

УДК 639.227.2(265.5)



Э.П. Черниенко, И.С. Черниенко*

Тихоокеанский филиал ВНИРО (ТИНРО),
690091, г. Владивосток, пер. Шевченко, 4**ИНФОРМАЦИОННОЕ СОПРОВОЖДЕНИЕ ПРОМЫСЛА
ЯПОНСКОЙ СКУМБРИИ *SCOMBER JAPONICUS*
В ТИХООКЕАНСКИХ ВОДАХ РОССИЙСКОЙ ФЕДЕРАЦИИ**

Для прогнозирования формирования благоприятной промысловой обстановки в Южно-Курильской зоне применяли методы машинного обучения. В качестве входных данных использовали значения температуры поверхности океана, производные гидрологические характеристики. Индикатором участков с благоприятной промысловой обстановкой выступали показания судовых суточных донесений по материалам промысловой статистики из Отраслевой системы мониторинга Центра системы мониторинга рыболовства и связи. Под промысловой обстановкой понимали наличие либо отсутствие промысла в определенной точке. Прогнозирование благоприятной промысловой обстановки, таким образом, было сведено к задаче бинарной классификации. Наличие промысла обозначали как «1», отсутствие — «0». Использовали библиотеку для языка сценариев R LightGBM, реализующий алгоритм градиентного бустинга на основе решающих деревьев. Показана эффективность примененного подхода для формирования оперативного прогноза с заблаговременностью до трех суток. За весь период промысла на спрогнозированных участках было добыто около 75 % общего вылова скумбрии, за период интенсивного промысла — около 84 %.

Ключевые слова: японская скумбрия, *Scomber japonicus*, пелагическая путина, южнокурильский район, оперативное прогнозирование, машинное обучение.

DOI: 10.26428/1606-9919-2021-201-390-399.

Chernienko E.P., Chernienko I.S. Information support for chub mackerel *Scomber japonicus* fishery in the Pacific waters of the Russian Federation // Izv. TINRO. — 2021. — Vol. 201, Iss. 2. — P. 390–399.

Methods of machine learning were applied for forecasting of chub mackerel fishing grounds in the South Kuril fishery district. The problem of perspective fishing area definition was reduced for a binary classification task, i.e. the sets of environmental conditions corresponded with presence or absence of fishing operations were determined for each point within the district. The fishery statistics for 2016–2020 and the data on SST with delay of 4–7 days from the date of catch, spatial SST gradients calculated using Belkin algorithm, and day-to-day SST variations were processed using LightGBM machine learning algorithm. The model was trained on the data for 2016–2019 and verified on the data for 2020. The AUC (as an aggregate measure of performance across all possible classification thresholds) varied from 0.65 to 0.92.

* Черниенко Эмилия Петровна, старший специалист, e-mail: emilya.chernienko@tinro-center.ru; Черниенко Игорь Сергеевич, кандидат биологических наук, ведущий научный сотрудник, e-mail: igor.chernienko@tinro-center.ru.

Chernienko Emilia P., senior specialist, Pacific branch of VNIRO (TINRO), 4, Shevchenko Alley, Vladivostok, 690091, Russia, e-mail: emilya.chernienko@tinro-center.ru; Chernienko Igor S., Ph.D., leading researcher, Pacific branch of VNIRO (TINRO), 4, Shevchenko Alley, Vladivostok, 690091, Russia, e-mail: chernienko.igor@tinro-center.ru.

In the fishery season of 2020, AUC was 0.69, on average, growing to 0.75 in the period of the highest catches. Approximately 75 % of the annual catch of chub mackerel was caught at the predicted sites in 2020; this portion reached 84 % in the period of the highest catches.

Key words: chub mackerel, *Scomber japonicus*, pelagic fishery season, South Kuril fishery district, operational forecasting, machine learning.

Введение

Японская скумбрия — ценный промысловый вид, широко распространенный в субтропических, тропических и умеренных водах Тихого океана. Скопления скумбрии обычны для вод, омывающих берега Японии, Республики Корея, Китая, а также Калифорнии и Мексики [Филатов, 2015]. В водах Российской Федерации наибольшие скопления характерны для Южно-Курильской зоны. Именно здесь и ведется промысел этого вида, возобновленный в последние годы и за короткое время успевший достичь значительных масштабов.

