Caspian Kutum (*Rutilus frisii*), with habitat parameters including day-time sea surface temperature, near-surface chlorophyll-a concentration, particulate organic carbon concentration, distance from fishing points to the river mouth, and bottom slope. Relative weights of environmental variables and suitability index (SI) fitting were determined using the support vector machine (SVM) technique. Sea surface temperature and particulate organic carbon concentration were identified as the most influential variables, with weights of 0.315 and 0.231, respectively, in explaining fish catch variance. Model performance evaluation revealed that the HSIWGMM model outperformed others, showing the lowest RMSE (training: 0.1818, testing: 0.2540) and the highest correlation coefficient (training: 0.4693, testing: 0.1953). In contrast, the HSIWAMM model showed the weakest performance (training: RMSE = 0.4023, $r = 0.3843$; testing: RMSE = 0.3858, $r = 0.1360$).



Publisher: University of Hormozgan

EXTENDED ABSTRACT

Introduction

Habitat suitability index (HSI) models are widely used by ecologists to quantify the relationship between fish distribution and habitat quality conditions. These models are constructed using a set of suitability indices (SIs) that are functions of one or more environmental predictors, which describe the suitability of habitat conditions for a target species. The weighting of habitat predictors plays a significant role in HSI model performance. Previous research has shown that the use of different weight estimates for model predictors can lead to substantial differences in model predictions. Therefore, applying an efficient weighting approach is crucial for developing reliable HSI models that accurately estimate fish habitat preferences and distributions. The objective of this study was to investigate the effect of weighting habitat predictors on the predictive performance of HSI models for Caspian Kutum (*Rutilus frisii*) as a case study.

Materials and Methods

Catch data for Caspian Kutum from the southern waters of the Caspian Sea during the 2002/03 to 2011/12 fishing seasons were used as a fish abundance index, converted to catch-per-unit-of-effort (CPUE) to serve as the response variable in the models. The environmental (habitat) variables included day-time sea surface temperature (SST, °C), near-surface chlorophyll-a concentration (CHL, mg m³), particulate organic carbon concentration (POC, mg m³), distance from fishing points to the river mouth (Distance, km), and bottom slope (Slope, °), which were obtained from the MODIS and GEBCO datasets. Eighty percent of the data were used for model training, while the remaining data were reserved for testing the models.

The support vector machine (SVM) technique was employed to calculate the relative importance of the environmental predictors and to fit the suitability index (SI) curves in R software (version 4.1.2) using the “e1071”, “mixOmix”, “randomForest”, and “pdp” packages. The SI values for each predictor were calculated using normalized CPUE values (equation 1):

$$\widehat{SI}_i = \frac{\widehat{CPUE}_i - \widehat{CPUE}_{min}}{\widehat{CPUE}_{max} - \widehat{CPUE}_{min}} \quad (\text{equation 1})$$

Where \widehat{SI}_i represents the estimated SI for the i th variable, \widehat{CPUE}_i is the mean estimated CPUE for the i th value of the predictor, and \widehat{CPUE}_{max} and \widehat{CPUE}_{min} are the maximum and minimum estimated CPUE for the predictor, respectively. Final HSI scores were calculated using the arithmetic mean model (AMM) (equation 2), weighted arithmetic mean model (WAMM) (equation 3), geometric mean model (GMM) (equation 4), and weighted geometric mean model (WGMM) (equation 5) methods as follows:

$$\widehat{HSI}_i = \frac{1}{n} \sum_{i=1}^n \widehat{SI}_i \quad (\text{equation 2})$$

$$\widehat{HSI}_i = \sum_{i=1}^n \widehat{W}_i \widehat{SI}_i \quad (\text{equation 3})$$

$$\widehat{HSI}_i = \sqrt{\prod_{i=1}^n \widehat{SI}_i} \quad (\text{equation 4})$$

$$\widehat{HSI}_i = \prod_{i=1}^n \widehat{SI}_i^{\widehat{W}_i} \quad (\text{equation 5})$$

where \widehat{SI}_i is the SI value for the i th predictor, \widehat{W}_i is the partial weight of the i th predictor, and n is the number of total predictors. A standardized form of the real CPUEs (stCPUE) (equation 6) was used as the fish abundance index at the range of [0, 1]:

$$stCPUE_{ij} = \frac{CPUE_{ij} - CPUE_{min}}{CPUE_{max} - CPUE_{min}} \quad (\text{equation 6})$$

The prediction error of HSI models was assessed using root mean squared error (RMSE) scores (equation 7):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{N}} \quad (\text{equation 7})$$

where x_i and \hat{x}_i are the stCPUE and predicted HSI scores, respectively. The Pearson correlation coefficient (r) between stCPUE and HSI values was used as another measure of model performance. Also, the proportions of fishing point suitability in stCPUE and HSI classes of [0.0, 0.2), [0.2, 0.4), [0.4, 0.6), [0.6, 0.8), and [0.8, 1.0] were calculated to compare the final model prediction accuracy.

Results

The fitted SVM models revealed the following weights for the environmental predictors: SST = 0.315, POC = 0.231, Slope = 0.186, CHL = 0.142, and Distance = 0.126. The suitability index (SI) curves for most predictors exhibited bell-shaped distributions, with the highest SI values at the following ranges: 13-17 mg m³ for CHL, 24-25°C for SST, 4200-5100 mg m³ for POC, 0.25-0.33° for Slope, and 0-10 km for Distance. Among the HSI models, the HSIWGMM model demonstrated the best performance, with the lowest RMSE values for both training (RMSE = 0.1818) and test (RMSE = 0.2540) datasets. It also exhibited the highest correlation coefficients for the training ($r = 0.4693$) and test ($r = 0.1953$) datasets. In contrast, the HSIWAMM model showed the weakest performance, with training RMSE = 0.4023 and $r = 0.3843$, and testing RMSE = 0.3858 and $r = 0.1360$. Among the unweighted models, HSI GMM outperformed HSI AMM, with lower RMSE and higher r values. Comparing the proportions of fishing points in habitat suitability classes for the 2010/11 and 2011/12 catch seasons revealed that the HSIWGMM model showed a higher overlap with the stCPUE data compared to other HSI models, while HSI AMM and HSIWAMM showed the lowest overlaps.

Conclusion

The findings of this study demonstrate that the HSI GMM model, without weighting predictors, outperformed the HSI AMM model. Incorporating predictor importance scores obtained from the SVM models as weights in the development of HSI models significantly improved the

predictive accuracy of the HSIWGMM model, which showed a high overlap between its suitability class distribution and stCPUE values. Conversely, applying weighted predictors to the AMM model resulted in reduced predictive performance for the HSIWAMM model.



تأثیر وزن دهی متغیرهای پیش‌بین بر عملکرد مدل‌های شاخص مطلوبیت زیستگاه (HSI) (مطالعه موردی: ماهی سفید دریای خزر، *Rutilus frisii*)

فاتح معزی^۱ | سهیل ایگدری[✉]

۱. گروه شیلات، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران

چکیده

اطلاعات مقاله

نوع مقاله:

مقاله پژوهشی

در مطالعه حاضر، تأثیر وزن دهی متغیرهای پیش‌بین بر عملکرد پیش‌بینی مدل‌های شاخص مطلوبیت زیستگاه (HSI) مبتنی بر دو روش مدل میانگین حسابی (AMM) و مدل میانگین هندسی (GMM) مورد بررسی قرار گرفت. داده‌های صید ماهی سفید دریای خزر (*Rutilus frisii*) به‌عنوان مورد مطالعاتی مورد استفاده قرار گرفت و متغیرهای زیستگاهی مورد استفاده عبارت بودند از: دمای سطح آب دریا در روز، غلظت کلروفیل-*a* در لایه سطحی آب، غلظت کربن آلی ذره‌ای، فاصله نقاط صیدگاهی از دهانه رودخانه و شیب بستر. محاسبه وزن نسبی پارامترهای محیطی و برازش مدل‌های شاخص مطلوبیت (SI) با استفاده از تکنیک ماشین بردار پشتیبان (SVM) انجام گرفت. دمای سطحی آب دریا و غلظت کربن آلی ذره‌ای به‌ترتیب با داشتن مقادیر ۰/۳۱۵ و ۰/۲۳۱، بیشترین مقادیر وزن را در توضیح واریانس صید ماهی به‌خود اختصاص دادند. ارزیابی پیش‌بینی مدل‌های برازش یافته در مراحل آموزش و آزمون مدل‌ها نشان داد که مدل HSI_{wgmm} با داشتن کمترین مقادیر RMSE (آموزش: ۰/۱۸۱۸؛ آزمون: ۰/۲۵۴۰) و بالاترین ضریب همبستگی (آموزش: ۰/۴۶۹۳؛ آزمون: ۰/۱۹۵۳) بهترین عملکرد را به خود اختصاص داده و ضعیف‌ترین عملکرد نیز با مدل HSI_{wamm} (آموزش: ۰/۴۰۲۳؛ RMSE = ۰/۳۸۴۳؛ $r = ۰/۳۸۵۸$ ؛ آزمون: ۰/۳۸۵۸ = RMSE: ۰/۱۳۶۰؛ $r = ۰/۱۳۶۰$) به‌دست آمد.

