



## Среда обитания водных биологических ресурсов

# Использование алгоритмов искусственного интеллекта при анализе особенностей сезонной изменчивости верхнего квазиоднородного слоя вод Баренцева моря

В.А. Ившин

Полярный филиал ГНЦ РФ ФГБНУ «ВНИРО» («ПИНРО») им. Н.М. Книповича, ул. Академика Книповича, 6, г. Мурманск, 183038

E-mail: ivshin@pinro.vniro.ru

SPIN-код: В.А. Ившин 3102-7538

**Целью работы** являлось на алгоритмах искусственного интеллекта (ИИ) и машинного обучения (МО) выявление особенностей сезонных изменений верхнего квазиоднородного слоя (ВКС) вод Баренцева моря в период 1993–2020 гг.

**Материалом исследования** послужили массивы данных ВКС на акватории Баренцева моря, представленные Службой мониторинга морской среды Copernicus за период 1993–2020 гг.

**Используемые методы:** кластерный анализ, машинное обучение, метод ближайшего соседа (kNN).

**Результаты:** на основе моделирования с использованием алгоритмов искусственного интеллекта и машинного обучения проведена классификация полей распределения верхнего квазиоднородного слоя по особенностям их сезонного состояния. Выявлено, что зимний период года определяется двумя классами (повышенными/пониженными значениями толщины слоя); третий класс включает в себя весенний и осенний сезоны, в которых распределения ВКС близки друг другу; четвёртая группа соотносится к летнему сезону (июнь–сентябрь), когда развитие верхнего квазиоднородного слоя минимально в течение года.

**Практическая значимость:** результаты, полученные в работе, позволят лучше понимать протекающие гидрофизические процессы в Баренцевом море и в дальнейшем могут использоваться как ряды независимых переменных в изучении функционирования экосистемы Баренцева моря, а также в оценках запаса и прогноза вылова промысловых гидробионтов.

**Ключевые слова:** Баренцево море, ВКС, машинное обучение, kNN.

## Using artificial intelligence algorithms in the investigation of mixed layer depth seasonal changes in the Barents Sea

Victor A. Ivshin

Polar branch of VNIRO (N.M. Knipovich «PINRO»), 6, Academician Knipovich St., Murmansk, 183038, Russia

**The study aims at** discovering features of seasonal changes in the mixed layer depth (MLD) of the Barents Sea in 1993–2020.

Charts of the distribution of the MLD in the Barents Sea in 1993–2020 provided by the Copernicus Marine Service were used as the material of the study.

**Methods of the study:** cluster analysis, machine learning, neuronal networks, the nearest neighbor method (kNN).

**Results.** Classification of the data sets of the MLD distribution according to their seasonal features was carried out based on the modelling using AI algorithms and machine learning. It was concluded that winter is specified by two classes (increased/decreased values of the layer thickness). The third class includes spring and autumn when distributions of the MLD are close to one another, and the fourth class comprises summer (June–September) when the MLD grows very slowly.

**Practical relevance.** The results will contribute to a better understanding of the hydrophysical processes of the Barents Sea and can further be used as series of independent variables to study the Barents Sea ecosystem and to estimate a stock and a catch forecast of commercial aquatic organisms.

**Keywords:** Barents Sea, MLD, machine learning, kNN.

## ВВЕДЕНИЕ

Одной из наиболее важных характеристик, определяющих режимные условия моря, является толщина верхнего квазиоднородного слоя, в границах которого температура, солёность и плотность вод практически не изменяются по вертикали. Однородность

гидрофизических параметров этого слоя достигается в результате турбулентного и конвективного перемешивания. Через ВКС происходит перенос массы, импульса и энергии, которые являются источником движений в океане, и толщина этого слоя определяет его теплоёмкость и механическую инерцию при взаимодействии с атмосферой [Montégut et al., 2004].

С конца XX века в Баренцевом море наблюдаются существенные климатические изменения, которые наиболее ярко проявляются в увеличении теплосодержания воздушных и водных масс, а также в сокращении акваторий, покрытых льдом [Watelet et al., 2020; Трофимов и др., 2018; Ingvaldsen et al., 2021]. Активное таяние льда в начальный период потепления привело к достаточно большому расслоению вод по вертикали, увеличению градиента плотности на этих участках. В последние годы в море отмечается уменьшение стратификации за счёт ослабления притока пресных вод, при этом поступление тепла из атмосферы остаётся повышенным по сравнению с начальным периодом потепления [Hordoir et al., 2022].

ВКС является важным звеном общей цепи экосистемы Мирового океана. В этом слое, наряду с физическими, происходят активные гидрохимические и гидробиологические процессы, которые оказывают значимое влияние на изменчивость общей биопродуктивности вод [Falkowski et al., 1998]. Изучение особенностей распределения биогенных элементов, хлорофилла, планктона, пелагических рыб, а также процессов взаимодействия океан-атмосфера требуют чёткого представления о параметрах ВКС, его сезонной и межгодовой изменчивости [Ившин, 2004; Лучин, 2019; Sandø et al., 2021].

Изучению изменчивости толщины ВКС в северных морях посвящено множество работ российских и зарубежных авторов [Калацкий, 1978; Аверкиев, 1984; Carton et al., 2008; Peralta-Ferriz, Woodgate, 2015]. Эти работы заложили фундамент в понимание процессов физической природы формирования, существования и разрушения ВКС. С приходом новых технологий сбора, обработки и анализа численных данных, а также в условиях изменения климата возникает необходимость пересмотреть этот важный океанографический параметр с целью выявления его отдельных и общих гидрофизических особенностей.

Стремительный рост информационных массивов приводит к появлению новых методов обработки и анализа данных, к которым, в свою очередь, необходимо отнести алгоритмы искусственного интеллекта в разных областях океанографии [Колесников и др., 2018; Ahmad H., 2019, Кривогуз и др., 2020; Захаржевский и др., 2021; Dong et al., 2022; Rubbens et al., 2023; Miller et al., 2024], в т. ч. и при изучении особенностей изменчивости толщины ВКС [Dallas et al., 2021; Hua et al., 2024].

Появление массивов данных с достаточно большим временным периодом и детальным пространственным разрешением предоставляет возможность подробно рассмотреть внутригодовую изменчивость

толщины ВКС, актуальность изучения которой не вызывает сомнения.

Цель работы — на алгоритмах ИИ и МО выделить основные особенности сезонной изменчивости ВКС на акватории Баренцева моря за период 1993–2020 гг.

## МАТЕРИАЛ И МЕТОДИКА

Исходными данными для проведения исследований послужили информационные массивы распределения толщины ВКС, предоставляемые сервисом CMEMS<sup>1</sup> (Copernicus Marine environment monitoring service). Расчётные поля формировались на основе ежемесячных данных<sup>2</sup> глобального моделирования Мирового океана и были представлены в формате netCDF. Анализировался участок большей части акватории Баренцева моря в координатах 67–81° с. ш. и 20–60° в. д. с шагом 0,25° по широте и долготе, включающий 7461 узлов координатной сетки (рис. 1).

Рассматриваемый массив охватывал период времени с января 1993 г. по декабрь 2020 г. и включал в себя 336 среднемесячных полей ВКС.

Основные расчёты и анализ полученных результатов производились в свободно распространяемой системе визуального программирования с открытым кодом *Orange 3.35*.<sup>3</sup> Существенным достоинством данной среды является наличие значительного количества готовых модулей по работе с большими массивами данных.

Для решения основной цели работы необходимо было создать модель, способную самостоятельно определять к какому сезону годового цикла относится данное распределение ВКС. Такое моделирование возможно на алгоритмах ИИ и МО, где в виде обучающего материала может служить корректное, объективное разделение полей ВКС по отдельным группам с характерными признаками распределения исследуемого параметра внутри каждого класса.

В соответствии с вышесказанным, на начальном этапе формировалась задача построения программного модуля для проведения кластеризации исходных данных. Рассматривался массив данных, состоящий из 336×7461 значений ВКС, т. е. каждый месяц представлялся переменными, соответствующими количеству узлов сеточной области. Оптимизация дан-

<sup>1</sup> Copernicus Marine Service. <https://marine.copernicus.eu/> 19.10.2023.

<sup>2</sup> Global Ocean Ensemble Physics Reanalysis. [https://data.marine.copernicus.eu/product/GLOBAL\\_REANALYSIS\\_PHY\\_001\\_031/download?dataset=global-reanalysis-phy-001-031-grepu2-monthly](https://data.marine.copernicus.eu/product/GLOBAL_REANALYSIS_PHY_001_031/download?dataset=global-reanalysis-phy-001-031-grepu2-monthly) 19.10.2023

<sup>3</sup> Orange. Data Mining Fruitful and Fun. <https://orangedatamining.com/> 19.10.2023.