Скопления, имеющие промысловый характер в исключительной экономической зоне Российской Федерации, образуются в период нагула. В российские воды нагульные скопления заходят во второй половине июля, наибольших плотностей достигая в октябре-ноябре.

Если миграции в районы нагула (и промысла) определяются крупномасштабными гидрологическими циклами [Шунтов, 2001; Беляев, 2003; Филатов, 2015], то на распределение скоплений внутри района влияют локальные гидрологические явления — температура воды, ее градиенты, течения и т.д. Эти факторы определяют распределение кормовых организмов, за которыми и следуют косяки рыб [Филатов, 2015]. Информация об этих явлениях, таким образом, может быть использована для прогнозирования распределения скоплений в пределах нескольких суток [Бочаров, 1990]. Прогноз локализации участков акватории с потенциально благоприятной промысловой обстановкой с заблаговременностью 3–5 сут позволяет сузить акваторию поиска рыб в 8–10 раз [Кулик и др., 2019].

В последние годы для моделирования пространственного распределения численности и биомассы популяций в связи с условиями окружающей среды, в том числе для оптимизации их промысла, находят применение методы машинного обучения [Scales et al., 2017; Кулик и др., 2019].

Цель работы — показать использование машинного обучения для прогнозирования формирования участков с благоприятной промысловой обстановкой в суточном разрешении и с заблаговременностью до трех суток.

Материалы и методы

Использованы данные о температуре поверхности океана (ТПО) разрешением в $0,1^\circ$ из общедоступных источников [Usui et al., 2006, 2017]. Данные были представлены в виде таблицы, каждая строка которой соответствовала ячейке регулярной сетки размерностью $0,1 \times 0,1$ градуса по широте и долготе для определенной даты. Столбцы содержали соответствующие ячейке географические координаты, дату, ТПО, соответствующую дате и ТПО с задержками 1–7 сут. Дополнительно рассчитали градиенты ТПО в соседних участках пространства по алгоритму Белкина [Belkin, O'Reilly, 2009], а также разности температур между смежными сутками (т.е. временные градиенты). Временные градиенты отражают тренды в формировании гидрологических условий. Использование задержек с биологической точки зрения обосновано тем, что для образования концентраций зоопланктона, служащего пищей для рыб, требуется некоторое время [Филатов, 2015; Кулик и др., 2019]. Текущую температуру обозначили как t , температуры с лагами как t_{lag} , где lag означает задержку в сутках и принимает значение от 1 до 7. Аналогичным образом пространственный градиент обозначили как t_{front} и t_{front_lag} , суточный градиент — как t_{grad} и t_{grad_lag} .

Под промысловой обстановкой понимали набор условий окружающей среды и наличие либо отсутствие промыслового объекта в некоторой точке акватории. Промысловая обстановка в некоторой точке в определенный момент благоприятна, если все ее компоненты лежат в областях благоприятных значений [Бочаров, 1993]. В качестве индикатора участков с благоприятной промысловой обстановкой использовали судовые суточные донесения по материалам промысловой статистики из Отраслевой системы мониторинга Центра системы мониторинга рыболовства и связи [Пырков и др., 2015]. Отбирали позиции судов из района промысла со статусом «на лову» и скоростью 3–5 уз, что характерно для промысловых тралений. Участки промысла оконтуривали, используя алгоритм ядерной плотности [Scales et al., 2017] (рис. 1, А). Ячейки сетки с вероятностью встретить промысловое судно, превышающей 0,5, помечали как благоприятные, присваивая им значение 1. Прочие ячейки считали неблагоприятными и присваивали им значение 0 (рис. 1, Б).