تاریخ دریافت: ۱۴۰۳/۰۶/۳۰

تاریخ پذیرش: ۱۴۰۳/۰۹/۰۴

تاریخ انتشار: ۱۴۰۳/۱۱/۰۶

✉ نویسنده مسئول:

soheil.eagderi@ut.ac.ir

کلیدواژه‌ها:

شاخص مطلوبیت زیستگاه

(HSI)،

ماشین بردار پشتیبان،

ماهی سفید،

مدلسازی،

وزن‌دهی.



ناشر: دانشگاه هرمزگان

مقدمه

برنامه‌ریزی و مدیریت حفاظتی ذخائر ماهیان مبتنی بر شناخت و تشخیص مکانی-زمانی گستره‌های جغرافیایی مربوط به حضور و فراوانی این گونه‌ها در ارتباط با شرایط محیطی است (Giannoulaki *et al.*, 2013). مدل‌سازی زیستگاه به‌طور معمول در تشخیص ارتباط بین الگوهای توزیع گونه و متغیرهای زیستی/غیرزیستی مورد استفاده قرار می‌گیرد (Brooks, 1997). مدل‌های توزیع گونه‌ای که با نام مدل‌های مطلوبیت زیستگاه نیز شناخته می‌شوند، اهمیت زیادی در ارزیابی فضایی و مدیریت صید گونه‌های تجاری ماهیان دارند (Tian *et al.*, 2009). این مدل‌ها اطلاعات مکانی مربوط به فراوانی ماهیان را با داده‌های محیطی ترکیب کرده و به ارزیابی بازه‌های بهینه شرایط زیستگاهی برای آن‌ها می‌پردازند (Zwolinski *et al.*, 2011; Moëzzi *et al.*, 2022). به‌طور کلی، مدل‌های زیستگاهی به‌صورت مدل‌های تحلیلی (analytical) (Pickett *et al.*, 1994)، مکانیکی (mechanistic) (Prentice, 1986) و تجربی (empirical) (Korzukhin *et al.*, 1996) قابل طبقه‌بندی هستند.

در میان طیف گسترده تکنیک‌های مدل‌سازی مورد استفاده در کمی‌سازی ارتباطات توزیع ماهی و شرایط کیفی زیستگاهی، مدل‌های تجربی مطلوبیت زیستگاه (habitat suitability index: HSI) به‌طور گسترده با توجه به مزیت‌های آن‌ها مورد استفاده بوم‌شناسان قرار می‌گیرند. مدل‌های HSI به‌طور عمده در مدیریت و تحقیقات مربوط به توزیع گونه‌های تجاری ماهیان نیز بکار گرفته شده‌اند (Mondal *et al.*, 2021; Vaz *et al.*, 2021; Moëzzi *et al.*, 2022; Wang *et al.*, 2022; Wang *et al.*, 2023). مدل‌سازی HSI می‌تواند نقش مهمی در توسعه معیارهای مدیریت مکانی ذخایر آبریان از جمله تعریف زیستگاه‌های اصلی ماهیان، شناخت نقاط بهینه ماهیگیری و استقرار نواحی حفاظت‌شده دریایی برای گونه‌های مهم داشته باشد (Chang *et al.*, 2015; Johnson *et al.*, 2013; Tanaka and Chen, 2012). این مدل‌ها در طیف متنوعی از موارد کاربرد مورد استفاده قرار می‌گیرند که از آن جمله می‌توان به تخصیص مناطق حفاظت‌شده دریایی تا مدل‌سازی توزیع گونه‌های با اهمیت تجاری اشاره کرد. الگوهای زمانی یا مکانی ترجیح زیستگاهی و شناسایی نقاط داغ حضور گونه‌ها به‌دست آمده از این مدل‌ها و تحقیقات مرتبط با آن‌ها می‌تواند مبنای روشن و کارآمدی برای مدیریت مناسب بهره‌برداری و حفاظت از گونه‌ها را فراهم سازد (Chen *et al.*, 2012). ارائه نقشه‌های قابل اعتماد از زیستگاه‌های مطلوب گونه‌ای و شناسایی زیستگاه‌های کلیدی در چرخه‌های حیات گونه‌ای به‌عنوان بخشی از خروجی این مدل‌ها می‌تواند برای مدیران شیلاتی بسیار کمک‌کننده باشد (Chang *et al.*, 2012). مدل HSI مبتنی بر مجموعه‌ای از شاخص‌های مطلوبیت (SI) به‌عنوان تابعی از یک یا تعداد بیشتری متغیر محیطی است که مطلوبیت زیستگاه را برای یک گونه هدف بیان می‌کنند (Brown *et al.*, 2000; Tian *et al.*, 2009; Chen *et al.*, 2010). مدل‌های HSI، مطلوبیت زیستگاهی یک گونه را در مقیاسی عددی بین صفر (کمترین سطح مطلوبیت) و یک (بیشترین سطح مطلوبیت) بر مبنای ترکیبی از شاخص‌های منفرد (SI) که توضیح دهنده ارتباط بین متغیرهای زیستی/غیرزیستی و فراوانی گونه می‌باشند، استانداردسازی می‌کنند (Franklin, 2010). در مدل‌سازی HSI، شاخص فراوانی (abundance index: AI) عمدتاً جهت ایجاد شاخص مطلوبیت برای هر متغیر زیستگاهی مورد استفاده قرار می‌گیرد (Tian *et al.*, 2009; Tanaka and Chen, 2016) و به‌طور کلی این فرض در نظر گرفته می‌شود که یک رابطه خطی مثبت بین شاخص‌های مطلوبیت و شاخص‌های فراوانی وجود دارد (Chang *et al.*, 2013) به‌طوری که نواحی دارای بیشترین مقادیر AI به عنوان زیستگاه‌های بهینه (SI = 1.0) و نواحی با کمترین مقادیر AI به عنوان زیستگاه‌های فقیر (SI = 0) شناخته می‌شوند (Brown *et al.*, 2000; Tian *et al.*, 2009). داده‌های شیلاتی تجاری نظیر زی‌توده، تلاش صیادی و نرخ صید به‌عنوان داده‌هایی ارزشمند و شاخص از فراوانی گونه‌ها در ساختار این مدل‌ها مورد استفاده قرار می‌گیرند (Li *et al.*, 2014; Moëzzi *et al.*, 2022). چپش مجموعه وزنی برای متغیرهای زیستگاهی مختلف می‌تواند تا حد زیادی مدل‌سازی HSI را تحت تأثیر قرار دهد (Gong *et al.*, 2012). تأثیر استفاده از وزن‌دهی‌های متفاوت متغیرهای زیستگاهی بر میزان مشارکت‌دهی این متغیرها در مدل‌های زیستگاه می‌بایست به دقت مورد بررسی قرار گیرد (Chang *et al.*, 2010; Yi *et al.*, 2016). در مدل‌سازی HSI، به‌دلیل عدم وجود اطلاعات کافی درباره سهم تأثیر پارامترهای محیطی بر پراکنش گونه، به‌طور معمول تمامی متغیرها با فرض داشتن وزن همسان مورد استفاده قرار می‌گیرند (Tian *et al.*, 2009).