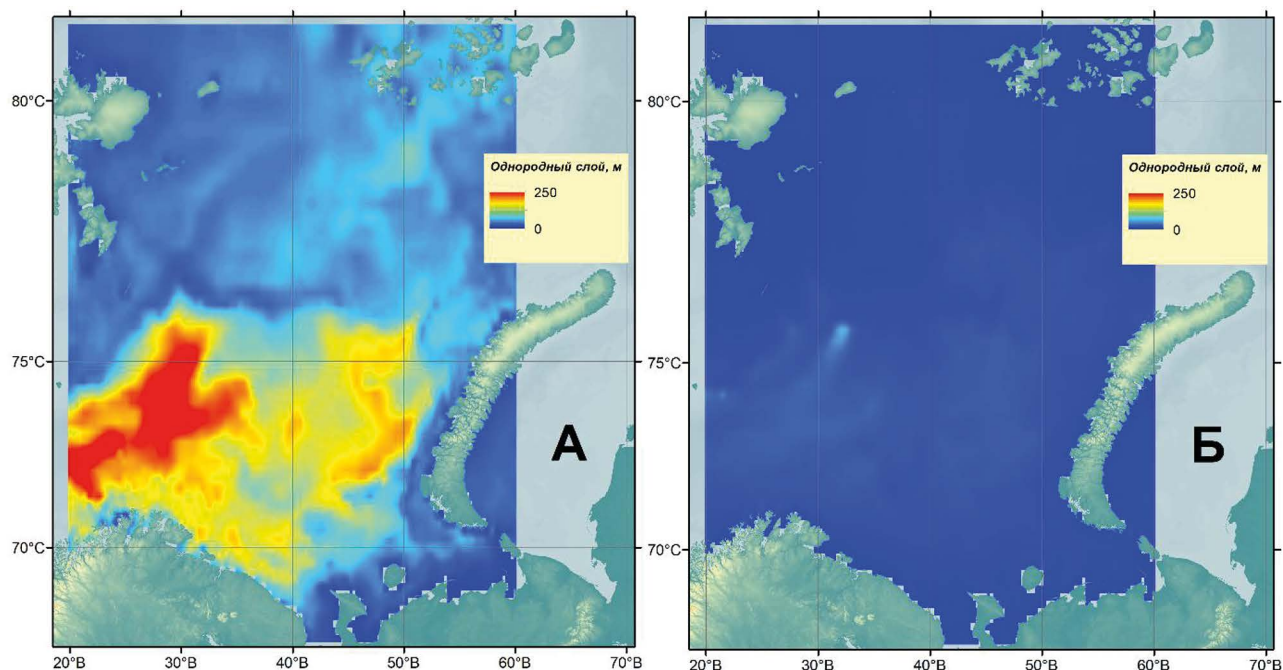


Рис. 1. Среднемесячное распределение верхнего квазиоднородного слоя в январе 1993 г. (А) и июне 2020 г. (Б)

Fig. 1. Monthly mean distribution of the MLD in January in 1993 (A) and June 2020 (B)

ных осуществлялась на основе алгоритма стохастического вложения соседей с  $t$ -распределением –  $t$ -SNE ( $t$ -distributed Stochastic Neighbor Embedding), особенностью которого является уменьшение размерности рассматриваемых параметров, где многомерное распределение переменных рассматривается в двумерном пространстве посредством их распределения вероятностей. Выбор метода  $t$ -SNE обосновывался на возможности алгоритма сохранять локальную и глобальную структуру данных [van der Maaten, Hinton, 2008] и получать надёжную оценку на большом количестве переменных [Kobak, Verens, 2019].  $t$ -SNE также отображает данные в более понятном визуальном формате, что помогает формулировать выводы и принятие решений [Balamurali, Melkumyan, 2016].

Оптимизированные данные подвергались кластеризации на основе метода  $k$ -means [Hartigan, Wong, 1979; Чубукова, 2016], широко используемого в задачах океанографии и морской экологии [Rubbens et al., 2023]. Кластеризация проводилась с условием принудительного разделения переменных на четыре класса, в соответствии с общим количеством сезонов годового цикла. Такое количество сезонов в изучении изменчивости ВКС рассматривали ряд авторов [Somavilla et al., 2017; Hordoir et al., 2022]. Качество кластеризации данных оценивалось по величине силуэта кластера. Оценка силуэта – это мера того, насколько объект похож на свой собственный кластер по сравнению с другими кластерами. Величина силуэта, близкая к 1, ука-

зывает на то, что экземпляр данных находится близко к центру кластера, а экземпляры, имеющие оценки силуэта близкие к 0, находятся на границе кластера.<sup>4</sup>

На основе полученной целевой переменной из кластерного анализа проводилось машинное обучение по созданию модели, способной самостоятельно определять принадлежность распределения ВКС к тому или иному сезону. Исследуемые поля толщины ВКС делились случайным образом в соотношении 70:30 на две группы – обучающую и тестовую выборки соответственно. Тестировалось пять различных алгоритмов: логистическая регрессия (LR), нейронная сеть (NN), случайный лес (RF), метод опорных векторов (SVM) и метод ближайшего соседа (kNN). В общем виде программный модуль, включающий блок кластерного анализа и машинного обучения, представлен на рис. 2.

Наглядным способом оценки проведённой классификации является анализ матрицы неточностей (Confusion Matrix) размерностью  $n \times n$ , где  $n$  – это число классов. Строки матрицы представляют классы исходной классификации, а столбцы – классы, полученные при работе исследуемого классификатора, при этом значения в ячейках соответствуют количеству произошедших событий (табл. 1).

Значения на главной диагонали представляют собой истинно положительные решения ( $TP$ ), т. е. коли-

<sup>4</sup> Orange. Silhouette Plot. <https://orangedatamining.com/widget-catalog/visualize/silhouetteplot/> 19.10.2023.

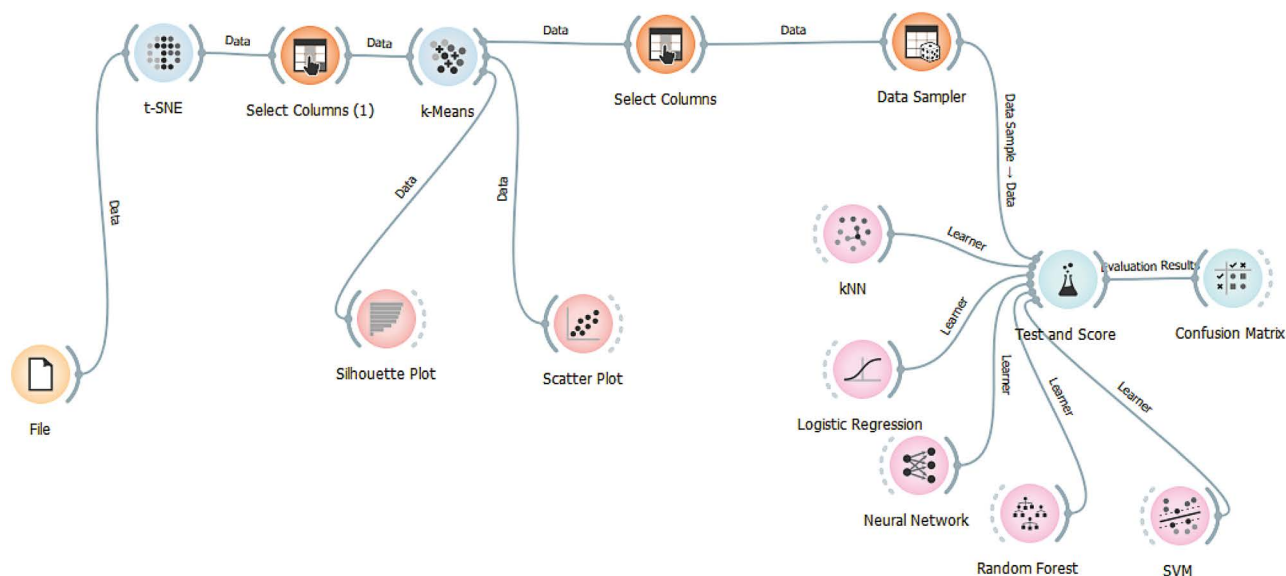


Рис. 2. Схема кластеризации и машинного обучения модели

Fig. 2. The algorithm clustering and machine learning models

Таблица 1. Идеализированное представление матрицы неточностей

Table 1. Idealized confusion matrix

Факт	Расчёт			
	C1	C2	C3	C4
C1	22	7	0	0
C2	5	17	4	0
C3	0	2	32	0
C4	0	0	0	24

чество правильно определённых классов классификатором. Сумма значений в столбце, не включающая в расчёт ячейку главной диагонали, является ложно положительной (*FP*) величиной, а сумма по строке (также без учёта ячейки главной диагонали) – ложно отрицательной (*FN*). Чем меньше сумма значений за пределами главной диагонали, тем лучше классификатор описал исходную классификацию. В конкретном случае (см. табл. 1) наилучшим образом описан класс «C4», а класс «C2» – плохо.