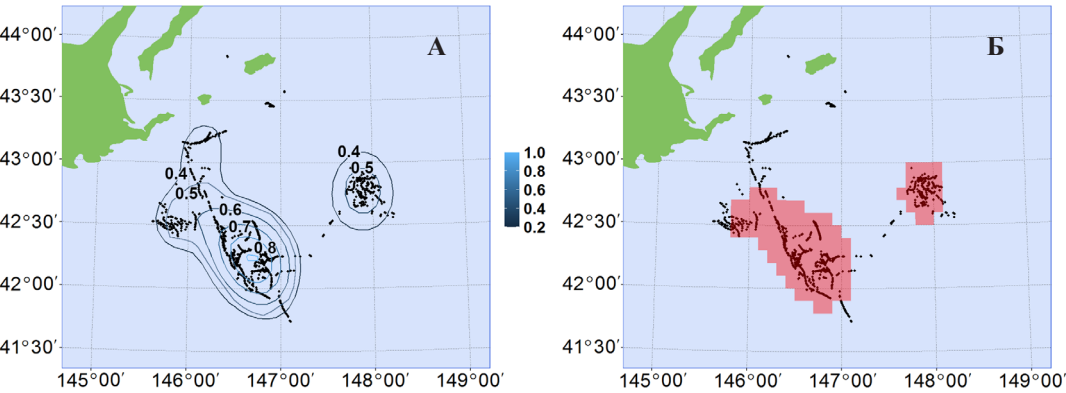


Рис. 1. Маркировка участков с благоприятной промысловой обстановкой. А: *изолинии* — значения ядерной плотности; Б: *полигоны* — участки со значением ядерной плотности, превышающим 0,5. Точки — треки промысловых судов

Fig. 1. Favorite areas for chub mackerel fishery. А: *isolines* — kernel density estimation (KDE); Б: *polygons* — areas with KDE > 0.5, considered as the areas favorable for chub mackerel fishery; *point lines* — tracks of fishing vessels

Таким образом, локализацию участков с благоприятной промысловой обстановкой свели к решению задачи бинарной классификации. Для решения этой задачи использовали модификацию алгоритма градиентного бустинга, реализованного в библиотеке LightGBM — Light Gradient Boosting Machine [Ke et al., 2017].

Сущность алгоритма градиентного бустинга заключается в последовательном применении решающего дерева к набору данных и результатам предыдущей классификации. Как все древовидные алгоритмы, LightGBM имеет возможность ранжировать признаки по степени значимости для разделения классов.

Для контроля качества обучения использовали несколько принятых в методологии машинного обучения метрик. Метрики выводятся из матрицы ошибок, характеризующей различные типы ошибок, возвращаемых в результате работы алгоритма [Бринк и др., 2017] (табл. 1).

Применительно к прогнозированию участков акватории с благоприятной промысловой обстановкой матрице ошибок может быть дана геометрическая интерпретация (рис. 2).

Точность (Ассигасу) Ac — отношение верно классифицированных ячеек сетки к их общему количеству в наборе данных:

$$Ac = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Таблица 1

Матрица ошибок для бинарной классификации

Table 1


Confusion matrix for binary classification

	$y = 1$	$y = 0$
$\hat{y} = 1$	TP	FP
$\hat{y} = 0$	FN	TN

Примечание. y — истинное значение класса; \hat{y} — оценка алгоритма на основе совокупности признаков; TP (true positive) — число верно определенных объектов, относящихся к классу 1; FN (false negative) — число объектов, ошибочно отнесенных к классу 0; FP (false positive) — число объектов, ошибочно отнесенных к классу 1; TN (true negative) — число объектов, верно отнесенных к классу 0.

Рис. 2. Геометрическая интерпретация матрицы ошибок для бинарной классификации

Fig. 2. Geometry interpretation of confusion matrix for binary classification



Этот показатель малоэффективен при высокой неравномерности долей классов в наборе данных. Например, на рассматриваемой нами акватории участки с благоприятной промысловой обстановкой могут занимать 1–2 % или даже десятые доли процента. При таких условиях, даже не предсказав благоприятные участки вообще, алгоритм покажет точность, превышающую 90 %.