(Yu et al., 2016). این وضعیت مبتنی بر تأثیرگذاری یکسان متغیرهای محیطی بر شاخص‌های فراوانی است که کاملاً غیرواقع-بینانه است. نشان داده شده است که برآوردهای وزنی مختلف منجر به شکل‌های متفاوتی از توزیع زیستگاهی مطلوب می‌گردد (Gong et al., 2012). از این جهت، لازم است به منظور دستیابی به پیش‌بینی‌های منطقی از توزیع گونه‌ای، در توسعه مدل‌ها از رویکردی استفاده گردد که بین نقش متغیرهای محیطی در ایجاد مدل تمایز قائل شود. استفاده از برخی روش‌ها و تکنیک‌های یادگیری ماشین در تعیین سهم مشارکت متغیرهای محیطی در پیش‌بینی توزیع گونه‌ای در برخی مطالعات صورت گرفته است (Zohmann et al., 2013; Torres et al., 2015; Yi et al., 2016; Xue et al., 2017). در این روش‌ها، ارتباط بین تناسب مجموعه پارامترهای محیطی و شاخص‌های فراوانی گونه ارزیابی شده و بر این اساس، سهم نسبی هر یک از پارامترها به‌عنوان عوامل پیش‌بین در توضیح واریانس توزیع فراوانی محاسبه می‌گردد (Xue et al., 2017). بکارگیری رویکردهای وزن‌دهی شده در مدل‌سازی HSI می‌تواند تا در برخی موارد منجر به تأثیر قابل ملاحظه بر مقادیر HSI پایین گردد، در صورتی که تأثیر کمتری بر مقادیر بالای HSI داشته باشد (Gong et al., 2012). این وضعیت ممکن است منجر به بیش برآورد سطوح مطلوبیت زیستگاهی در مقایسه با وضعیت واقعی مبتنی بر شاخص‌های فراوانی گردد. از این جهت، لازم است وجود یک رویکرد ساختارمند مشخص جهت اختصاص اوزان متناسب به متغیرهای محیطی در مدل‌سازی زیستگاه مورد بررسی قرار گیرد.

در مطالعه حاضر، تأثیر وزن‌دهی پارامترهای محیطی زیستگاهی بر عملکرد پیش‌بینی مدل‌های HSI پرداخته شده است. بدین منظور ماهی سفید دریای خزر (*Rutilus frisii*) با توجه به دسترسی به داده‌های صید بلندمدت و همچنین داده‌های محیطی زیستگاهی اثرگذار بر پراکنش آن در نقاط صیدگاهی به‌عنوان مورد مطالعاتی مورد استفاده قرار گرفت. ماهی سفید از گونه‌های بومی دریای خزر است که عمدتاً در آب‌های جنوبی خزر پراکنش داشته و مهمترین گونه از ماهیان استخوانی از نظر صید تجاری و مباحث حفاظتی محسوب می‌گردد (Moëzzi et al., 2022; Moëzzi et al., 2024). روش مدل‌سازی ماشین بردار پشتیبان (support vector machine: SVM) نیز به‌عنوان تکنیک مورد استفاده جهت برآورد سهم نسبی متغیرهای محیطی در توضیح توزیع پراکندگی ماهی بکار گرفته شد.

مواد و روش‌ها

در این مطالعه، داده‌های صید ماهی سفید دریای خزر (*Rutilus frisii*) به‌عنوان مورد مطالعاتی مورد استفاده قرار گرفت. این داده‌ها مربوط به صیدگاه‌های صید پره ساحلی در نوار ساحلی جنوب خزر در بازه سال‌های ۲۰۰۲ تا ۲۰۱۲ (فصول صید ۲۰۰۲/۰۳ تا ۲۰۱۱/۱۲) بود. جهت استانداردسازی داده‌ها، مقادیر صید در واحد تلاش صیادی (catch-per-unit-of-effort: CPUE) با استفاده از رابطه (۱) محاسبه گردید و به‌عنوان شاخصی از فراوانی ماهی مورد استفاده قرار گرفت.

$$CPUE (kg\ seine^{-1}h^{-1}) = \frac{\text{صید (kg)}}{\text{زمان صید (h)} \times \text{تعداد تور پره (seine)}} \quad (\text{رابطه 1})$$

میانگین مقادیر CPUE در طول هر فصل صید در صیدگاه‌ها به‌عنوان متغیر پاسخ در فرآیند مدل‌سازی مورد استفاده قرار گرفت.

مجموعه‌ای از داده‌های سنجش از دور متغیرهای محیطی دارای تأثیر شناخته شده بر پراکنش گونه مورد مطالعه (Moëzzi *et al.*, 2022) به‌عنوان متغیرهای پیش‌بین مورد استفاده قرار گرفتند که عبارت بودند از: دمای سطحی آب دریا در روز (-day near surface chlorophyll-a)؛ غلظت کلروفیل-*a* در لایه سطحی آب (concentration: CHL(mg m⁻³))؛ غلظت کربن آلی ذره‌ای (particulate organic carbon: POC(mg m⁻³))؛ فاصله صیدگاه از دهانه رودخانه (Distance (km))؛ شیب بستر (Slope (°)). داده‌های مربوط به متغیرهای SST، CHL و POC از پایگاه داده پروژه MODIS (NASA Goddard Space Flight Center, Ocean Ecology Laboratory (2021)) استخراج گردید و برداشت مقادیر آنها در نقاط صیدگاهی در دوره زمانی سال‌های ۲۰۰۲ تا ۲۰۱۲ در محیط نرم‌افزار R (version: 4.1.2) با استفاده از بسته raster انجام گرفت. جهت تهیه نقشه شیب در نقاط صیدگاهی، از نقشه عمق‌سنجی به‌دست آمده از پایگاه داده GEBCO (The General Bathymetry Chart of the Oceans, 2021) استفاده شد. فاصله بین نقاط صیدگاهی تا دهانه رودخانه (Distance) نیز بر اساس نزدیک‌ترین فاصله مستقیم تا دهانه رودخانه‌های اصلی ورودی به جنوب دریای خزر در امتداد ساحل محاسبه گردید (Moëzzi *et al.*, 2022). داده‌های محیطی و صید مربوط به دوره‌های صید ۲۰۰۲/۰۳ تا ۲۰۰۹/۱۰ (۸۰٪ کل مجموعه داده) جهت آموزش مدل‌ها و داده‌های مربوط به دوره‌های صید ۲۰۱۰/۱۱ و ۲۰۱۱/۱۲ (۲۰٪ کل مجموعه داده) جهت آزمون پیش‌بینی مدل‌ها مورد استفاده قرار گرفت.

به‌منظور محاسبه سهم نسبی پارامترهای محیطی موردنظر در توضیح واریانس فراوانی ماهی سفید بر مبنای مقادیر CPUE و همچنین برازش منحنی‌های شاخص مطلوبیت این متغیرها از تکنیک ماشین بردار پشتیبان (SVM) استفاده گردید. این تکنیک، یکی از روش‌های کارآمد یادگیری ماشین (machine learning: ML) است که در مطالعات مختلف توزیع گونه‌ای مورد استفاده قرار گرفته است (Mugo and Saitoh, 2020; Martinez-Santos *et al.*, 2021; Raman *et al.*, 2023). برازش مدل SVM با استفاده از تابع svm از بسته (version 1.7-11) "e1071" با کرنل رادیال (شعاعی) انجام شد. به‌منظور تعیین ترکیب بهترین ترکیب پارامترهای مدل (gamma و cost) از تابع tune از بسته (version 6.3.2) "mixOmics" استفاده گردید. میزان اهمیت نسبی متغیرها در مدل با استفاده از تابع Importance از بسته "randomForest" به‌دست آمد. رسم نمودارهای وابستگی نسبی متغیرهای مدل (یا به عبارت دیگر منحنی‌های شاخص مطلوبیت (SI)) از تابع partial از بسته (version 0.8.0) "pdp" استفاده گردید.