Качество работы классификатора определялось по численным величинам тестовых метрик. Самым простым показателем качества классификации может быть отношение правильно классифицированных объектов к общему их количеству, называемом точностью (*Accuracy*):

$$Accuracy = \frac{P}{N}, \quad (1)$$

где: *P* – количество правильных решений, а *N* – размер выборки.

Точностью в пределах класса (*Precision*) называют отношение правильно классифицированных объектов к общему числу объектов, которые классификатор отнёс к этому классу:

$$Precision = \frac{TP}{TP+FP}, \quad (2)$$

где: *TP* – истинно положительные решения; *FP* – ложноположительные решения.

Полнота (*Recall*) определяется как доля найденных классификатором объектов некоторого класса относительно всех объектов данного класса в тестовом наборе:

$$Recall = \frac{TP}{TP+FN}, \quad (3)$$

где *FN* – ложноотрицательные решения.

Для реальных данных и классификаторов часто нельзя одновременно добиться и высокой точности, и полноты. Для этого ввели производную характеристику, которую назвали *F-мера* [Герасименко, 2017]. *F-мера* – это гармоническое среднее между точностью и полнотой, представленное формулой:

$$F\text{-мера} = \frac{2 * Precision * Recall}{Precision + Recall}. \quad (4)$$

Среднее гармоническое обладает важным свойством – оно стремится к нулю, если хотя бы один из аргументов также стремится к нулю. Очевидно, что чем ближе точность и полнота к единице, тем лучше выбран и настроен классификатор.

Для каждого выделенного класса с использованием инструментов *ArcGIS 10.2* строились среднеголетние (за период 1993–2020 гг.) поля толщины ВКС.



При построении ледовых полей использовались данные<sup>5</sup> Норвежского Полярного института. Среднемесячное положение кромки льда определялось по его концентрации, соответствующей как минимум 50% частоты встречаемости для соответствующих месяцев, в период 1993–2022 гг.

## РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Толщина перемешанного верхнего слоя на разных участках моря имеет значительные колебания как по

пространству, так и по времени, при этом максимальные значения могут превосходить минимальные в десять раз и больше. По данным расчётов, среднемесячные значения полей толщины ВКС на рассматриваемом участке Баренцева моря представлены в табл. 2.

Из приведенной таблицы отчетливо видно, что квазиоднородный слой имеет наименьшую толщину в тёплое время года, максимального развития он достигает зимой. Весной и осенью ВКС имеет близкие численные значения и по своему развитию характеризуется этапом

Таблица 2. Среднемесячная толщина (м) ВКС Баренцева моря  
Table 2. Monthly mean thickness (m) of the MLD of the Barents Sea

Годы	Янв.	Фев.	Мар.	Апр.	Май	Июн.	Июл.	Авг.	Сен.	Окт.	Ноя.	Дек.	Среднее
2020	112.5	113.5	116.7	90.2	27.8	16.6	12.6	12.8	19.0	31.3	48.3	73.1	56.2
2019	119.7	131.9	119.3	85.9	45.6	18.1	13.1	17.1	22.4	39.6	67.0	91.3	64.3
2018	104.8	113.8	132.1	107.8	31.2	19.6	13.6	15.3	24.6	38.2	59.7	87.3	62.3
2017	108.8	113.5	114.4	107.2	66.5	20.3	11.8	14.1	21.4	30.6	53.0	80.7	61.8
2016	101.9	110.1	114.7	87.1	28.3	16.9	12.7	15.7	21.6	32.2	49.0	73.1	55.3
2015	101.3	114.4	101.9	67.2	33.0	15.6	14.6	14.1	22.0	35.7	55.3	81.1	54.7
2014	111.4	112.3	124.1	110.6	45.1	14.7	12.9	14.5	23.4	36.6	66.5	78.6	62.6
2013	121.9	123.4	140.6	93.9	21.5	14.4	11.8	13.0	20.5	39.1	66.2	99.5	63.8
2012	81.8	93.9	100.6	91.1	43.0	17.0	13.2	16.8	22.6	34.8	58.1	92.1	55.4
2011	106.9	119.2	112.1	65.6	32.8	13.7	12.9	12.9	15.3	28.5	48.7	59.0	52.3
2010	94.5	110.6	118.1	84.7	28.5	16.3	12.7	19.2	26.7	36.1	62.9	87.5	58.1
2009	86.9	104.0	103.2	96.9	39.3	17.0	14.4	13.4	20.9	33.6	44.8	72.2	53.9
2008	89.6	104.2	112.0	104.9	49.5	14.9	11.7	14.5	20.6	32.5	52.0	67.9	56.2
2007	96.7	116.0	95.1	90.7	48.2	16.2	12.4	13.7	20.5	32.7	51.5	72.7	55.5
2006	82.6	96.4	109.0	81.1	33.1	16.3	14.0	14.0	22.8	40.5	63.7	79.1	54.4
2005	86.0	98.0	109.0	88.4	38.0	14.5	12.0	12.6	20.6	34.2	48.3	64.5	52.2
2004	67.4	79.0	72.8	61.5	24.3	14.7	11.1	12.7	19.9	33.2	57.5	74.0	44.0
2003	81.5	76.8	81.1	59.2	28.4	13.3	11.0	11.8	17.5	27.1	38.5	54.4	41.7
2002	83.2	95.4	92.2	61.5	28.9	13.0	11.4	13.9	21.6	36.0	49.7	62.8	47.5
2001	75.1	87.0	94.6	76.3	26.8	13.0	11.9	14.0	17.6	30.7	53.5	63.9	47.0
2000	72.7	80.3	91.2	84.4	41.2	13.4	12.1	13.1	20.7	28.2	40.1	58.0	46.3
1999	69.3	80.4	80.0	73.0	37.6	13.7	11.7	13.7	19.6	32.5	45.8	55.5	44.4
1998	80.0	97.1	79.1	72.1	37.0	13.4	11.1	12.5	18.3	30.1	43.0	52.2	45.5
1997	87.5	91.2	88.8	86.3	28.6	15.1	12.9	13.5	17.3	29.2	43.5	61.8	48.0
1996	73.4	78.0	66.1	66.6	43.1	13.3	12.2	13.6	21.0	33.9	45.7	65.3	44.3
1995	71.1	84.1	86.7	63.4	31.5	14.7	13.3	15.2	23.5	37.7	63.4	76.7	48.5
1994	77.9	86.1	80.3	46.4	30.8	14.7	12.3	14.0	21.1	36.8	53.1	57.9	44.3
1993	89.7	94.5	93.0	79.3	33.5	14.3	12.1	13.0	18.7	33.8	48.4	60.6	49.2
Среднее	90.6	100.2	101.0	81.5	35.8	15.3	12.5	14.1	20.8	33.8	52.8	71.5	

<sup>5</sup> The marginal ice zone. <https://www.npolar.no/en/themes/the-marginal-ice-zone/> 19.10.2023.

перехода от зимы к лету и наоборот. Так, если летний сезон (наименьшая толщина) объективно выделить достаточно просто, то показать границы других весьма проблематично. В изменчивости среднегодовых значений отмечается некоторый прирост толщины слоя в последние рассматриваемые годы, который, в свою очередь, обуславливается повышенным его развитием в зимние месяцы (декабрь-апрель). С мая по ноябрь сохраняется некоторая стационарность изменений этого показателя.

Для объективного выделения границ сезонов ВКС использовались алгоритмы искусственного интеллекта, а в виде исходных данных для кластерного анализа среднемесячные значения распределения этого параметра в узлах регулярной сетки на рассматриваемой акватории.

Для понижения размерности исходных данных был использован алгоритм t-SNE, который визуализирует переменные в двумерной плоскости на основе t-распределенного стохастического внедрения соседей. Успешность работы этого инструмента во многом зависит от тонкой настройки его гиперпараметров и особенно от величины перплексии (Perplexity), которая контролирует ширину окна, используемого для вычисления сходства между точками [Kobak, Berens, 2019]. Обычно, для многих задач перплексию в t-SNE задают в диапазоне от 30 до 50 [Van der Maaten, Hinton, 2008; Kobak, Berens, 2019], тем не менее, у каждого набора данных могут быть свои отличительные особенности в структуре данных.