Специфичность (Precision) P — показатель, характеризующий положительную прогностическую ценность. По его величине можно судить, насколько отчетливо выделяются положительные классы:

$$P = \frac{TP}{TP + FP}. \quad (2)$$

Чувствительность (Recall) R — показатель, характеризующий потерю положительных классов алгоритмом:

$$R = \frac{TP}{TP + FN}. \quad (3)$$

Описанные метрики могут иметь неодинаковое значение в разных ситуациях. Например, для отдельного судна важно знать, что на конкретном участке акватории будет с высокой вероятностью встречен промысловый объект. Большое значение ложнонегативных оценок для него будет гораздо менее критично, чем большое число ложнопозитивных. Таким образом, с точки зрения отдельного судна важнее будет высокое значение метрики P . Для промысловой флотилии, напротив, важно охватить как можно больше промысловых скоплений. Большое число ложнопозитивных значений может быть скомпенсировано за счет оконтуривания скоплений в процессе поиска, площадь которого будет в любом случае значительно сокращена. Таким образом, с точки зрения группы судов важнее высокое значение показателя R , и оно тем более критично, чем флотилия больше.

Специфичность и чувствительность могут быть объединены в F -метрику, являющуюся их гармоническим средним:

$$F = \frac{2PR}{P + R}. \quad (4)$$

F -метрика достигает максимума при специфичности и чувствительности, равным единице, и близка к нулю, если один из аргументов близок к нулю.

Еще одним способом оценить модель в целом является площадь под кривой ошибок (Receiver Operating Characteristic curve, ROC) Area Under the Curve, AUC . ROC строится в координатах True Positive Rate (TPR) и False Positive Rate (FPR), в пределах от (0,0) до (1,1). TPR идентичен чувствительности, а FPR показывает, какую долю из объектов класса 0 алгоритм предсказал неверно:

$$FPR = \frac{FP}{FP + TN}. \quad (5)$$

AUC может принимать значения от 0 до 1. Если этот показатель принимает значение 1, то алгоритм выполнил классификацию идеально. При $AUC = 0,5$ результат классификации идентичен случайному угадыванию, т.е. классификация не выполнена. Если AUC меньше 0,5, алгоритм работает с точностью до наоборот.

Для контроля качества обучения набор данных разделяли на обучающий и тестовый, в случайном порядке отбирая из исходного набора 10 % наблюдений. Под наблюдениями в данном случае понимаются сутки промысла. В обучающем наборе выполняли прореживание строк с отрицательными классами, чтобы скомпенсировать высокую неравномерность долей классов и избежать переобучения модели. Оптимизация модели выполнялась по значению AUC .

После обучения модели выполняли прогноз на тестовой выборке и сравнивали прогнозные значения с фактическими, рассчитывая вышеописанные метрики.

Важнейшим этапом в машинном обучении является валидация модели. Валидация выполняется на данных, которые не входили в обучающий набор. В связи с тем что промысел скумбрии был возобновлен относительно недавно, валидацию модели выполняли на данных, получаемых в ходе пелагической путины 2020 г., проходившей с конца июля по начало декабря. Способом, описанным выше, оконтуривали благоприятные для промысла участки и сравнивали их с прогнозными, используя метрики 1–4 и AUC . Вычисляли метрики посуточно и затем по итогам путины в целом. Кроме того, используя данные позиционирования судов, рассчитывали суточное изъятие скумбрии на участках автатории, определенных как благоприятные. Отношение этого изъятия к суточному изъятию послужило дополнительным показателем качества оперативного прогноза.

Использовали следующее программное обеспечение:

язык сценариев R*;

LightGBM — библиотека, реализующая алгоритм градиентного бустинга;

lightgbm — интерфейс к библиотеке LightGBM;

data.table — пакет для языка сценариев R, обеспечивающий работу с большими массивами данных;

tidyr — пакет для представления данных в различной форме;

raster — работа с регулярными сетками, моделирующими географические данные;

maptools — пакет для чтения векторных картографических данных;

caret — пакет, интегрирующий инструменты для машинного обучения, использовался для расчета метрик;

grec — пакет для расчета градиентов по алгоритму Белкина;

RMySQL — интерфейс для работы с СУБД MySQL, использовался для доступа к данным отраслевой системы «Мониторинг»;

ggplot2 — графический вывод графиков и географических карт.