جهت محاسبه مقادیر SI برای هر یک پارامترهای محیطی، براساس مقادیر CPUE برآوردشده نرمال‌شده، از رابطه (۲) استفاده شد:

$$\widehat{SI}_i = \frac{\widehat{CPUE}_i - \widehat{CPUE}_{min}}{\widehat{CPUE}_{max} - \widehat{CPUE}_{min}} \quad (\text{رابطه 2})$$

که در آن مقدار \widehat{SI}_i مقدار SI برآوردشده برای مقدار i ام از متغیر پیش‌بین، مقدار میانگین \widehat{CPUE}_i برآوردشده برای مقدار i ام از متغیر پیش‌بین، و \widehat{CPUE}_{min} و \widehat{CPUE}_{max} نیز مقادیر حداقل و حداکثر CPUE برآوردشده برای متغیر مورد بررسی است (Moëzzi *et al.*, 2022). جهت محاسبه مقادیر نهایی HSI برای نقاط صیدگاهی بر مبنای مقادیر SI مجموعه پارامترهای محیطی از رویکردهای محاسباتی مدل میانگین حسابی (arithmetic mean model: AMM) (رابطه ۳)، مدل میانگین حسابی وزن‌دهی شده (weighted arithmetic mean model: WAMM) (رابطه ۴)، مدل میانگین هندسی (geometric mean model: GMM) (رابطه ۵) و مدل میانگین هندسی وزن‌دهی شده (weighted geometric mean model: WGMM) (رابطه ۶) استفاده گردید:

$$\widehat{HSI}_i = \frac{1}{n} \sum_{i=1}^n \widehat{SI}_i \quad (\text{رابطه 3})$$

$$\widehat{HSI}_i = \sum_{i=1}^n \widehat{W}_i \widehat{SI}_i \quad (\text{رابطه 4})$$

$$\widehat{HSI}_i = \sqrt[n]{\prod_{i=1}^n \widehat{SI}_i} \quad (\text{رابطه 5})$$

$$\widehat{HSI}_i = \prod_{i=1}^n \widehat{SI}_i^{\widehat{W}_i} \quad (\text{رابطه 6})$$

در این روابط \widehat{SI}_i مقدار SI برای پارامتر محیطی نام، \widehat{W}_i مقدار سهم نسبی پارامتر نام، و n تعداد متغیرهای محیطی مورد استفاده در برازش مدل HSI است.

به‌منظور ارزیابی مقادیر پیش‌بینی‌شده مدل‌های HSI با سطوح واقعی CPUE به عنوان شاخص فراوانی ماهی، از شکل استاندارد شده صید در واحد تلاش صیادی (stCPUE) (در مقیاس [0, 1] استفاده شد که محاسبه آن با استفاده از رابطه (۷) انجام گرفت:

$$stCPUE_{ij} = \frac{CPUE_{ij} - CPUE_{min}}{CPUE_{max} - CPUE_{min}} \quad (\text{رابطه 7})$$

در این رابطه $CPUE_{ij}$ عبارت است از مقدار CPUE در صیدگاه نام در سال نام. همچنین، $CPUE_{min}$ و $CPUE_{max}$ به‌ترتیب کمترین و بیشترین مقادیر CPUE در تمامی صیدگاه‌ها و کل سال‌های دوره زمانی مورد بررسی می‌باشد. در ادامه، با استفاده از مقادیر HSI و stCPUE، ریشه میانگین مربعات خطا (root mean square error: RMSE) (رابطه (۸)) محاسبه گردید:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{N}} \quad (\text{رابطه 8})$$

در این رابطه، x_i معادل مقادیر stCPUE و \hat{x}_i نیز مقادیر HSI برآورد شده توسط مدل‌ها است. از ضریب همبستگی پیرسون (r) جهت بررسی میزان تطابق مقادیر stCPUE و HSI برآورد شده استفاده گردید. همچنین، در پایان چگونگی توزیع نسبت‌های نقاط صیدگاهی بر اساس مقادیر HSI و stCPUE در بازه‌های $[0/8, 1/0]$ ، $[0/6, 0/8]$ ، $[0/4, 0/6]$ ، $[0/2, 0/4]$ ، $[0/0, 0/2]$ مقایسه گردید.

نتایج

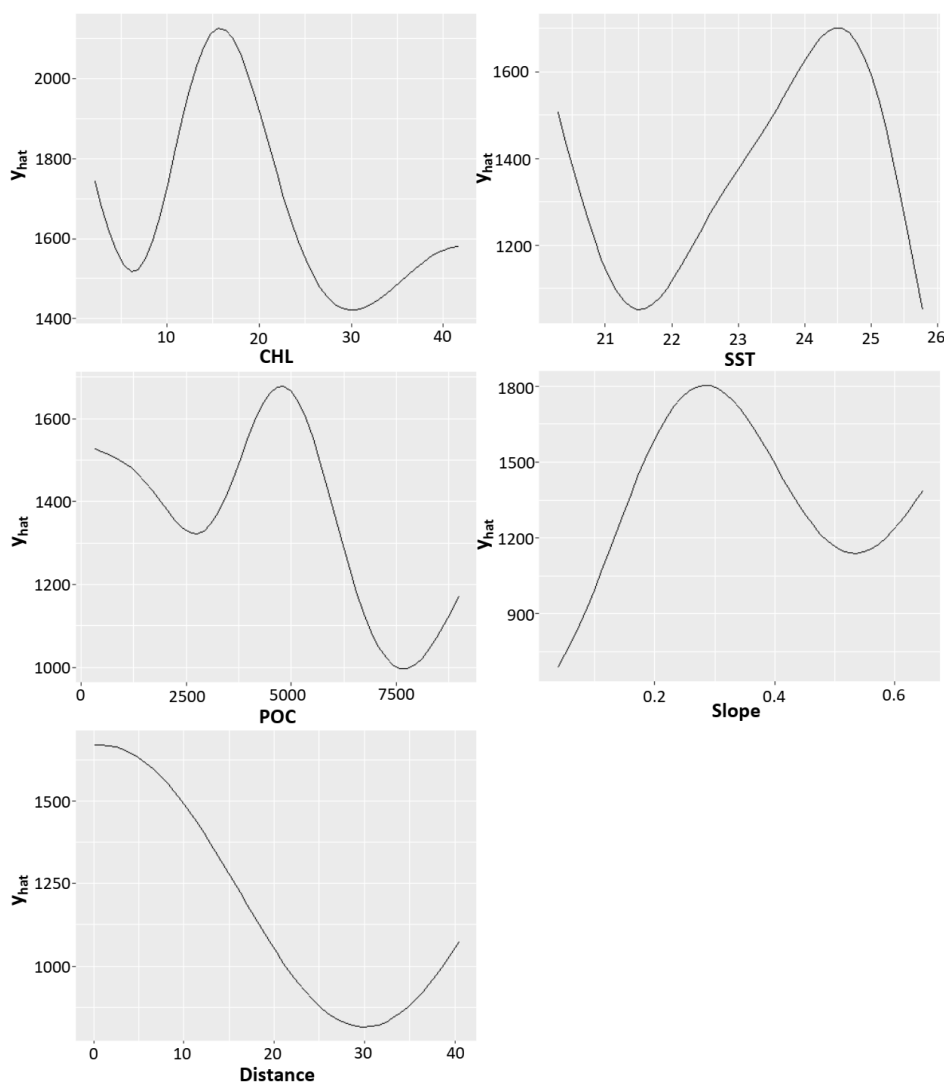
مقادیر وزن نسبی متغیرهای محیطی مورد استفاده در مدل‌های SVM (جدول ۱) نشان داد که دمای سطحی آب دریا (SST) و غلظت کربن آلی ذره‌ای (POC) به‌ترتیب بیشترین مقادیر اهمیت را در توضیح پراکنش ماهی داشته‌اند ($SST = 0/315$ ؛ $POC = 0/231$). کمترین وزن نیز در میان مجموعه متغیرهای مورد استفاده متعلق به عامل فاصله از دهانه رودخانه ($Distance = 0/126$) بود.