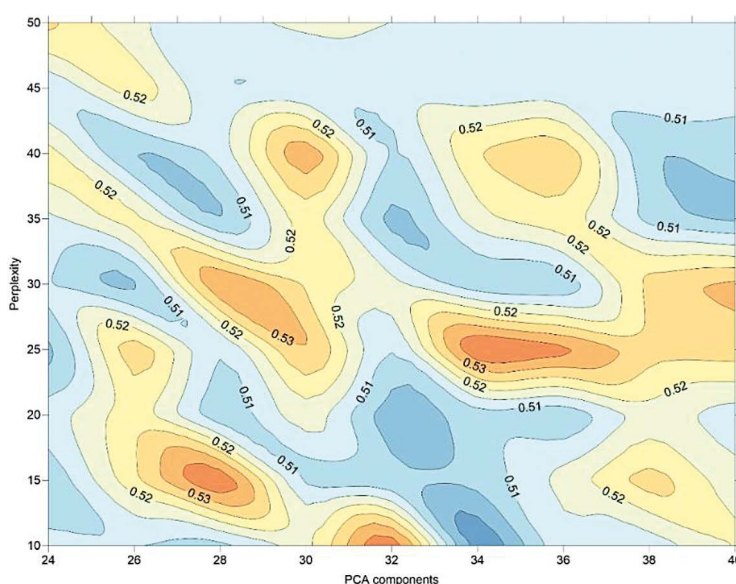
С целью получения оптимальной кластеризации данных были рассчитаны средние силуэты кластеров

для метода k-means при разных гиперпараметрах t-SNE (рис. 3).

Анализ полученных результатов показал, что наилучшие величины силуэтов кластеров метода k-means достигаются при величине перплексии 25 и 34 главных PCA-компонент. Отдельные высокие «ядра» силуэтов в плоскости PCA-компоненты-Перплексия отмечаются в координатах (28; 15) и (40; 30). Из приведенного рисунка видно, что область высоких силуэтов кластеров сосредоточена в диапазоне изменчивости перплексии от 25 до 30, что хорошо согласуется с выводами авторов [Van der Maaten, Hinton, 2008; Kobak, Berens, 2019].

На основе нового представления переменных (значения t-SNE\_x, t-SNE\_y) был проведен кластерный анализ методом k-means (случайная инициализация данных, 10 перезапусков, максимальное количество итераций – 300). Результаты кластеризации в пространстве t-SNE и в табличной форме представлены на рис. 4.

Из приведенного рис. 4 видно, что t-SNE достаточно корректно распределил поля ВКС в двумерном пространстве признаков, сохранив при этом локальную и глобальную структуру данных. Кластеризация методом k-means (см. рис. 4 Б) достаточно четко согласуется с характерными сезонными и межгодовыми особенностями толщины ВКС, полученным по осредненным значениям на рассматриваемом участке моря (см. табл. 2). При этом, в отдельный кластер (C2) входили летние месяцы, а также переходные периоды (весна и осень) состояния квазиоднородного слоя (C3). Холодный период года состоял из двух кластеров: в одном были сосредоточены месяцы с относительно умеренным развитием



**Рис. 3.** Распределение среднего силуэта кластеров от величины гиперпараметров t-SNE  
**Fig. 3.** The distribution of the average cluster silhouette from the value of t-SNE hyperparameters

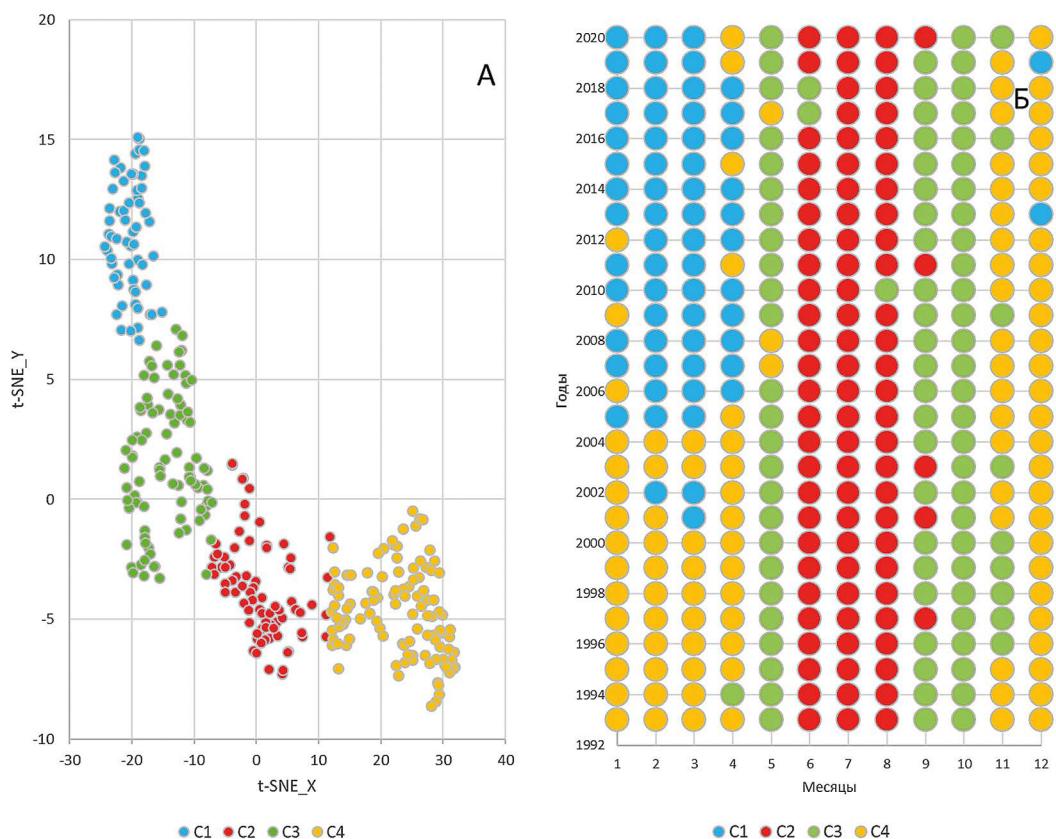


Рис. 4. Результаты кластеризации полей толщины ВКС: положение кластеров (C1-C4) в пространстве t-SNE (А) и в табличной форме (Б)

Fig. 4. Results of the clustering of the MLD: the position of clusters (C1-C4) in the t-SNE distribution (A) and in tabular form (B)

ВКС (C4), в другом – с повышенными его значениями (C1) (табл. 3).

Таблица 3. Отдельные характеристики выделенных кластеров

Table 3. Characteristics of the selected clusters

Параметр	C1	C2	C3	C4
Количество месяцев	61	86	89	100
Толщина ВКС, м	106,3	14,0	31,3	71,7
Силуэт	0,644	0,692	0,457	0,399

Как видно из табл. 3, в месяцы рассматриваемого периода наиболее часто (29,8% случаев) отмечаются распределения, соответствующие зимнему характеру распределения ВКС (C4). Приблизительно в равных долях (25,6 и 26,5% случаев) отмечается состояние однородного слоя для переходного и летнего сезонов (C2 и C3, соответственно), а самый немногочисленный (18,2% случаев) зимний период с повышенным развитием толщины ВКС (C1). Наиболее чётко в рассматриваемом пространстве были выделены кластеры C1 и C2 (величина силуэтов 0,644 и 0,692, соответственно).

Формирование целевой (зависимой) переменной заключалось в присвоении числовым полям распределения ВКС соответствующего имени кластера, полученного методом k-means. Поиск наилучшего классификатора по описанию полученной целевой переменной основывался на результатах работы пяти рассматриваемых методов: логистической регрессии, метода ближайшего соседа, нейронной сети, случайного леса и метода опорных векторов. Результаты качества их работы на обучающей выборке (70% случайных имиджей) представлены в табл. 4.

Таблица 4. Характеристики качества описания классификации

Table 4. Features of the classification description quality

Модель	Accuracy	F-мера	Precision	Recall
kNN	0,975	0,975	0,975	0,975
RF	0,936	0,937	0,937	0,936
SVM	0,911	0,910	0,915	0,911
NN	0,894	0,894	0,894	0,894
LR	0,886	0,885	0,885	0,886

Как видно из приведённой таблицы, наилучшим образом при описании целевой переменной справился метод ближайшего соседа (kNN). Максимальные значения точности (*Precision*) и полноты (*Recall*), а соответственно и F-меры (*F-мера*), определяют предпочтение данного метода на этапе обучения модели. kNN выдал максимальную оценку правильно классифицированных объектов к общему их количеству

(*Accuracy*), что подтверждает превосходство данного метода над другими.