Результаты и их обсуждение

На первом этапе выполнили обучение с использованием всех переменных, после чего предварительно оценили прогностическую ценность переменных (рис. 3).

* Team R.C. R: A Language and Environment for Statistical Computing. Vienna, Austria: R Foundation for Statistical Computing, 2014.




Рис. 3. Вклад переменных в прогнозирование благоприятной промысловой обстановки
Fig. 3. Contribution of variables to formation of favorable conditions for chub mackerel fishery

Наибольший вклад в прогнозирование промысловой обстановки вносят географические координаты и день года, что говорит о существовании устойчивых пространственно-временных шаблонов. Среди гидрологических факторов ведущее значение отмечается для суточных градиентов температур, а также температур и пространственных градиентов с большими лагами. Температуры с небольшими лагами имеют наименьший вклад. Это можно объяснить тем, что для формирования скоплений кормовых организмов требуется некоторое время [Филатов, 2015; Кулик и др., 2019].

Для дальнейшей работы отбросили переменные с лагами 1–3 и выполнили повторное обучение модели. Было достигнуто достаточно высокое качество обучения на тестовой выборке: $Ac = 0,88$, $P = 0,27$, $R = 0,97$, $F = 0,42$, $AUC = 0,93$.

Расчет метрик, выполненный посуточно, показал взаимосвязь между качеством прогноза и интенсивностью подходов скумбрии (рис. 4). Это, вероятно, обусловлено тем, что в эти сроки промысел шире распространяется по акватории, что позволяет более корректно отразить взаимосвязь гидрологических условий и распределения промыслового флота. Кроме того, данный период более полно обеспечен данными.




Рис. 4. Изменение качества прогноза в течение путины
Fig. 4. Changes in the forecast quality during the season

В табл. 2 приведены метрики качества обучения для всего рассмотренного периода и для периода наиболее интенсивного промысла в водах Российской Федерации в 2020 г.

Таблица 2

Метрики качества обучения в различные периоды

Table 2

Learning performance metrics for certain periods		
Показатель	Весь период	01.10–15.11
Ac	0,97	0,97
P	0,22	0,36
R	0,33	0,52
F	0,27	0,43
AUC	0,69	0,75

Снижение показателей качества обучения во второй половине ноября объясняется тем, что в этот период происходит смещение скоплений скумбрии в исключительную экономическую зону Японии. Сведений о промысловом усилии по данному району у нас недостаточно, поэтому у модели снижаются значения метрик качества обучения. Кроме того, следует отметить, что данные судовых суточных донесений далеко не всегда передаются именно из района промысла. Наконец, судно вовсе не обязательно будет работать именно на том участке, где гидрологические условия наиболее благоприятны. К тому же качество прогноза непосредственно связано с методикой выделения благоприятных участков акватории. На рис. 5 приводятся примеры карт, на которые нанесены прогнозы благоприятной промысловой обстановки и фактическое размещение промысловых судов по данным судовых суточных донесений тремя сутками позже.