جدول ۱. مقادیر وزن متغیرهای محیطی حاصل از برازش مدل ماشین بردار پشتیبان (SVM).

متغیر پیش‌بین	CHL	SST	POC	Slope	Distance
---------------	-----	-----	-----	-------	----------

وزن نسبی	۰/۱۴۲	۰/۳۱۵	۰/۲۳۱	۰/۱۸۶	۰/۱۲۶
----------	-------	-------	-------	-------	-------

نمودارهای شاخص مطلوبیت (SI) به دست آمده برای بیشتر متغیرهای پیش‌بین (به استثنای فاصله از دهانه رودخانه (distance)) روندهایی منظم و عمدتاً زنگونه‌ای شکل با پیک مشخص را نشان دادند (شکل ۱). بازه‌های دارای بیشترین مقادیر SI برای این پارامترها عبارت بودند از: CHL: ۱۳ – ۱۷ mg m^{-3} ; SST: ۲۴ – ۲۵ $^{\circ}\text{C}$; POC: ۴۲۰۰ – ۵۱۰۰ mg m^{-3} ; Slope: منحنی به دست آمده برای متغیر پیش‌بین فاصله از دهانه رودخانه روندی کاهشی را با افزایش فاصله از دهانه رودخانه نشان داد به طوری که بیشترین مطلوبیت نقاط حضور ماهی مربوط به بازه ۰ – ۱۰ km بود.



شکل ۱. منحنی‌های شاخص مطلوبیت (SI) برای متغیرهای زیستگاهی حاصل از مدل‌های ماشین بردار پشتیبان (SVM). (CHL: غلظت کلروفیل در لایه سطحی آب (mg m^{-3}); SST: دمای سطحی آب دریا ($^{\circ}\text{C}$); POC: غلظت کربن آلی ذره‌ای (mg m^{-3}); Slope: شیب بستر ($^{\circ}$); Distance: فاصله از دهانه رودخانه (km)).

در میان مدل‌های HSI برازش یافته، بهترین عملکرد پیش‌بینی (جدول ۲) بر مبنای مقادیر RMSE مربوط به مدل HSI میانگین هندسی وزن‌دهی شده (HSI_{WGMM}) برای هر دو مجموعه داده آموزش و آزمون بود (آموزش: $\text{RMSE} = 0/1818$; آزمون: $\text{RMSE} = 0/2540$). همچنین، مدل HSI_{WGMM} بیشترین ضریب همبستگی (r) را در هر دو مرحله آموزش ($r = 0/4693$) و آزمون ($r = 0/1953$) به خود اختصاص داد. با این حال، مدل HSI_{WAMM} ضعیف‌ترین عملکرد را در مراحل آموزش ($r = 0/4023$)

مدل HSI_{GMM} با داشتن مقدار کمتر RMSE و مقدار بیشتر ضریب همبستگی در مقایسه با HSI_{AMM} در هر دو مرحله آموزش و آزمون بهتر بود (جدول ۲).

جدول ۲. مقادیر خطای میانگین مجذور مربعات (RMSE) و ضریب همبستگی پیرسون (r) مدل‌های شاخص مطلوبیت زیستگاه (HSI_{AMM}): مدل میانگین حسابی؛ HSI_{GMM} : مدل میانگین هندسی؛ HSI_{WAMM} : مدل میانگین حسابی وزن‌دهی شده؛ HSI_{WGMM} : مدل میانگین هندسی وزن‌دهی شده)

مدل	RMSE	r
HSI_{AMM}	۰/۳۸۴۱	۰/۴۰۴۷
HSI_{GMM}	۰/۲۹۷۰	۰/۴۲۱۵
HSI_{WAMM}	۰/۴۰۲۳	۰/۳۸۴۳
HSI_{WGMM}	۰/۱۸۱۸	۰/۴۶۹۳
HSI_{AMM}	۰/۳۶۶۵	۰/۱۵۱۹
HSI_{GMM}	۰/۳۲۷۶	۰/۱۶۵۸
HSI_{WAMM}	۰/۳۸۵۸	۰/۱۳۶۰
HSI_{WGMM}	۰/۲۵۴۰	۰/۱۹۵۳

آموزش

آزمون

مقایسه نسبت‌های توزیع نقاط در طبقات زیستگاهی در دوره‌های صید ۲۰۱۰/۱۱ و ۲۰۱۱/۱۲ (شکل ۲) نشان داد که خروجی‌های حاصل از مدل HSI_{WGMM} و طبقات زیستگاهی مبتنی بر مقادیر استاندارد شده صید در واحد تلاش صیادی ($stCPUE$) در مقایسه با دیگر مدل‌های HSI از تشابه بالایی برخوردار بود. مدل‌های HSI_{AMM} و HSI_{WAMM} کمترین همپوشانی را با نسبت‌های نقاط صیادی در طبقات مبتنی بر $stCPUE$ داشتند به طوری که خروجی‌های این مدل‌ها فاقد نقاط متعلق به طبقه دارای کمترین سطوح مطلوبیت زیستگاه ($0/2 - 0/0$) HSI بوده و نسبت بالایی از نقاط متعلق به طبقات با سطوح مطلوبیت بالاتر ($0/4$) $HSI >$ از خروجی‌های این مدل‌ها به دست آمد که بیانگر بیش‌برازش حاصل از آن‌ها در پیش‌بینی مطلوبیت شرایط زیستگاهی بوده است.



شکل ۲. توزیع نسبت نقاط ماهیگیری متعلق به طبقات شاخص مطلوبیت زیستگاهی و همچنین مقادیر استاندارد شده صید در واحد تلاش صیادی در فصول صید ۲۰۱۰/۱۱ و ۲۰۱۱/۱۲. (stCPUE: صید در واحد تلاش استاندارد شده؛ AMM: مدل میانگین حسابی؛ GMM: مدل میانگین هندسی؛ WAMM: مدل میانگین حسابی وزن دهی شده؛ WGMM: مدل میانگین هندسی وزن دهی شده)

بحث

مدلسازی HSI یکی از رویکردهای پرکاربرد مورد استفاده در تحقیقات مربوط به توزیع گونه‌های آبرزی محسوب می‌گردد که علی‌رغم سابقه طولانی استفاده از آن، همچنان به عنوان روشی کارآمد به کار گرفته می‌شود (Mondal *et al.*, 2021; Vaz *et al.*, 2021; Wang *et al.*, 2022; Wang *et al.*, 2023). یکی از عوامل مهم در ارتقای عملکرد و اعتبار مدل‌های HSI برازش مناسب منحنی‌های SI است (Tian *et al.*, 2009). مطالعات متعددی استفاده از روش‌های جدید یادگیری ماشین جهت برازش کارآمد مدل‌های زیستگاهی و تعیین سهم وزن متغیرهای محیطی را گزارش داده‌اند (Elith *et al.*, 2008; Xue *et al.*, 2017; Torre *et al.*, 2018). در مطالعه حاضر، از تکنیک ماشین بردار پشتیبان (SVM) که یکی از مدل‌های کارآمد یادگیری ماشین محسوب می‌گردد، جهت برازش شاخص‌های مطلوبیت (SI) و تعیین وزن متغیرهای محیطی استفاده گردید. این روش به صورت ترکیبی با دیگر رویکردهای مدلسازی و انواع مختلف داده‌های در دسترس در بررسی‌های توزیع گونه‌ای مورد استفاده قرار گرفته است (Mugo and Saitoh, 2020; Martinez-Santos *et al.*, 2021; Raman *et al.*, 2023). نتایج به دست آمده در این مطالعه به خوبی نشان داد که مدل SVM قابلیت بالایی در تشخیص روندهای غیرخطی موجود بین پارامترهای محیطی و شاخص فراوانی توزیع ماهی را دارا می‌باشد به طوری که در ارتباط با بیشتر متغیرها، تشخیص سطوح بهینه تأثیرگذاری عوامل محیطی مورد بررسی بر پراکنش ماهی در بازه‌های محدود و مشخص قابل تشخیص بود. بر اساس مقادیر به دست آمده وزن متغیرها (یا به عبارت دیگر، اهمیت این پارامترها در توضیح واریانس پراکنش ماهی)، متغیر دمای سطحی آب دریا (SST) و پس از آن غلظت کربن آلی ذره‌ای (POC) با داشتن بیشترین مقادیر وزنی، بالاترین نقش را در توضیح پراکنش گونه مورد بررسی داشتند.