Анализ матрицы ошибок проведённой классификации методом kNN на обучающей и тестовой выборках показал удовлетворительные результаты (табл. 5).

Лишь в 6 случаях (не нулевые значения за пределами главной диагонали матрицы) из 236 на обучающей выборке была получена не верная оценка.

Таблица 5. Матрица ошибок kNN на обучающей и тестовой выборках

Table 5. A confusion matrix of the kNN in training and test sampling

		Расчет										
		Обучение					Тест					
		C1	C2	C3	C4	Σ	C1	C2	C3	C4	Σ	
Факт	C1	40	0	0	3	43	C1	16	0	0	2	18
	C2	0	60	0	0	60	C2	0	26	0	0	26
	C3	0	0	62	1	63	C3	0	0	26	0	26
	C4	1	0	1	68	70	C4	0	0	1	29	30
	Σ	41	60	63	72	236	Σ	16	26	27	31	100

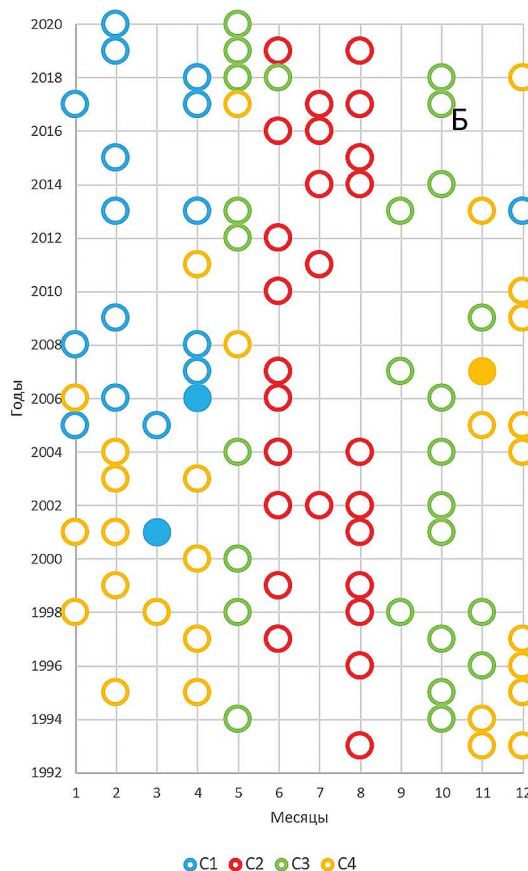
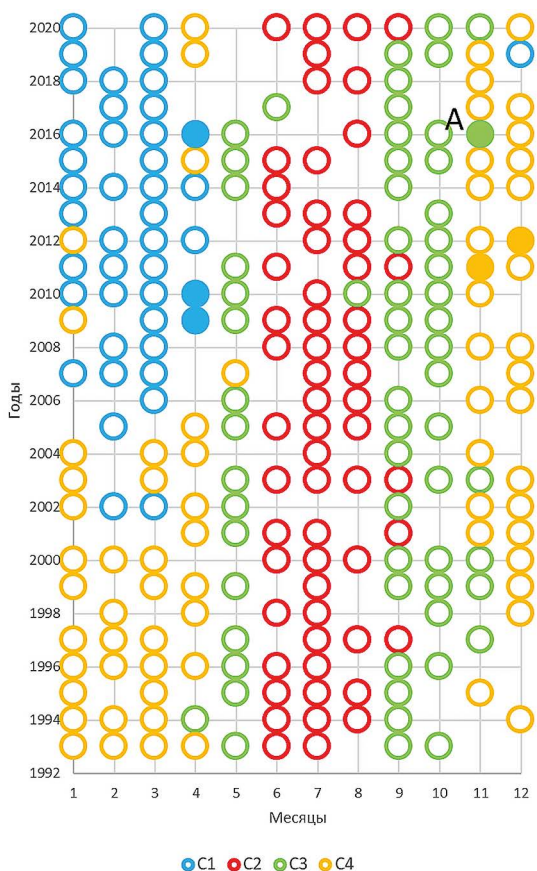


Рис. 5. Результаты работы kNN на обучающих (А) и тестовых (Б) данных, C1-C4 – имена кластеров, заполненные символы – ложно отрицательные ошибки классификации

Fig. 5. Results of the kNN of the training (A) and test (B) data, C1-C4 – names of the clusters, filled symbols – false negative classification errors



Абсолютно точно kNN справилась с определением летнего сезона (кластер С2), наибольшее количество ошибок было зафиксировано для четвертого кластера (зима, с умеренной толщиной ВКС). Общее количество правильных решений по обучающей выборке составило 97,5% (оценка Ассигасу, см. табл. 4). Проверка работы модели на тестовых значениях показала наличие трёх ложно положительных ошибок для третьего и четвертого кластера с оценкой точности 97,0%. Следует отметить, что восемь из девяти ложно

положительных ошибок по обоим выборкам приходятся на кластеры С3 и С4, что объясняется относительно низкой величиной их внутрикластерного силуэта (см. табл. 3).

В графическом виде работа kNN на обучающих и тестовых данных представлена на рис. 5.

Основная масса ошибок в классификации ВКС по среднемесячным картам распределения обоих выборок отмечалась в январе-апреле для периода позднее 2000 г. Вероятно, данные неточности были связаны