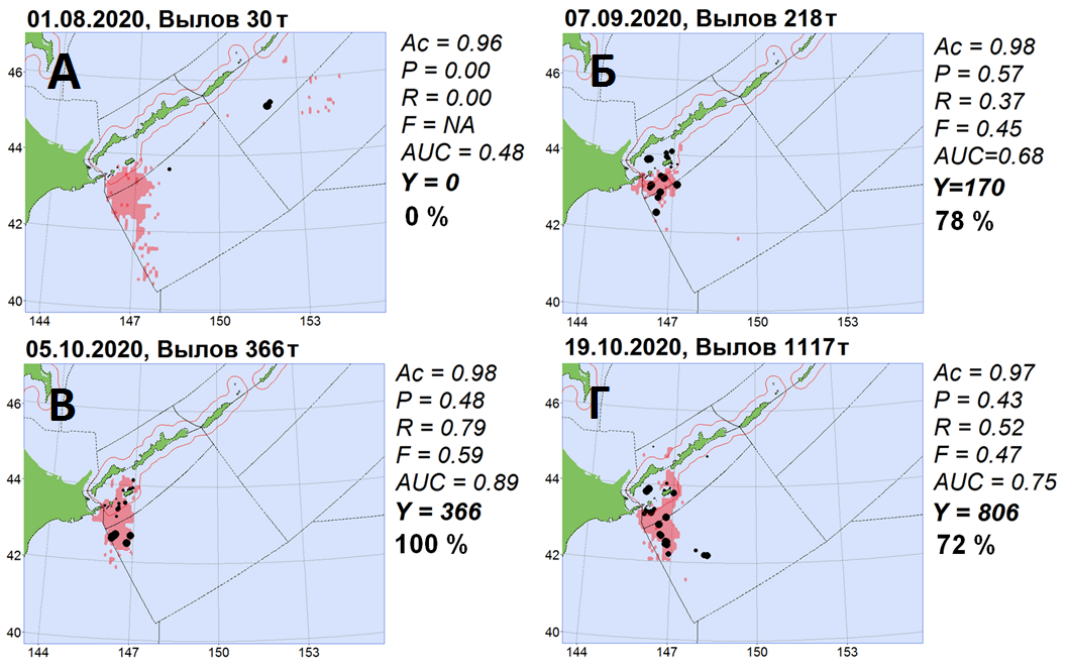


Рис. 5. Прогнозы благоприятной промысловой обстановки (полигон, выделен красным) и фактическое размещение судов (точки) при промысле скумбрии (условные обозначения смотри в тексте)

Fig. 5. Forecasts of favorable conditions for chub mackerel fishery (polygons) and actual locations of fishing vessels (points)

На рис. 5 Y — вылов на участке, определенном как благоприятный для промысла. В процентах обозначена доля вылова на таком участке от общего вылова за сутки. Рис.

5 (А) соответствует ситуации, когда скумбрия в районе промысла встречается единично и промысловый флот ориентирован на добычу сардины иваси. На рис. 5 (Б) изображен один из первых значимых уловов скумбрии. Рис. 5 (В) иллюстрирует ситуацию, близкую к середине массового хода, 5 (Г) отображает один из самых крупных суточных уловов, а также ситуацию, в которой АУС близок к среднему за период значению.

На рис. 5 видно, что даже если фактический промысловый район не вполне совпадает с прогнозным, промысловые скопления находятся поблизости. В конечном итоге большая часть промыслового усилия в 2020 г. приходилась на предсказанные участки. За весь период промысла на этих участках было изъято около 75 % всей скумбрии, за период интенсивного промысла — около 84 % (рис. 6).

Таким образом, использование предложенной методики в любом случае сузит район поиска и связанные с поиском непроизводительные расходы.




Рис. 6. Суточный вылов в Южно-Курильской зоне (чёрная сплошная линия) и на предсказанных участках (красная пунктирная линия)

Fig. 6. Dynamics of chum mackerel daily catch in the entire South Kuril fishery district (black solid line) and in the predicted areas with favorable conditions for fishery (red dashed line)

Несмотря на наличие нескольких существенных ошибок (16, 17 октября и 12 ноября), в целом наблюдалось хорошее соответствие между прогнозом и фактическим размещением промыслового усилия.

Заключение

Использование машинного обучения для информационного сопровождения промысла скумбрии показало хорошие результаты. Участки, на которых прогнозировалась благоприятная промысловая обстановка, совпадают с участками, на которых впоследствии работали промысловые суда. При этом наибольшие уловы, за редким исключением, наблюдаются именно на предсказанных участках. Вместе с тем качество оперативного прогноза может быть существенно улучшено. Для этого необходимо, во-первых, дополнить обучающий набор данными из японской промысловой зоны и, во-вторых, более тщательно подойти к методике выделения участков с благоприятной промысловой обстановкой.

Подытоживая вышесказанное, можно констатировать следующее.

Выделенные по результатам предварительного анализа наиболее значимые для прогноза переменные позволили строить прогноз с заблаговременностью в трое суток.

Достигнуты высокие значения показателей качества обучения на тестовом наборе данных.

Валидация модели показала взаимосвязь между качеством прогноза и интенсивностью подхода скумбрии в район промысла.