این دو عامل در برخی از مطالعات قبلی نیز به عنوان عوامل مهم اثرگذار بر توزیع ماهی سفید دریای خزر تشخیص داده شده‌اند (Moëzzi *et al.*, 2022; Moëzzi *et al.*, 2023). اهمیت این دو عامل تا حد زیادی مرتبط با فرآیندهای فیزیولوژیک مربوط به مهاجرت ماهی (Hua *et al.*, 2020) و همچنین، دسترسی به مناطق تغذیه‌ای با در نظر گرفتن سطوح بالای تولید ثانویه بتتیک (Zhang *et al.*, 2019; Moëzzi *et al.*, 2022) مرتبط دانسته شده است.

مقایسه عملکرد روش‌های مورد استفاده در محاسبه مقادیر شاخص مطلوبیت زیستگاه در مطالعه حاضر نشان داد که در هر دو مجموعه مدل‌های فاقد وزن‌دهی و مدل‌های وزن‌دهی شده، محاسبه HSI با استفاده از روش GMM در مقایسه با روش AMM به برآوردهای مناسب‌تر و دقیق‌تری از شرایط زیستگاهی منتج شده است. مطالعات صورت گرفته با استفاده از این روش‌ها در محاسبه مقادیر HSI نتایج متفاوتی را در ارتباط با برتری نسبی این روش‌ها در پیش‌بینی مناسب‌تر توزیع ماهی گزارش داده‌اند (Xue *et al.*, 2017). به‌طور کلی انتخاب رویکردهای مختلف در ساختاردهی مدل‌های HSI یکی از مباحث مهم در توسعه مدل‌های HSI مرتبط با توزیع گونه‌ای قلمداد می‌شود (Vincenzi *et al.*, 2007). تفاوت در خروجی‌های متفاوت حاصل از این مدل‌ها به تفاوت در شکل ادغام مدل‌های SI در این روش‌ها و مفروضات متفاوت مربوط به هر یک از آن‌ها و همچنین محدودیت‌های آنها در تناسب با شاخص‌های فراوانی گونه مورد بررسی نسبت داده شده است (Li *et al.*, 2016). رویکرد AMM فرض یکسان بودن تأثیرگذاری متغیرهای ورودی را در چهارچوب محاسباتی HSI با توجه به مبنای جمع‌پذیری آن در نظر می‌گیرد و اثرات محدودکننده سطوح نامطلوب برخی از متغیرها در آن نادیده گرفته می‌شود که در برخی از موارد منتج به بیش‌برآورد مقادیر نهایی HSI محاسباتی می‌گردد. این وضعیت که به‌طور مشخص در نتایج به‌دست آمده در مطالعه حاضر برای مدل AMM مشاهده گردید، در دیگر مطالعات نیز مورد اشاره قرار گرفته است (Tian *et al.*, 2009; Chang *et al.*, 2013). این در حالی است که در رویکرد GMM، ضرب‌پذیری مقادیر SI مربوط به متغیرها سبب می‌گردد تا مقادیر کمتر برخی از متغیرها در محاسبه مقادیر HSI در مقایسه با روش AMM بیشتر دخالت داده شده و تطابق بیشتری بین مقادیر HSI نهایی و توزیع فراوانی گونه مورد بررسی به دست آید. چنین وضعیتی در نتایج به دست آمده در مطالعه حاضر از نظر تناسب پیش‌بینی‌های حاصل از مدل GMM (وزن‌دهی شده و فاقد وزن‌دهی) با توزیع stCPUE مشاهده شد. با این حال، این تأثیرات با افزایش تعداد متغیرهای ورودی مورد استفاده در مدلسازی و کاهش سهم تأثیرگذاری کلی هر یک از متغیرها کاهش می‌یابد (Xue *et al.*, 2017) که امکان قضاوت صحیح در مورد روش مورد استفاده در محاسبه HSI را تقلیل می‌دهد.

یافته‌های به دست آمده در مطالعه حاضر نشان داد استفاده از سناریوی وزن‌دهی متغیرهای محیطی پیش‌بین حاصل از مدل‌های SVM در ساختار مدل HSI برای روش محاسباتی GMM به شکلی قابل توجه ارتقای دقت پیش‌بینی را به همراه داشته است. این در حالی است که وزن‌دهی متغیرهای پیش‌بین در مدل HSI مبتنی بر روش محاسباتی AMM ضعیف‌ترین عملکرد مدل را در میان مجموعه مدل‌های برآزش یافته سبب شد به طوری که حتی عملکرد این مدل در مقایسه با مدل AMM فاقد وزن‌دهی نیز ضعیف‌تر بوده است. بررسی توزیع نقاط صیدگاهی در گروه‌های طبقه‌بندی شده بر اساس سطح مطلوبیت زیستگاهی به وضوح بیانگر این واقعیت بود که مدل‌های HSI_{AMM}، HSI_{WAMM} و به میزان کمتر، مدل HSI_{GMM} منجر به بیش‌برآورد سطح مطلوبیت زیستگاهی در نقاط صیدگاهی در مقایسه با توزیع طبقات زیستگاهی مبتنی بر stCPUE شده است به طوری که سهم ناچیزی از نقاط صیدگاهی بر اساس خروجی‌های این مدل‌ها به طبقات زیستگاهی با مطلوبیت کم تر ($HSI < 0.4$) اختصاص یافته و در مقابل تعداد زیادی از نقاط بر خلاف گروه‌بندی مبتنی بر stCPUE و همچنین خروجی HSI_{WGMM} در طبقات با مطلوبیت زیستگاهی بالاتر ($HSI > 0.6$) قرار داشته‌اند. از این نظر تأثیر وزن‌دهی در روش‌های مختلف محاسبه HSI تا حد زیادی متفاوت بوده است. پیامدهای اختصاص وزن‌های متفاوت به متغیرهای زیستگاهی مختلف در مدل‌های HSI در مطالعات معدودی مورد بررسی قرار گرفته است (Gong *et al.*, 2012; Yi *et al.*, 2016; Zohmann *et al.*, 2013). به‌طور کلی، تأثیر بکارگیری وزن‌دهی متغیرهای زیستگاهی بر میزان مشارکت‌دهی این متغیرها در مدل‌ها می‌بایست با دقت مورد بررسی قرار گیرد (Chang *et al.*, 2010; Yi *et al.*, 2016) به شکلی که چینش‌های وزنی در مدل‌های مختلف HSI می‌تواند تا حد زیادی خروجی‌ها را تحت تأثیر قرار دهد (Gong *et al.*, 2012). در مطالعه (Xue *et al.*, 2017) استفاده از سناریوهای وزن‌دهی افزایش دقت

پیش‌بینی مدل‌های AMM و GMM را در مقایسه با مدل‌های وزن‌دهی نشده به‌همراه داشته است که از نظر عملکرد مدل AMM در تضاد با نتایج یافته‌های حاضر می‌باشد. چنین تناقضی ممکن است مرتبط با واریانس داده‌های مربوط به شاخص فراوانی گونه و شکل کلی توزیع آن بوده باشد. استفاده از رویکردهای وزن‌دهی شده در مدل‌سازی HSI می‌تواند در برخی موارد منجر به تأثیر قابل ملاحظه بر مقادیر HSI پایین گردد اما تأثیر کمتری بر مقادیر بالای HSI داشته باشد (Gong et al., 2012). این وضعیت منتج به بیش‌آورد مدل‌ها برای داده‌های فراوانی کمتر و سطوح مطلوبیت زیستگاهی در مقایسه با وضعیت واقعی مبتنی بر شاخص‌های فراوانی گردد که در مطالعه حاضر نیز برای مدل HSI_{WAMM} مشهود بود. از این جهت می‌توان گفت استفاده از وزن‌های نسبی در محاسبات مدل‌سازی HSI و نتایج نهایی حاصل از آن تا حد زیادی وابسته به نوع مدل می‌باشد آنچنان که بر اساس یافته‌ها، دقت پیش‌بینی را در رویکرد محاسباتی AMM کاهش داده و ارتقای قابل توجه عملکرد مدل را در رویکرد GMM به همراه داشته است.