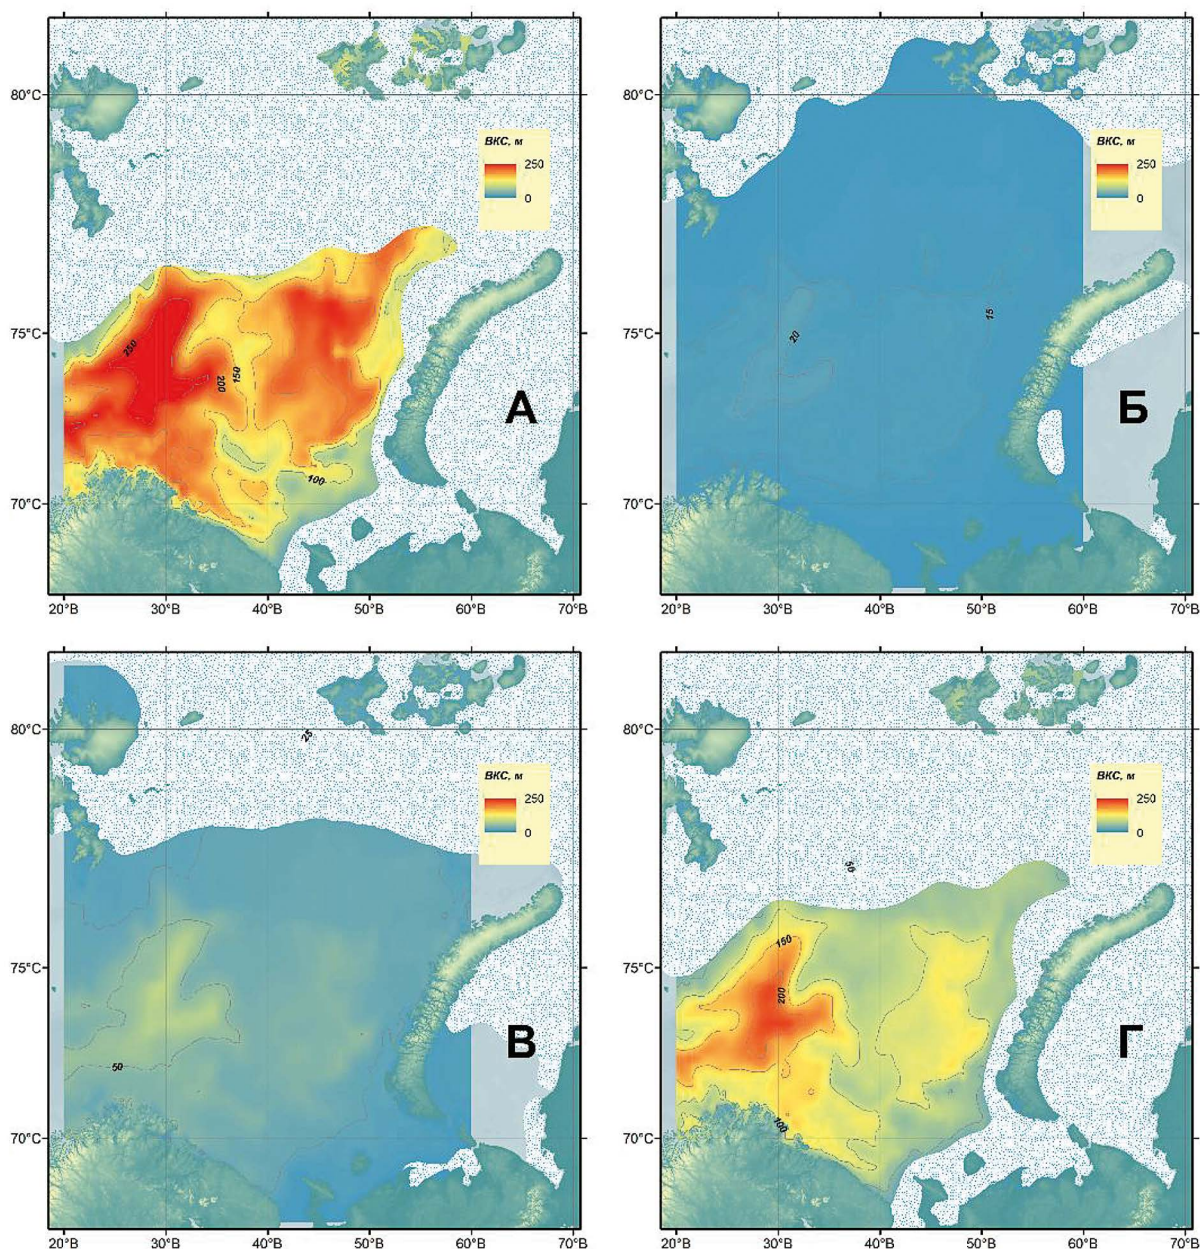


Рис. 6. Среднегодовое распределение ВКС в первом (А), во втором (Б), третьем (В) и четвертом (Г) кластерах. Ледовые условия в феврале (А и Г), ноябре (В) и июле (Б)

Fig. 6. Long-term mean of the MLD in the first (A), second (Б), third (В) and fourth (Г) clusters. Ice conditions in February (A and Г), November (В) and July (Б)

с тем, что этот период характеризовался возникновением отдельного кластера (см. рис. 4 Б) в зимний сезон года, а также существенными климатическими изменениями, связанными с увеличением теплосодержания воздушных и водных масс [Трофимов и др., 2018; Ingvaldsen et al., 2021].

На основе выделенных кластеров были построены среднемноголетние карты распределения ВКС (рис. 6).

По результатам работы модели, в январе-апреле существует обособленный тип распределения квазиоднородного слоя, соответствующий первому кластеру (см. рис. 6 А). Он характеризуется мощным вертикальным развитием слоя, охватывающим практически всю толщу вод и лимитирующим свой размах в отдельных местах лишь глубиной места. Развитый ВКС отмечается на значительной открытой ото льда акватории моря и может достигать толщины 200 м и более. Как правило, такие распределения достаточно редки, а наиболее часто они стали отмечаться после 2005 г. (см. рис. 4). Возможно, на механизм формирования усиленного развития ВКС оказывает влияние атлантификация Баренцева моря, которая, в свою очередь, ослабляет стратификацию вод, усиливает потоки тепла и сокращает морской лёд [Polyakov et al., 2023].

Наиболее характерным для зимнего сезона (декабрь-апрель) является тип распределения ВКС, сосредоточенный во втором кластере (см. рис. 6 Г). Толщина слоя имеет наибольшее развитие в границах распространения атлантических вод, с максимумом более 150 м в западной части моря.

Третий кластер (см. рис. 6 В) представляет собой переходное состояние квазиоднородного слоя от зимнего сезона к летнему и, наоборот, от летнего к зимнему. Продолжительность существования переходного периода в первом случае составляет месяц, во втором – около двух месяцев. В переходный период тол-

щина ВКС на рассматриваемой акватории изменяется в среднем в диапазоне 30–60 м, достигая максимальных значений (около 100 м) в западной части моря.

Четвёртый кластер (см. рис. 6 Б) характеризует свойства распределения верхнего квазиоднородного слоя в тёплый сезон (преимущественно июнь-сентябрь) года на рассматриваемой акватории Баренцева моря. В этот период толщина ВКС оценивается минимальными значениями (10–20 м) в течение календарного года.

Проведённая работа позволила выделить границы четырёх периодов в сезонной изменчивости ВКС на большей акватории Баренцева моря. Особый интерес представляют распределения, относящиеся к кластеру С1, существования которых стали обнаруживаться с начала 2000-х гг. Основной их чертой является увеличение толщины ВКС в зимний период года, вызванный ослаблением стратификации вод. На ослабление стратификации потенциальное влияние может оказывать изменение водного баланса [Hordoir et al., 2022], а также атлантификация вод Баренцева моря [Polyakov et al., 2023].

Из всех выделенных кластеров значимые межгодовые изменения отмечаются только в С1 (рис. 7).

Как видно из приведённого графика, в изменениях толщины ВКС отчётливо прослеживается выраженный тренд с амплитудой колебаний в рассматриваемый период до 20 м и межгодовым приростом одно-родного слоя в среднем около 1 м/год.

При использовании в расчётах среднесуточных данных по толщине ВКС, на основе созданной и обученной модели, представленной в работе, возможно получить временные ряды продолжительности сезонов годового цикла, которые, в свою очередь, могут быть полезны в изучении ряда задач:

- процессов накопления и отдачи тепла;

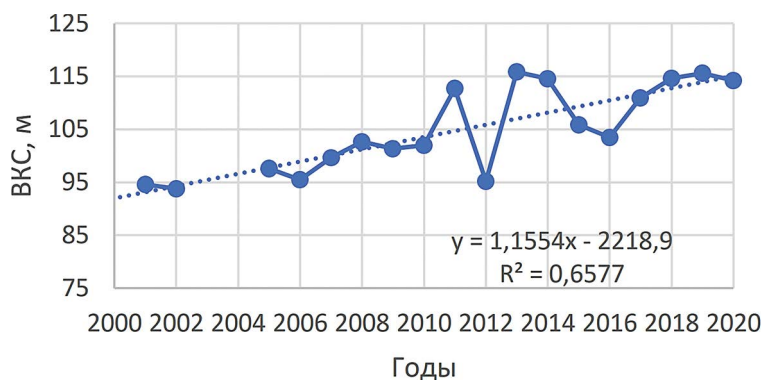


Рис. 7. Межгодовые изменения толщины ВКС в кластере С1

Fig. 7. Interannual changes in the thickness of the MLD in the cluster C1



- сроках начала и продолжительности цветения фитопланктона;
- условиях обитания зоо- и ихтиопланктона и проч.

## ЗАКЛЮЧЕНИЕ

В работе были апробированы алгоритмы ИИ и МО при анализе особенностей сезонных изменений развития ВКС. Для уменьшения размерности исходных данных использовался алгоритм t-SNE, который наилучшим образом отобразил рассматриваемые переменные в двумерной плоскости при величине переплексии 25 и 34 главных PCA-компонент. Выходные данные t-SNE анализа использовались для проведения кластерного анализа полей ВКС методом k-means. По данным результатов кластеризации была сформирована целевая переменная, на основе которой проводилось обучение моделей, отвечающей за определение принадлежности полей распределения к тому или иному сезону.

Из пяти рассматриваемых алгоритмов оптимальные результаты были получены по методу kNN, который правильно определил классы в 97,5% случаев по обучающей выборке (236 полей) и в 97,0% по тестовой выборке (100 полей).

Внутригодовая изменчивость в распределении однородного слоя на рассматриваемой акватории Баренцева моря характеризуется наличием зимнего (декабрь-апрель) и летнего (июнь-сентябрь) периода, а также переходного состояния ВКС (май, октябрь-ноябрь), располагающегося между этими двумя периодами. Кроме того, в холодный период года выделен отдельный кластер с повышенным развитием однородного слоя, проявляющийся с начала 2000-х гг. Возможно, его образование связано с увеличивающейся атлантификацией вод, а также изменением водного баланса. В структуре сезона с максимально развитым ВКС выявлен значимый возрастающий тренд с приростом толщины однородного слоя около 1 м/год.

## Конфликт интересов

Автор заявляет об отсутствии конфликта интересов.

## Соблюдение этических норм

Все применимые этические нормы соблюдены.

## Финансирование

Анализ материала и подготовка рукописи выполнены по личной инициативе без привлечения дополнительного финансирования.