На участках, определенных моделью как благоприятные, добыто 75 % общего вылова скумбрии за весь период наблюдений и 84 % в период наибольшей интенсивности промысла.

Благодарности

Авторы выражают благодарность сотрудникам ТИНРО В.Н. Филатову за рекомендации по работе с гидрологическими материалами и В.В. Кулику за методическую помощь.

Финансирование работы

Исследование не имело спонсорской поддержки.

Соблюдение этических стандартов

Настоящая статья не содержит каких-либо исследований с использованием животных в качестве объектов. Библиографические ссылки на все использованные в работе данные других авторов оформлены в соответствии с правилами данного издания. Авторы заявляют, что у них нет конфликта интересов.

Информация о вкладе авторов

Э.П. Черниенко — сбор материала, систематизация первичных данных, текст всех разделов статьи, И.С. Черниенко — оценка параметров модели, текст всех разделов статьи.

Список литературы

- Беляев В.А.** Экосистема зоны течения Куроисио и ее динамика : моногр. — Хабаровск : Хабаровское книжное издательство, 2003. — 382 с.
- Бочаров Л.Н.** Информационная технология краткосрочного промыслового прогнозирования : дис. ... д-ра техн. наук в форме научного доклада. — Владивосток : ИАПУ ДВО РАН, 1993. — 68 с.
- Бочаров Л.Н.** Системный анализ в краткосрочном рыбопромысловом прогнозировании : моногр. — Л. : Наука, 1990. — 208 с.
- Бринк Х., Ричардс Д., Феверолф М.** Машинное обучение : моногр. — СПб. : Питер, 2017. — 336 с.
- Кулик В.В., Байталюк А.А., Катугин О.Н., Устинова Е.И.** Моделирование распределения уловов сайры в связи с факторами окружающей среды // Изв. ТИНРО. — 2019. — Т. 199. — С. 193–213. DOI: 10.26428/1606-9919-2019-199-193-213.
- Пырков В.Н., Солодилов А.В., Дегай А.Ю.** Создание и внедрение новых спутниковых технологий в системе мониторинга рыболовства // Современные проблемы дистанционного зондирования Земли из космоса. — 2015. — Т. 12, № 5. — С. 251–262.
- Филатов В.Н.** Миграции и формирование скоплений массовых пелагических гидробионтов (на примере тихоокеанской сайры) : моногр. — Ростов н/Д : ЮНЦ РАН, 2015. — 168 с.
- Шунтов В.П.** Биология дальневосточных морей России : моногр. — Владивосток : ТИНРО-центр, 2001. — Т. 1. — 580 с.
- Belkin I.M., O'Reilly J.E.** An algorithm for oceanic front detection in chlorophyll and SST satellite imagery // J. Mar. Syst. — 2009. — Vol. 78, № 3. — P. 319–326. DOI: 10.1016/j.jmarsys.2008.11.018.
- Ke G., Meng Q., Finley T. et al.** LightGBM: a highly efficient gradient boosting decision tree // Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS 17). — Red Hook, NY, USA : Curran Associates Inc., 2017. — P. 3149–3157.
- Scales K.L., Hazen E.L., Maxwell S.M. et al.** Fit to predict? Eco-informatics for predicting the catchability of a pelagic fish in near real time // Ecol. Appl. — 2017. — Vol. 27, Iss. 8. — P. 2313–2329. DOI: 10.1002/eap.1610.
- Usui N., Ishizaki S., Fujii Y. et al.** Meteorological Research Institute multivariate ocean variational estimation (MOVE) system: Some early results // Adv. Sp. Res. — 2006. — Vol. 37, № 4. — P. 806–822. DOI: 10.1016/j.asr.2005.09.022.

Usui N., Wakamatsu T., Tanaka Yu. et al. Four-dimensional variational ocean reanalysis: a 30-year high-resolution dataset in the western North Pacific (FORA-WNP30) // *J. Oceanogr.* — 2017. — Vol. 73, Iss. 2. — P. 205–233. DOI: 10.1007/s10872-016-0398-5.