نتیجه‌گیری

در مطالعه حاضر، تأثیر وزن‌دهی متغیرهای پیش‌بین در ساختار مدل‌های HSI در روش‌های محاسباتی AMM و GMM بر عملکرد نهایی پیش‌بینی مدل‌ها مورد بررسی قرار گرفت. یافته‌های به‌دست آمده نشان داد که در شرایط عدم استفاده از وزن‌دهی متغیرها، مدل GMM عملکرد مناسب‌تری در مقایسه با مدل AMM داشته است. استفاده از سهم نسبی متغیرها در توضیح مقادیر صید گونه مطالعاتی حاصل از مدل‌های SVM ارتقای عملکرد مدل GMM و وزن‌دهی شده را به شکلی قابل توجه به همراه داشت به‌طوری که تطابق بالایی بین توزیع نقاط صیدگاهی در طبقات مطلوبیت زیستگاهی حاصل از این مدل با طبقات زیستگاهی حاصل از شاخص فراوانی استاندارد شده صید (stCPUE) به‌دست آمد. در عین حال، استفاده از وزن‌دهی متغیرها، تنزل عملکرد مدل AMM را در مقایسه با وضعیت بدون وزن‌دهی به همراه داشت. یافته‌های به‌دست آمده در این مطالعه در مجموع نشان‌دهنده اهمیت تأثیر وزن‌دهی مناسب متغیرهای پیش‌بین و همچنین استفاده از روش‌های کارآمدتر محاسبه شاخص مطلوبیت زیستگاه (HSI) در افزایش دقت نتایج مدل‌سازی HSI در پیش‌بینی سطوح صید ماهی سفید بود. بر این اساس، توجه به این موضوع می‌تواند در دستیابی به برآوردهای مناسب‌تر از توزیع گونه در برنامه‌های مدیریتی مرتبط با بهره‌برداری و حفاظت ذخایر این گونه و سایر گونه‌های آبریزان مؤثر واقع گردد.

سپاسگزاری

این مطالعه با حمایت مالی بنیاد ملی نخبگان (طرح پسادکتری شهید چمران) و دانشگاه تهران انجام شده است.

منابع

- Brooks, R.P., 1997. Improving habitat suitability index models. *Wildlife Society Bulletin*, 25, pp.163-167.
- Brown, S.K., Buja, K.R., Jury, S.H., Monaco, M.E. and Banner, A., 2000. Habitat suitability index models for eight fish and invertebrate species in Casco and Sheepscot Bays, Maine. *North American Journal of Fisheries Management*, 20(2), pp. 408-435. [https://doi.org/10.1577/1548-8675\(2000\)020<0408:HSIMFE>2.3.CO;2](https://doi.org/10.1577/1548-8675(2000)020<0408:HSIMFE>2.3.CO;2)

- Chang, J.H., Chen, Y., Holland, D. and Grabowski, J., 2010. Estimating spatial distribution of American lobster *Hamarus americanus* using habitat variables. *Marine Ecology Progress Series*, 420, pp. 145-156. <https://doi.org/10.3354/meps08849>
- Chang, Y.J., Sun, C.L., Chen, Y., Yeh, S.Z. and DiNardo, G., 2012. Habitat suitability analysis and identification of potential fishing grounds for swordfish, *Xiphias gladius*, in the South Atlantic Ocean. *International Journal of Remote Sensing*, 33, pp.7523-7541. <https://doi.org/10.1080/01431161.2012.685980>
- Chang, Y.J., Sun, C.L., Chen, Y., Yeh, S.Z., DiNardo, G., and Su, N.J., 2013. Modelling the impacts of environmental variation on the habitat suitability of swordfish, *Xiphias gladius*, in the equatorial Atlantic Ocean. *ICES journal of Marine Science*, 70(5), pp.1000-1012. <https://doi.org/10.1093/icesjms/fss190>
- Chen, X., Cao, J., Chen, Y., Liu, B. and Tian, S., 2012. Effect of the kuroshio on the spatial distribution of the red flying squid *Ommastrephes bartramii* in the Northwest Pacific Ocean. *Bulletin of Marine Science*, 88(1), pp. 63-71. <https://doi.org/10.5343/bms.2010.1098>
- Chen, X.J., Tian, S.Q., Chen, Y. and Liu, B.L., 2010. A modeling approach to identify optimal habitat and suitable fishing grounds for neon flying squid (*Ommastrephes bartramii*) in the Northwest Pacific Ocean. *Fishery Bulletin*, 108, pp.1-14. <https://doi.org/10.5343/bms.2010.1098>
- Elith, J., Leathwick, J.R. and Hastie, T., 2008. A working guide to boosted regression trees. *Journal of Animal Ecology*, 77(4), pp.802-813. <https://doi.org/10.1111/j.1365-2656.2008.01390.x>
- Franklin, J., 2010. Mapping species distributions: spatial influence and prediction. Cambridge University Press. <https://doi.org/10.1017/CBO9780511810602>
- Giannoulaki, M., Iglesias, M., Tugores, M.P., Bonanno, A., Patti, B., De Felice, A., Leonori, I., Bigot, J.L., Tićina, V., Pyrounaki, M.M., Tsagarakis, K., Machias, A., Somarakis, S., Schismenou, E., Quinci, E., Basilone, G., Cuttitta, A., Campanella, F., Miquel, J., Onate, D., Roos, D. and Valavanis, V., 2013. Characterizing the potential habitat of European anchovy *Engraulis encrasicolus* in the Mediterranean Sea, at different life stages. *Fisheries Oceanography*, 22(2), pp.69-89. <https://doi.org/10.1111/fog.12005>
- Gong, C., Chen, X., Gao, F. and Chen, Y., 2012. Importance of weighting for multi-variable habitat suitability index model: A case study of winter-spring cohort of *Ommastrephes bartramii* in the Northwestern Pacific Ocean. *Journal of Ocean University of China*, 11, pp. 241-248. <https://doi.org/10.1007/s11802-012-1898-6>
- Hua, C., Li, F., Zhu, Q., Zhu, G. and Meng, L., 2020. Habitat suitability of Pacific saury (*Cololabis saira*) based on a yield-density model and weighted analysis. *Fisheries Research*, 221, p.105408. <https://doi.org/10.1016/j.fishres.2019.105408>
- Johnson, A.F., Jenkins, S.R., Hiddink, J.G. and Hinz, H., 2013. Linking temperate demersal fish species to habitat: scales, patterns and future directions. *Fish and Fisheries*, 14(3), pp.256-280. <https://doi.org/10.1111/j.1467-2979.2012.00466.x>
- Korzukhin, M.D., Ter-Mikaelian, M.T. and Wagner, R.C., 1996. Process versus empirical models: which approach for forest management? *Canadian Journal of Forest Research*, 26(5), pp.879-887. <https://doi.org/10.1139/x26-096>