## ЛИТЕРАТУРА

- Аверкиев А.С.* 1984. Моделирование синоптической изменчивости верхнего квазиоднородного слоя океана // *Метеорология и гидрология*. № 7. С. 102–104.
- Герасименко Е.М.* 2017. Интеллектуальный анализ данных. Алгоритмы Data Mining. Таганрог: Изд-во Южного федерального университета. 84 с.
- Захаржевский М.В., Козлов И.Е., Крицкий М.А., Осадчиев А.А., Степанова Н.Б.* 2021. Возможность применения методов машинного обучения для автоматического создания маски льда на спутниковых снимках Sentinel-1 // *Морские исследования и образование: Сб. трудов X Межд. науч.-практ. конф. Тверь, 25–29 октября 2021 года. Том I (III)*. – Тверь: ООО «ПолиПРЕСС». С. 219–222.
- Ившин В.А.* 2004. Вертикальная термохалинная и плотностная структура вод Баренцева моря. Мурманск: Изд-во ПИНРО. 99 с.
- Калацкий В.И.* 1978. Моделирование вертикальной термической структуры верхнего слоя океана. Л: Гидрометеоздат. 216 с.
- Колесников А.А., Кикин П.М., Комиссарова Е.В., Касьянова Е.Л.* 2018. Использование технологий машинного обучения при решении геоинформационных задач // *ИнтерКарто. ИнтерГИС*. Т. 24. № 2. С. 371–384. DOI 10.24057/2414–9179–2018–2–24–371–384.
- Кривогуз Д.О., Малько С.В., Семенова А.Ю.* 2020. Прогнозирование распределения зоопланктона в Южном океане с помощью машинного обучения // *Современная наука: актуальные проблемы теории и практики. Серия: Естественные и технические науки*. № 7. С. 37–43. DOI 10.37882/2223–2966.2020.07.19.
- Лучин В.А.* 2019. Средние многолетние параметры верхнего квазиоднородного слоя Берингова моря (нижняя граница, температура, солёность) и их внутригодовая изменчивость // *Известия ТИНРО*. Т. 199. С. 214–230. DOI 10.26428/1606–9919–2019–199–214–230
- Трофимов А.Г., Карсаков А.Л., Ившин В.А.* 2018. Изменения климата в Баренцевом море на протяжении последнего полувека // *Труды ВНИРО*. Т. 173. С. 79–91. DOI 10.36038/2307–3497–2018–173–79–9
- Чубукова И.А.* 2016. Data Mining. М.: Национальный Открытый Университет ИНТУИТ. 470 с.
- Ahmad H.* 2019. Machine learning applications in oceanography // *Aquatic Research*. V. 2(3). P. 161–169. DOI 10.3153/AR19014.
- Balamurali M., Melkumyan A.* 2016. t-SNE Based Visualisation and Clustering of Geological Domain // *International Conference on Neural Information Processing*. DOI 10.1007/978–3–319–46681–1\_67.
- Carton J., Grodsky S., Liu H.* 2008. Variability of the oceanic mixed layer, 1960–2004 // *Journal of Climate*. V. 21. P. 1029–1047. DOI 10.1175/2007JCLI1798.1.
- Dong C., Xu G., Han G., Bethel D., Xie W., Zhou Sh.* 2022. Recent Developments in Artificial Intelligence in Oceanography // *Ocean-Land-Atmosphere Research*. P. 1–26. DOI 10.34133/2022/9870950.
- Falkowski P., Barber R., Smetacek V.* 1998. Biogeochemical controls and feedbacks on ocean primary production//

- Science. Vol. 281. N. 5374. p. 200–206. DOI 10.1126/science.281.5374.200.
- Foster D., Gagne D., Whitt D. 2021. Probabilistic Machine Learning Estimation of Ocean Mixed Layer Depth From Dense Satellite and Sparse In Situ Observations // Journal of Advances in Modeling Earth Systems. V. 13. Iss. 12. DOI 10.1029/2021MS002474.
- Hua S., Zhiwei T., Junlong Q., An W., Xiao-Hai Y. 2024. Estimating the mixed layer depth of the global ocean by combining multisource remote sensing and spatiotemporal deep learning // International Journal of Digital Earth. DOI 10.1080/17538947.2024.2332374
- Hartigan J., Wong M. 1979. Algorithm AS 136: A K-Means Clustering Algorithm // Journal of the Royal Statistical Society. Series C (Applied Statistics). V. 28. No. 1. P. 100–08. DOI 10.2307/2346830.
- Hordoir R., Skagseth Ø., Ingvaldsen R., Sandø A., Löptien U., Dietze H., Gierisch A., Assmann K., Lundesgaard Ø., Lind S. 2022. Changes in Arctic stratification and mixed layer depth cycle: A modeling analysis // Journal of Geophysical Research: Oceans, V. 127. Iss. 1. e2021JC017270. DOI 10.1029/2021JC017270.
- Ingvaldsen R., Assmann K., Primicerio R., Fossheim M., Polyakov I., Dolgov A. 2021. Physical manifestations and ecological implications of Arctic Atlantification. // Nature Reviews Earth & Environment. V. 2. P. 874–889. DOI 10.1038/s43017-021-00228-x.
- Kobak D., Berens P. 2019. The art of using t-SNE for single-cell transcriptomics // Nature Communication. V 10: 5416. DOI 10.1038/s41467-019-13056.
- Montégut B., Madec C., Fischer G., Lazar A., Ludicone D. 2004. Mixed layer depth over the global ocean: An examination of profile data and a profile-based climatology // Journal of Geophysical Research. V. 109. C12003. DOI 10.1029/2004JC002378.
- Miller T., Durlík I., Lobodzińska A., Kozłowska P., Lewita K., Kaczanowska O. 2024. Oceans and Algorithms: A new era of machine learning in oceanography // Coll. of scien. pap. «SCIENTIA». DOI: 10.36074/scientia-26.01.2024
- Peralta-Ferriz C., Woodgate R. 2015. Seasonal and interannual variability of pan-Arctic surface mixed layer properties from 1979 to 2012 from hydrographic data, and the dominance of stratification for multiyear mixed layer depth shoaling // Progress in Oceanography. V. 134. P. 19–53. DOI 10.1016/j.pocean.2014.12.005.
- Polyakov I., Ingvaldsen R., Pnyushkov A., Bhatt U., Francis J., Janout M., Kwok R., Skagseth Ø. 2023. Fluctuating Atlantic inflows modulate Arctic atlantification // Science (New York, N.Y.), V. 381(6661). P. 972–979. DOI 10.1126/science.adh5158.
- Rubbens P., Brodie S., Cordier T., Barcellos D., Devos P., Fernandes-Salvador J., Fincham J., Gomes A., Handegard N., Howell K., Jamet C., Kartveit K., Moustahfid H., Parcerisas C., Politikos D., Sauzède R., Sokolova M., Uusitalo L., Van den Bulcke L., van Helmond A., Watson J., Welch H., Beltran-Perez O., Chaffron S., Greenberg D., Kühn B., Kiko R., Lo M., Lopes R., Möller K., Michaels W., Pala A., Romagnan J., Schuchert P., Seydi V., Villasante S., Malde K., Irisson J. 2023. Machine learning in marine ecology: an overview of techniques and applications // ICES Journal of Marine Science, V. 80, Iss. 7. P. 1829–1853. DOI 10.1093/icesjms/fsad100
- Sandø A., Mousing E., Budgell W., Hjøllø S., Skogen M., Adlandsvik B. 2021. Barents Sea plankton production and controlling factors in a fluctuating climate // ICES Journal of Marine Science. V. 78(6). P. 1999–2016. DOI 10.1093/icesjms/fsab067.
- Somavilla R., Gonzalez-Pola C., Fernandez-Diaz J. 2017. The warmer the ocean surface, the shallower the mixed layer. How much of this is true? // J. Geophys. Res. Oceans. V. 122. P. 7698–7716. DOI 10.1002/2017JC013125
- Szegedy C., Vanhoucke V., Ioffe S., Shlens J., Wojna Z. 2016. Rethinking the Inception Architecture for Computer Vision // IEEE Conference on Computer Vision and Pattern Recognition. IEEE, Las Vegas, NV, USA. P. 2818–2826. DOI 10.1109/CVPR.2016.308.
- Van der Maaten L., Hinton G. 2008. Visualizing Data using t-SNE // Journal of Machine Learning Research. V. 9. P. 2579–2605.
- Watelet S., Skagseth Ø., Lien V., Sagen H., Østensen Ø., Ivshin V., Beckers J.-M. 2020. A volumetric census of the Barents Sea in a changing climate. // Earth System Science Data. V. 12. P. 2447–2457.