References

Belyaev, V.A., *Ekosistema zony techeniya Kuroshio i yeye dinamika* (Ecosystem of the Kuroshio Current Area and its Dynamics), Khabarovsk: Khabarovskoye knizhnoye izdatel'stvo, 2003.

Bocharov, L.N., Information technology of short-term field forecasting, *Dr. Tech. Sci. Dissertation in the form of a scientific report*, Vladivostok: IAPU DVO RAN, 1993.

Bocharov, L.N., *Sistemnyy analiz v kratkosrochnom rybopromyslovom prognozirovanii* (System analysis in short-term fishing forecasting), Leningrad: Nauka, 1990.

Brink, H., Richards, J.W., and Fetherolf, M., *Mashinnoye obucheniye* (Real-World Machine Learning), St. Petersburg: Piter, 2017.

Kulik, V.V., Baitaliuk, A.A., Katugin, O.N., and Ustinova, E.I., Modeling distribution of saury catches in relation with environmental factors, *Izv. Tikhookean. Nauchno-Issled. Inst. Rybn. Khoz. Okeanogr.*, 2019, vol. 199, pp. 193–213. doi 10.26428/1606-9919-2019-199-193-213

Pyrkov, V.N., Solodilov, A.N., and Degai, A.Yu., Development and implementation of new satellite techniques in the fishery monitoring system, *Sovrem. Probl. Distantionnogo Zondirovaniya Zemli Kosmosa*, 2015, vol. 12, no. 5, pp. 251–262.

Filatov, V.N., *Migratsii i formirovaniye skopleniy massovykh pelagicheskikh gidrobiontov (na primere tikhookeanskoy sayry)* (Migrations and the formation of clusters of massive pelagic aquatic organisms (on the example of Pacific saury)), Rostov-on-Don: Yuzhn. Nauchn. Tsentr, Ross. Akad. Nauk, 2015.

Shuntov, V.P., *Biologiya dal'nevostochnykh morei Rossii* (Biology of the Far Eastern Seas of Russia), Vladivostok: TINRO-Tsentr, 2001, vol. 1.

Belkin, I.M. and O'Reilly, J.E., An algorithm for oceanic front detection in chlorophyll and SST satellite imagery, *J. Mar. Syst.*, 2009, vol. 78, no. 3, pp. 319–326. doi 10.1016/j.jmarsys.2008.11.018

Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., and Liu, T.-Y., LightGBM: a highly efficient gradient boosting decision tree, *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS 17)*, Red Hook, NY, USA: Curran Associates Inc., 2017, pp. 3149–3157.

Scales, K.L., Hazen, E.L., Maxwell, S.M., Dewar, H., Kohin, S., Jacox, M.G., Edwards, C.A., Briscoe, D.K., Crowder, L.B., Lewison, R.L., and Bograd, S.J., Fit to predict? Eco-informatics for predicting the catchability of a pelagic fish in near real time, *Ecol. Appl.*, 2017, vol. 27, no. 8, pp. 2313–2329. doi 10.1002/eap.1610

Usui, N., Ishizaki, S., Fujii, Y., Tsujino, H., Yasuda, T., and Kamachi, M., Meteorological Research Institute multivariate ocean variational estimation (MOVE) system: Some early results, *Adv. Sp. Res.*, 2006, vol. 37, no. 4, pp. 806–822. doi 10.1016/j.asr.2005.09.022

Usui, N., Wakamatsu, T., Tanaka, Yu., Hirose, N., Toyoda, T., Nishikawa, S., Fujii, Y., Takatsuki, Y., Igarashi, H., Nishikawa, H., Ishikawa, Y., Kuragano, T., and Kamachi, M., Four-dimensional variational ocean reanalysis: a 30-year high-resolution dataset in the western North Pacific (FORA-WNP30), *J. Oceanogr.*, 2017, vol. 73, no. 2, pp. 205–233. doi 10.1007/s10872-016-0398-5

Team, R.C., *R: A Language and Environment for Statistical Computing*, Vienna, Austria: R Foundation for Statistical Computing, 2014.

Поступила в редакцию 19.03.2021 г.

После доработки 27.04.2021 г.

Принята к публикации 21.05.2021 г.