- Li, G., Cao, J., Zou, X., Chen, X. and Runnebaum, J., 2016. Modeling habitat suitability index for Chilean jack mackerel (*Trachurus murphyi*) in the South East Pacific. *Fisheries Research*, 178, pp.47–60. <https://doi.org/10.1016/j.fishres.2015.11.012>
- Li, G., Chen, X., Lei, L. and Guan, W., 2014. Distribution of hotspots of chub mackerel based on remote-sensing data in coastal waters of China. *International Journal of Remote Sensing*, 35(11-12), pp. 4399-4421. <https://doi.org/10.1080/01431161.2014.916057>
- Martinez-Santos, P., Aristizabal, H.F., Diaz-Alcaide, S. and Gomez-Escalonilla, V., 2021. Predictive mapping of aquatic ecosystems by means of support vector machines and random forests. *Journal of Hydrology*, 595, p.126026. <https://doi.org/10.1016/j.jhydrol.2021.126026>
- Moëzzi, F., Poorbagher, H., Eagderi, S. and Fegghi, J., 2023. Comparing the performance of generalized linear model (GLM) and random forest (RF) models in predicting catch distribution of Caspian Kutum (*Rutilus frisii*). *Journal of Fisheries (Iranian Journal of Natural Resources)*, 76(1), pp.27-38. (In Persian). <https://doi.org/10.22059/jFISHERIES.2023.91491>
- Moëzzi, F., Poorbagher, H., Eagderi, S., Fegghi, J., Dormann, C.F., Khorshidi Nergi, S. and Amiri, K., 2024. The importance of temporal scale in distribution modeling of migratory Caspian Kutum, *Rutilus frisii*. *Ecology and Evolution*, 14(9), p.e70259. <https://doi.org/10.1002/ece3.70259>
- Moëzzi, F., Poorbagher, H., Eagderi, S., Fegghi, J., Dormann, C.F., Khorshidi Nergi, S. and Amiri, K., 2022. Modelling habitat preference of Caspian Kutum, *Rutilus kutum*, using non-linear habitat suitability indices and generalized additive models. *Regional Studies in Marine Scienc*, 56, p.102715. <https://doi.org/10.1016/j.rsma.2022.102715>
- Mondal, S., HaghiVayghan, A., Lee, M-A., Wang, Y.-C. and Semedi, B., 2021. Habitat suitability modeling for the feeding ground of immature Albacore in the Southern Indian Ocean using satellite-derived sea surface temperature and chlorophyll data. *Remote Sensing*, 13, 2669. <https://doi.org/10.3390/rs13142669>
- Mugo, R. and Saitoh, S.I., 2020. Ensemble modeling of skipjack tuna (*Katsuwonus pelamis*) habitats in the western north pacific using satellite remotely sensed data: a comparative analysis using machine-learning models. *Remote Sensing*, 12(16), p.2591. <https://doi.org/10.3390/rs12162591>
- NASA., 2021. Goddard Space Flight Center, Ocean Ecology Laboratory.
- Pickett, S.T.A., Burke, I.C., Dale, V.H., Gosz, J.R., Lee, R.G., Pacala, S.W. and Shachak, M., 1994. Integrated models of forested regions. In: Groffman, P.M. and Linkens, G.E. (eds). *Integrated regional models: interactions between human and their environment*. Springer. <https://doi.org/10.1007/978-1-4684-6447-4-8>
- Prentice, I.C., 1986. Some concepts and objectives of forest dynamics research. *Forest Dynamics Research in Western and Central Europe*. PUDOC, Wageningen, 3241
- Raman, R.K., Das, A.K., Manna, R.K., Sahu, S.K. and Das, B.K., 2023. Ability of machine learning models to identify preferred habitat traits of a small indigenous fish (*Chanda nama*) in a large river of peninsular India. *Environmental Science and Pollution Research*, 30(6), pp.16499-16509. <https://doi.org/10.1007/s11356-022-23396-9>
- Tanaka, K. and Chen, Y., 2015. Spatiotemporal variability of suitable habitat for American lobster (*Homarus americanus*) in Long Island Sound. *Journal of Shellfish Research*. 34(2), pp.531–543. <https://doi.org/10.2983/10.2983/035.034.0238>

- Tanaka, K. and Chen, Y., 2016. Modeling spatiotemporal variability of the bioclimate envelope of *Homarus americanus* in the coastal waters of Maine and New Hampshire. *Fisheries Research*, 177, pp.137–152. <https://doi.org/10.1016/j.fishres.2016.01.010>
- The General Bathymetry Chart of the Oceans., 2021.
- Tian, S., Chen, X., Chen, Y., Xu, L. and Dai, X., 2009. Evaluating habitat suitability indices derived from CPUE and fishing effort data for *Ommatrephesbratramii* in the northwestern Pacific Ocean. *Fisheries Research*, 95, pp.181–188. <https://doi.org/10.1016/j.fishres.2008.08.012>
- Torre, M., Tanaka, K. and Chen, Y., 2018. A spatiotemporal evaluation of Atlantic Sea scallop *Placopectenmagellanicus* habitat in the gulf of maine using a bioclimate envelope model. *Marine and Coastal Fisheries: Dynamics, Management, and Ecosystem Science*, 10, pp.224-235. <https://doi.org/10.1002/mcf2.10022>
- Torres, L.G., Sutton, P.J., Thompson, D.R., Delord, K., Weimerskirch, H., Sagar, P.M., Sommer, E., Dilley, B.J., Ryan, P.G. and Phillips, R.A., 2015. Poor transferability of species distribution models for a pelagic predator, the Grey Petrel, indicates contrasting habitat preferences across ocean basins. *PLoS One*, 10(3), p.e0120014. <https://doi.org/10.1371/journal.pone.0120014>
- Vaz, L., Sousa, M. C., Gomez-Gesteira, M. and Dias, J. M., 2021. A habitat suitability model for aquaculture site selection: Ria de Avetro and Rias Baixas. *Science of the Total Environment*, 801, 149687. <https://doi.org/10.1016/j.scitotenv.2021.149687>
- Vincenzi, S., Caramori, G., Rossi, R. and De Leo, G.A., 2007. A comparative analysis of three habitat suitability models for commercial yield estimation of *Tapes philippinarum* in a North Adriatic coastal lagoon (Sacca di Goro, Italy). *Marine Pollution Bulletin*, 55(10), pp.579–590. <https://doi.org/10.1016/j.marpolbul.2007.09.016>
- Wang, D., Yu, J., Lin, Z. and Chen, P., 2023. Spatial-temporal distribution of fish larvae in the Pearl River estuary based on habitat suitability index model. *Biology*, 12, 603. <https://doi.org/10.3390/biology12040603>
- Wang, Y., Zhou, X., Chen, J., Xie, B. and Huang, L., 2022. Climate-induced habitat suitability changes intensify fishing impacts on the life history of large yellow croaker (*Larimichthys crocea*). *Ecology and Evolution*, 12, e9342. <https://doi.org/10.1002/ece3.9342>
- Xue, Y., Guan, L., Tanaka, K., Li, Z., Chen, Y. and Ren, Y., 2017. Evaluating effects of rescaling and weighting data on habitat suitability modeling. *Fisheries Research*, 188, pp.84-94. <https://doi.org/10.1016/j.fishres.2016.12.001>
- Yi, Y., Sun, J. and Zhang, S., 2016. A habitat suitability model for Chinese sturgeon determined using the generalized additive method. *Journal of Hydrology*, 534, pp.11–18. <https://doi.org/10.1016/j.jhydrol.2015.12.055>
- Yu, W., Yi, Q., Chen, X. and Chen, Y., 2016. Modelling the effects of climate variability on habitat suitability of jumbo flying squid, *Dosidicus gigas*, in the Southeast Pacific Ocean of Peru. *ICES Journal of Marine Science*, 73(2), pp.239-249. <https://doi.org/10.1093/icesjms/fsv223>
- Zhang, M., Wu, Y., Qi, L., Xu, M., Yang, C. and Wang, X., 2019. Impact of the migration behavior of mesoplagic fishes on the compositions of dissolved and particulate organic carbon on the northern slope of the South China Sea. *Deep Sea Research II*, 167, pp.46-54. <https://doi.org/10.1016/j.dsr2.2019.06.012>

- Zohmann, M., Pennerstorfer, J. and Nopp-Mayr, U., 2013. Modelling habitat suitability for alpine rock ptarmigan (*Lagopus mutahelvetica*) combining object-based classification of IKONOS imagery and Habitat Suitability Index modelling. *Ecological Modelling*, 254, pp.22–32. <https://doi.org/10.1016/j.ecolmodel.2013.01.008>
- Zwolinski, J.P., Emmett, R.L. and Demer, D.A., 2011. Predicting habitat to optimize sampling of Pacific sardine (*Sardinopssagax*). *ICES Journal of Marine Science*, 68(5), pp.867-879. <https://doi.org/10.1093/icesjms/fsr038>