## REFERENCES

- Averkiev A.S. 1984. Modeling of synoptic variability of the mixed layer depth in the ocean // Meteorology and hydrology. No. 7. P. 102–104. (In Russ.).
- Gerasimenko Y.M. 2017. Data mining. Data Mining Algorithms. Taganrog: Southern Federal University Press. 84 p. (In Russ.).
- Zakharzhevsky M.V., Kozlov I.E., Krinitsky M.A., Osadchiv A.A., Stepanova N.B. 2021. The possibility of using machine learning methods to automatically create an ice mask on Sentinel-1 satellite images // Marine Research and education: Proc. of the X Intern. Scient. and Prac. Conf. Tver, October 25–29, 2021. V. I (III). P. 219–222. (In Russ.).
- Ivshin V.A. 2004. Vertical thermohaline and density structure of the Barents Sea waters. Murmansk: PINRO Publish. 99 p. (In Russ.).
- Kalatsky V.I. 1978. Modeling of the vertical thermal structure of the upper ocean layer. Leningrad: Hydrometeoizdat. 216 p. (In Russ.).
- Kolesnikov A.A., Kikin P.M., Komissarova E.V., Kasyanova E.L. 2018. The use of machine learning technologies in solving geoinformation problems // The InterCarto. InterGIS. V. 24. No. 2. P. 371–384. DOI 10.24057/2414-9179-2018-2-24-371-384. (In Russ.).
- Krivoguz D.O., Malko S.V., Semenova A.Yu. 2020. Prediction of zooplankton distribution in Southern Ocean using machine learning // Modern science: Actual problems of theory and practice. Series: Natural and Technical Sciences. No. 7. P. 37–43. DOI 10.37882/2223-2966.2020.07.19. (In Russ.).
- Luchin V.A. 2019. Mean climatic parameters of the upper mixed layer in the Bering Sea (lower boundary, temperature, salinity) and their annual variability. // Izvestiya TINRO. V. 199(4). P. 214–230. DOI 10.26428/1606-9919-2019-199-214-230. (In Russ.).



- Trofimov A.G., Karsakov A.L., Ivshin V.A. 2018. Climate changes in the Barents Sea over the last half century // *Trudy VNIRO*. V. 173. p. 79–91. DOI 10.36038/2307–3497–2018–173–79–9. (In Russ.)
- Chubukova I.A. 2016. *Data Mining*. Moscow: Natsionalnyj otkrytyj institut (INTUIT). 470 p. (In Russ.)
- Ahmad H. 2019. Machine learning applications in oceanography // *Aquatic Research*. V. 2(3). P. 161–169. DOI 10.3153/AR19014.
- Balamurali M., Melkumyan A. 2016. t-SNE Based Visualisation and Clustering of Geological Domain // *International Conference on Neural Information Processing*. DOI 10.1007/978–3–319–46681–1\_67.
- Carton J., Grodsky S., Liu H. 2008. Variability of the oceanic mixed layer, 1960–2004 // *Journal of Climate*. V. 21. P. 1029–1047. DOI 10.1175/2007JCLI1798.1.
- Dong C., Xu G., Han G., Bethel D., Xie W., Zhou Sh. 2022. Recent Developments in Artificial Intelligence in Oceanography // *Ocean-Land-Atmosphere Research*. P. 1–26. DOI 10.34133/2022/9870950.
- Falkowski P., Barber R., Smetacek V. 1998. Biogeochemical controls and feedbacks on ocean primary production // *Science*. Vol. 281. N. 5374. p. 200–206. DOI 10.1126/science.281.5374.200.
- Foster D., Gagne D., Whitt D. 2021. Probabilistic Machine Learning Estimation of Ocean Mixed Layer Depth From Dense Satellite and Sparse In Situ Observations // *Journal of Advances in Modeling Earth Systems*. V. 13. Iss. 12. DOI 10.1029/2021MS002474.
- Hua S., Zhiwei T., Junlong Q., An W., Xiao-Hai Y. 2024. Estimating the mixed layer depth of the global ocean by combining multisource remote sensing and spatiotemporal deep learning // *International Journal of Digital Earth*. DOI 10.1080/17538947.2024.2332374
- Hartigan J., Wong M. 1979. Algorithm AS 136: A K-Means Clustering Algorithm // *Journal of the Royal Statistical Society. Series C (Applied Statistics)*. V. 28. No. 1. P. 100–08. DOI 10.2307/2346830.
- Hordoir R., Skagseth Ø., Ingvaldsen R., Sandø A., Löptien U., Dietze H., Gierisch A., Assmann K., Lundesgaard Ø., Lind S. 2022. Changes in Arctic stratification and mixed layer depth cycle: A modeling analysis // *Journal of Geophysical Research: Oceans*, V. 127. Iss. 1. e2021JC017270. DOI 10.1029/2021JC017270.
- Ingvaldsen R., Assmann K., Primicerio R., Fosheim M., Polyakov I., Dolgov A. 2021. Physical manifestations and ecological implications of Arctic Atlantification. // *Nature Reviews Earth & Environment*. V. 2. P. 874–889. DOI 10.1038/s43017–021–00228-x.
- Kobak D., Berens P. 2019. The art of using t-SNE for single-cell transcriptomics // *Nature Communication*. V 10: 5416. DOI 10.1038/s41467–019–13056.
- Montégut B., Madec C., Fischer G., Lazar A., Iudicone D. 2004. Mixed layer depth over the global ocean: An examination of profile data and a profile-based climatology // *Journal of Geophysical Research*. V. 109. C12003. DOI 10.1029/2004JC002378.
- Miller T., Durlík I., Lobodzińska A., Kozłowska P., Lewita K., Kaczanowska O. 2024. *Oceans and Algorithms: A new era of machine learning in oceanography* // *Coll. of scien. pap. «SCIENTIA»*. DOI: 10.36074/scientia-26.01.2024
- Peralta-Ferriz C., Woodgate R. 2015. Seasonal and interannual variability of pan-Arctic surface mixed layer properties from 1979 to 2012 from hydrographic data, and the dominance of stratification for multiyear mixed layer depth shoaling // *Progress in Oceanography*. V. 134. P. 19–53. DOI 10.1016/j.pocean.2014.12.005.
- Polyakov I., Ingvaldsen R., Pnyushkov A., Bhatt U., Francis J., Janout M., Kwok R., Skagseth Ø. 2023. Fluctuating Atlantic inflows modulate Arctic atlantification // *Science (New York, N.Y.)*, V. 381(6661). P. 972–979. DOI 10.1126/science.adh5158.
- Rubbens P., Brodie S., Cordier T., Barcellos D., Devos P., Fernandes-Salvador J., Fincham J., Gomes A., Handegard N., Howell K., Jamet C., Kartveit K., Moustahfid H., Parcerisas C., Politikos D., Sauzède R., Sokolova M., Uusitalo L., Van den Bulcke L., van Helmond A., Watson J., Welch H., Beltran-Perez O., Chaffron S., Greenberg D., Kühn B., Kiko R., Lo M., Lopes R., Möller K., Michaels W., Pala A., Romagnan J., Schuchert P., Seydi V., Villasante S., Malde K., Irisson J. 2023. Machine learning in marine ecology: an overview of techniques and applications // *ICES Journal of Marine Science*, V. 80, Iss. 7. P. 1829–1853. DOI 10.1093/icesjms/fsad100
- Sandø A., Mousing E., Budgell W., Hjøllo S., Skogen M., Adlandsvik B. 2021. Barents Sea plankton production and controlling factors in a fluctuating climate // *ICES Journal of Marine Science*. V. 78(6). P. 1999–2016. DOI 10.1093/icesjms/fsab067.
- Somavilla R., Gonzalez-Pola C., Fernandez-Diaz J. 2017. The warmer the ocean surface, the shallower the mixed layer. How much of this is true? // *J. Geophys. Res. Oceans*. V. 122. P. 7698–7716. DOI 10.1002/2017JC013125
- Szegedy C., Vanhoucke V., Ioffe S., Shlens J., Wojna Z. 2016. Rethinking the Inception Architecture for Computer Vision // *IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, Las Vegas, NV, USA. P. 2818–2826. DOI 10.1109/CVPR.2016.308.
- Van der Maaten L., Hinton G. 2008. Visualizing Data using t-SNE // *Journal of Machine Learning Research*. V. 9. P. 2579–2605.
- Watelet S., Skagseth Ø., Lien V., Sagen H., Østensen Ø., Ivshin V., Beckers J.-M. 2020. A volumetric census of the Barents Sea in a changing climate // *Earth System Science Data*. V. 12. P. 2447–2457.

Поступила в редакцию 26.10.2023 г.  
Принята после рецензии 06.08.2024 г.